

Clasificación de patrones de marcha para diferenciar entre adultos jóvenes y adultos mayores
utilizando modelos de aprendizaje automático sobre datos de sensores inerciales

María Fernanda Moros Rivera, Valentina Meza Cárdenas

Trabajo de Grado para optar al título de Ingeniería Mecánica

Directora

Diana Carolina Martínez Reyes

M.Sc Ingeniería Mecánica

Codirector

Diego Fernando Villegas

PhD Ingeniería Mecánica

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Mecánica

Ingeniería Mecánica

Bucaramanga

2026

Dedicatoria

A mis padres que son lo que más amo, mi ejemplo a seguir y mi motivación para superarme cada día, gracias por darme la oportunidad de estudiar lejos, de vivir mi gran sueño de ser UIS.

A mis tías por darme todo su apoyo, a Thiago que con su sonrisa me alegra la vida, a mi abuelita que me ama y me cuida desde el cielo.

A Brunito, mi alma gemela que me enseñó a convertir dolor en motivación, el que acompañó a mi mamá mientras yo estudiaba lejos de casa. Gracias, tu amor y tu recuerdo vivirá siempre conmigo.

A mis amigos Laura y Jaime; por entender mi lucha y recordarme quien soy. A Ari, que camina a mi lado, entiende mis sueños.

A las mujeres ingenieras que he encontrado en mi camino, con las que me construyo e inspiro.

A todos mis compañeros de carrera y de vida, con los que compartí madrugadas y traspasadas, libros, apuntes y empanadas. Infinitas gracias por creer en mí, por compartir el conocimiento y hacerme sentir que todo es posible con esfuerzo y dedicación.

- María Fernanda Moros Rivera

Inicialmente, a Dios, por nunca soltar mi mano; por ser mi motor principal y la luz de mi vida, porque llegar hasta aquí fue gracias a Él.

A mi madre, mi apoyo más incondicional, quien ha dedicado su vida entera a cuidarme, apoyarme y brindarme su amor.

A mi papá, por dedicar sus noches, sus días y sus desvelos para apoyar nuestros sueños: los míos y los de mis hermanos.

A mi familia entera, por ser el principal impulsor de lo que hoy soy, porque sus palabras de aliento inundan mi corazón de calma y mi mente de seguridad.

A mis amigos de carrera, esos seres invaluable, inteligentes y graciosos, con quienes no solo reí, sino también lloré, viví y aprendí. Fueron mi combustible cuando los días pesaban.

A todas las personas que sembraron en mí la semilla de que, con trabajo constante, disciplina y esfuerzo, es posible salir adelante.

- Valentina Meza Cárdenas

Agradecimientos

A la ingeniera Diana Martínez, directora de este proyecto, nuestro más sincero agradecimiento por confiar en nosotras, en nuestro talento y nuestras capacidades desde el primer momento. Gracias por cada reunión, por cada consejo y por cada enseñanza compartida a lo largo de este proceso. Sin su guía y su confianza, este trabajo no hubiese sido posible.

Al profesor Diego Villegas, gracias por despertar en nosotras el amor por la biomecánica. Su acompañamiento fue una guía invaluable en este camino, y su pasión se convirtió en una fuente constante de inspiración para el desarrollo de este proyecto.

Tabla de Contenido

	Pág.
Introducción	22
1. Planteamiento de la investigación.....	25
1.1 Planteamiento del problema.....	25
1.2 Justificación	26
1.3 Alcance y delimitaciones	27
1.4 Pregunta de investigación	28
2. Objetivos	
2.1 Objetivo General.....	29
2.2 Objetivos Específicos.....	29
3. Fundamentación teórica y estado del arte.....	30
3.1 Antecedentes bibliográficos.....	30
3.2 Revisión sistemática de la literatura	32
3.2.1 Criterios de búsqueda y selección.....	32
3.2.2 Resultados y características de estudios incluidos.....	34
3.2.3 Síntesis y vacíos identificados	38
3.3 Marco teórico	39
3.3.1 Definición de marcha.....	39
3.3.2 Fases de la marcha	39
3.3.3 Planos y direcciones anatómicas.....	41
3.3.4 Eventos de la marcha y Segmentación del ciclo Locomotor	42
3.3.4.1 Definición y significado biomecánico de Heel Strike y Toe – Off.....	43

3.3.4.2 Métodos de detección de Eventos de Marcha.....	44
3.3.4.3 Relación entre Segmentación y exactitud de los Biomarcadores Espaciotemporales.	45
3.3.4.4 Normalización Temporal del Ciclo de Marcha.....	46
3.3.5 Cinemática de la marcha.....	46
3.3.5.1 Parámetros temporales de la marcha.....	48
3.3.5.2 Parámetros espaciales de la marcha.....	52
3.3.6 Cinética de la marcha.....	56
3.3.6.1 Fuerza de reacción del suelo.	56
3.3.6.2 Torque articular.....	57
3.3.7 Clasificación de marcha patológica.	60
3.3.8 Tecnologías usadas para captura de movimiento en laboratorios de marcha.	61
3.3.8.1 Non Wearable Sensors.....	61
3.3.8.2 Wearable Sensors.....	62
3.3.9 Inteligencia Artificial.....	63
3.3.9.1 Machine Learning.....	63
3.3.9.2 Modelos de Validación.	67
3.3.9.3 Aprendizaje profundo.	70
3.3.9.4 Descubrimiento de conocimiento y análisis avanzado	70
3.3.9.5 Lógica difusa.....	70
3.3.10 Estadística aplicada al estudio	70
3.3.10.1 Estadística descriptiva.....	71
3.3.10.2 Estadística inferencial	71
3.3.10.3 Tamaño del efecto: d de Cohen..	72

4. Metodología	73
4.1 Tipo y diseño del estudio	73
4.2 Base de datos y muestra	74
4.2.1 Origen	74
4.2.2 Muestra inicial y grupos etarios	74
4.2.3 Sensores y protocolo de registro	74
4.2.4 Criterios de inclusión y exclusión aplicados	75
4.2.5 Flujo metodológico	75
4.3 Preprocesamiento de señales	75
4.3.1 Estructura de los datos brutos y carga	75
4.3.2 Recortes de bordes de señal (Trimming)	76
4.4 Segmentación y detección de eventos de marcha	77
4.4.1 Estrategias usadas para detección de eventos:	77
4.4.2 Comparación de estrategias	78
4.4.3 Algoritmo de Segmentación	78
4.4.4 Criterios de Aceptación y Descarte de Ciclos	79
4.4.5 Validación visual de los ciclos	80
4.4.6 Relación entre segmentación y cálculo de variables espaciotemporales	80
4.5 Extracción de Biomarcadores Espaciotemporales	81
4.5.1 Lista de biomarcadores calculados	81
4.5.2 Criterios de calidad y manejo de variables no calculables	84
4.5.3 Verificación de consistencia interna	85
4.5.5 Interpretación biomecánica en el contexto del envejecimiento	86

4.5.6 Niveles de Resumen Estadístico	87
4.5.7 Entorno y herramientas computacionales	88
4.6 Procedimiento de análisis estadístico.....	89
4.6.1 Agregación de datos por sujeto.....	89
4.6.2 Construcción de tablas maestras y estadística descriptiva.....	89
4.6.3 Evaluación de normalidad.....	90
4.6.4 Homogeneidad de varianzas y selección de prueba.....	90
4.6.5 Tamaño del efecto.....	91
4.7 Modelos de aprendizaje automático.....	92
4.7.1 Variables de entrada y variable objetivo.....	92
4.7.2 Modelos evaluados y configuración de hiper-parámetros	92
4.7.2.1 Regresión Logística	94
4.7.2.2 Máquina de Soporte Vectorial — SVM (kernel RBF).	94
4.7.2.3 Random Forest	94
4.7.2.4 Estrategia de validación.	94
4.7.2.5 Métricas de evaluación	96
4.7.2.6 Importancia de variables y análisis exploratorio:	97
4.7.2.7 Selección del mejor modelo.....	98
4.7.2.8 Librerías de ML utilizadas	99
4.8 Identificación e interpretación de biomarcadores relevantes.....	99
5. Resultados	100
5.1 Caracterización de la muestra	100
5.1.1 Descripción de la muestra y criterios de selección	100

5.1.2 Características demográficas y antropométricas.....	101
5.1.3 Protocolo de recolección de datos de GaitPrint	102
5.2 Resultados del preprocesamiento y segmentación.....	103
5.2.1 Coherencia morfológica interciclo.....	104
5.2.2 Simetría bilateral.....	105
5.3 Biomarcadores espaciotemporales: estadística descriptiva	107
5.3.1 Tabla descriptiva por biomarcador y grupo	107
5.4 Estadística inferencial	109
5.4.1 Comparación estadística y tamaño del efecto.....	109
5.4.2 Tamaño del efecto.....	111
5.4.3 Distribución de biomarcadores significativos.....	113
5.5 Resultados del modelo de aprendizaje automático	114
5.5.1 Selección de variables (features) para el modelo.....	114
5.5.2 Visualización PCA.....	115
5.5.3 Clasificación con Leave-One-Subject-Out (LOSO)	117
5.5.4 Desempeño comparativo de los clasificadores	117
5.5.5 Matrices de confusión	118
5.5.6 Curvas ROC por clasificador	119
5.5.7 Reporte detallado del mejor clasificador	121
5.6 Biomarcadores más relevantes para la clasificación.....	122
5.6.1 Biomarcadores más importantes para la clasificación	123
5.6.2 Comparación entre métodos de evaluación de importancia	123
6. Discusión.....	125

6.1 Biomarcadores significativos.....	126
6.1.1 Reducción del tiempo de apoyo unilateral.....	127
6.1.2 Reducción del tiempo de balanceo	127
6.1.3 Reducción del tiempo de ciclo.....	128
6.1.4 Ausencia de diferencia en parámetros espaciales	128
6.1.5 Ausencia de diferencias en el tiempo de doble apoyo	129
6.1.6 Ausencia de diferencias en velocidad de marcha	130
6.2 Discusión biomecánica del envejecimiento	132
6.3 Análisis de modelos de aprendizaje automático	133
6.3.1 Mejor desempeño.....	133
6.3.2 Aplicabilidad del modelo.....	134
6.3.3 Implicaciones clínicas.....	135
6.4 Integración de lo cuantitativo y lo cualitativo.....	135
6.5 Fortalezas	136
6.6 Limitaciones.....	137
7. Conclusiones	139
Referencias Bibliográficas	141

Lista de Tablas

	Pág.
Tabla 1. <i>Porcentajes y números de personas de 60 años y más con incapacidad</i>	25
Tabla 2. <i>Rutas de búsqueda utilizadas en bases de datos científicas, autoría propia</i>	32
Tabla 3. <i>Dependencia de biomarcadores espaciotemporales respecto a la segmentación</i>	45
Tabla 4. <i>Resumen de variables espaciotemporales calculadas con sus respectivas unidades y ecuaciones</i>	47
Tabla 5. <i>Comportamiento torque de cada articulación en el contacto inicial. b) en la respuesta a la carga. c) en el soporte medio. d) en el soporte terminal. e) en pre-balanceo en el plano sagital</i>	58
Tabla 6. <i>Comparación de estrategias de detección de eventos de marcha</i>	78
Tabla 7. <i>Listado de biomarcadores espaciotemporales calculados a partir del módulo spatiotemporal_calculation2.py</i>	82
Tabla 8. <i>Organización funcional de los 24 biomarcadores y dirección esperada del cambio con el envejecimiento. D: derecho; I: Izquierdo</i>	86
Tabla 9. <i>Niveles de agregación de los biomarcadores espaciotemporales y su uso en el proyecto</i>	87
Tabla 10. <i>Entorno computacional del proyecto</i>	88
Tabla 11. <i>Librerías utilizadas en Python para el análisis</i>	91
Tabla 12. <i>Características demográficas y antropométricas de la muestra</i>	101
Tabla 13. <i>Resumen de protocolo de recolección de datos de la base NONAN GaitPrint</i>	103
Tabla 14. <i>Estadísticos descriptivos de los 24 biomarcadores espaciotemporales</i>	107
Tabla 15. <i>Resultados de la prueba de Shapiro-Wilk</i>	110

Tabla 16. <i>Resumen de los tres clasificadores evaluados</i>	117
Tabla 17. <i>Clasificación por clase, precisión, Recall y F1-Score</i>	121
Tabla 18. <i>Comparación de estrategias locomotoras entre grupos basada en biomarcadores discriminantes</i>	123
Tabla 19. <i>Comparación de importancia Gini e importancia de permutación por biomarcador</i>	124
Tabla 20. <i>Comparación de los hallazgos del estudio con la literatura de referencia</i>	130

Lista de Figuras

	Pág.
Figura 1 <i>Diagrama de flujo PRISMA para selección de estudios</i>	33
Figura 2 <i>Distribución por tipo de sensor</i>	35
Figura 3 <i>Distribución por ubicación corporal</i>	35
Figura 4 <i>Histograma de tamaño de muestras</i>	36
Figura 5 <i>Proporción de estudios por área de aplicación en porcentaje</i>	37
Figura 6 <i>Algoritmos más utilizados en Machine Learning</i>	38
Figura 7 <i>Distribución anual de publicaciones entre 2015 y 2025</i>	39
Figura 8 <i>Representación fases de la marcha</i>	40
Figura 9 <i>Planos anatómicos del cuerpo</i>	42
Figura 10 <i>Representación gráfica de los parámetros temporales de la marcha</i>	48
Figura 11 <i>Representación gráfica de los parámetros espaciales de la marcha</i>	52
Figura 12 <i>Vector de la fuerza de reacción del suelo según el apoyo de la extremidad</i>	56
Figura 13 <i>Variación de la fuerza de reacción del suelo con relación al ciclo de marcha en fase de apoyo</i>	57
Figura 14 <i>Diseño explicativo secuencial</i>	74
Figura 15 <i>Pseudocódigo del procedimiento de validación cruzada Leave-One-Subject-Out</i>	95
Figura 16 <i>Coherencia morfológica interciclo de los ángulos de flexión de rodilla y cadera durante la marcha del sujeto S001 (G01, ensayo D01-B01-T01)</i>	105
Figura 17 <i>Simetría bilateral de ángulos de flexión de rodilla y cadera durante la marcha del sujeto S001 (G01, ensayo D01-B01-T01)</i>	106

Figura 18 <i>Señal de dorsiflexión del tobillo derecho (S002, G01, D01-B01-T01) tras el recorte temporal (10 s en cada extremo). El eje horizontal representa el número de muestra tras el recorte; el eje vertical representa el ángulo de dorsiflexión en grados</i>	107
Figura 19 <i>Tamaño del efecto (Hedges g) de los 24 biomarcadores analizados</i>	112
Figura 20 <i>Distribución de biomarcados significativos por grupo etario</i>	113
Figura 21 <i>Espacio de biomarcadores</i>	116
Figura 22 <i>Matrices de confusión.....</i>	118
Figura 23 <i>Curvas ROC (Receiver Operating Characteristic) de los tres clasificadores evaluados</i>	120
Figura 24 <i>Importancia de biomarcadores para la clasificación</i>	125

Lista de Apéndices

Los apéndices están disponibles en el Repositorio Institucional.

Apéndice A. Estadísticos de forma y prueba de Shapiro-Wilk por biomarcador (Archivo adjunto)

Apéndice B. Tabla maestra de biomarcadores espaciotemporales por sujeto (Archivo adjunto)

Apéndice C. Resultados de la revisión sistemática de literatura (Archivo adjunto)

Apéndice D. Caracterización de los estudios incluidos en la revisión sistemática (Archivo adjunto)

Apéndice E. Código de programación: Cálculo de parámetros espaciotemporales (Archivo adjunto)

Apéndice F. Código de programación: Análisis estadístico y modelos de aprendizaje automático (Archivo adjunto)

Glosario

Aprendizaje automático (Machine Learning): rama de la inteligencia artificial que desarrolla algoritmos capaces de aprender patrones a partir de los datos para realizar tareas de clasificación, predicción o reconocimiento sin ser programados explícitamente para cada caso.

Biomarcador espaciotemporal: variable cuantitativa obtenida del análisis de la marcha que describe características espaciales o temporales del desplazamiento, permitiendo evaluar el comportamiento locomotor de un individuo.

Cadencia: número de pasos realizados por minuto durante la marcha. Es un parámetro espaciotemporal ampliamente utilizado para evaluar el desempeño locomotor.

Clasificación: proceso mediante el cual un modelo de aprendizaje automático asigna una observación a una categoría previamente definida, como adulto joven o adulto mayor.

Ciclo de marcha: intervalo comprendido entre dos contactos iniciales consecutivos del mismo pie durante la locomoción. Constituye la unidad básica para el análisis biomecánico de la marcha.

Conjunto de entrenamiento: grupo de datos utilizado para entrenar un modelo de aprendizaje automático y permitir que aprenda los patrones presentes en la información.

Conjunto de prueba: grupo de datos empleado para evaluar el desempeño de un modelo una vez finalizado su entrenamiento.

Exactitud (Accuracy): métrica que expresa la proporción de clasificaciones correctas realizadas por un modelo respecto al total de observaciones evaluadas.

Fase de apoyo (Stance Phase): etapa del ciclo de marcha durante la cual el pie permanece en contacto con el suelo soportando el peso corporal.

Fase de balanceo (Swing Phase): etapa del ciclo de marcha en la que el pie permanece sin contacto con el suelo mientras avanza hacia el siguiente apoyo.

Heel Strike (HS): evento de la marcha que corresponde al instante en que el talón establece el primer contacto con el suelo, marcando el inicio del ciclo de marcha.

IMU (Unidad de Medición Inercial): dispositivo compuesto por acelerómetros y giróscopos que permite medir aceleraciones y velocidades angulares para registrar el movimiento de los segmentos corporales.

Inferencia estadística: conjunto de métodos estadísticos utilizados para determinar si las diferencias observadas entre grupos son significativas y pueden extrapolarse a una población.

Leave-One-Subject-Out (LOSO): técnica de validación cruzada en la que los datos de un sujeto se utilizan para prueba mientras los datos de los demás sujetos se emplean para entrenar el modelo.

Longitud de paso (Step Length): distancia longitudinal entre el contacto inicial de un pie y el contacto inicial del pie contralateral.

Longitud de zancada (Stride Length): distancia recorrida por un mismo pie entre dos contactos iniciales consecutivos.

Marcha humana: patrón de locomoción bípeda generado por la coordinación de los sistemas musculoesquelético y neurológico para producir el desplazamiento del cuerpo.

Modelo de clasificación: algoritmo de aprendizaje automático diseñado para asignar automáticamente observaciones a categorías previamente definidas.

Normalización temporal: procedimiento mediante el cual todos los ciclos de marcha se representan en una escala común de 0 a 100 %, permitiendo comparar sujetos y sesiones con diferente duración del ciclo.

Parámetros espaciales: variables que describen las características geométricas de la marcha, como la longitud de paso, longitud de zancada y ancho de paso.

Parámetros temporales: variables que describen la duración de las distintas fases del ciclo de marcha, como el tiempo de apoyo, tiempo de balanceo y tiempo de zancada.

Patrón de marcha: conjunto de características biomecánicas y espaciotemporales que describen la forma en que una persona camina.

Precisión (Precision): métrica que indica la proporción de predicciones positivas correctas respecto al total de predicciones positivas realizadas por el modelo.

Random Forest: algoritmo de aprendizaje automático basado en un conjunto de árboles de decisión cuya combinación mejora la capacidad de clasificación y reduce el sobreajuste.

Red Neuronal Convolutiva (CNN): arquitectura de aprendizaje profundo especializada en la extracción automática de características complejas a partir de datos como imágenes o señales.

Red Neuronal de Memoria a Largo y Corto Plazo (LSTM): tipo de red neuronal recurrente diseñada para modelar secuencias temporales y aprender dependencias de largo plazo entre los datos.

Segmentación del ciclo de marcha: proceso de identificación de los eventos que delimitan cada ciclo de marcha para calcular correctamente los biomarcadores espaciotemporales.

Sensor inercial: dispositivo electrónico capaz de medir aceleraciones y velocidades angulares para estimar el movimiento y la orientación de un segmento corporal.

Sensibilidad (Recall): métrica que mide la capacidad de un modelo para identificar correctamente los casos pertenecientes a una clase específica.

Tiempo de apoyo (Stance Time): intervalo durante el cual un pie permanece en contacto con el suelo durante un ciclo de marcha.

Tiempo de balanceo (Swing Time): intervalo durante el cual un pie permanece sin contacto con el suelo durante un ciclo de marcha.

Toe-Off (TO): evento que marca el instante en que el pie abandona completamente el suelo, indicando el final de la fase de apoyo y el inicio de la fase de balanceo.

Validación cruzada: técnica de evaluación utilizada para estimar la capacidad de generalización de un modelo mediante diferentes particiones de los datos en entrenamiento y prueba.

Resumen

Título: Clasificación de patrones de marcha para diferenciar entre adultos jóvenes y adultos mayores utilizando modelos de aprendizaje automático sobre datos de sensores inerciales *

Autor: María Fernando Moros Rivera y Valentina Meza Cárdenas **

Palabras Clave: Marcha, IMU, machine learning, espaciotemporales, envejecimiento

Descripción: El envejecimiento modifica los patrones de marcha humana, afecta la funcionalidad locomotora y aumenta el riesgo de caídas en adultos mayores. La identificación objetiva de estos cambios mediante sensores portátiles y modelos computacionales es relevante para la ingeniería mecánica y la biomecánica. Este estudio comparó la marcha de adultos jóvenes y adultos mayores mediante modelos de aprendizaje automático aplicados a datos cinemáticos y espaciotemporales obtenidos con sensores inerciales, con el fin de identificar cambios biomecánicos asociados al envejecimiento. Se analizaron 30 sujetos sanos: 15 adultos jóvenes (19–35 años) y 15 adultos mayores (56+ años), seleccionados de la base NONAN GaitPrint, capturada con sensores IMU Noraxon Ultium Motion™. Se extrajeron 24 biomarcadores espaciotemporales y se aplicó un protocolo estadístico secuencial (Shapiro-Wilk, Levene, t de Student, t de Welch y U de Mann-Whitney), complementado con el tamaño del efecto mediante Hedges g. Los biomarcadores significativos se emplearon como variables de entrada en tres clasificadores supervisados: Regresión Logística, SVM con kernel RBF y Random Forest, evaluados mediante validación cruzada Leave-One-Subject-Out (LOSO). Los resultados evidenciaron siete biomarcadores con diferencias estadísticamente significativas entre grupos ($p < 0.05$), todos asociados a parámetros temporales del ciclo de marcha: Right Stance Time, Right Swing Time, Single Support Time, Right Stride Time, Left Step Time, Left Swing Time y Left Stride Time, con tamaños de efecto grandes. Ningún parámetro espacial ni porcentual alcanzó significancia estadística, lo que indica que el envejecimiento locomotor en adultos funcionalmente sanos se manifiesta primero en la dimensión temporal. Random Forest obtuvo el mejor desempeño global (AUC-ROC = 0.707, Accuracy = 0.733, F1 = 0.733), superando a los modelos lineales. Se concluye que los biomarcadores temporales son los indicadores más sensibles para caracterizar cambios biomecánicos asociados al envejecimiento y que el aprendizaje automático es viable para apoyar la clasificación de patrones de marcha.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Ingeniería Mecánica. Directora: Diana Carolina Martínez Reyes. M.Sc Ingeniería Mecánica. Codirector: Diego Fernando Villegas. PhD Ingeniería Mecánica

Abstract

Title: Classification of walking patterns to distinguish between young adults and elderly adults using machine learning models based on inertial sensor data *

Author(s): María Fernando Moros Rivera y Valentina Meza Cárdenas **

Key Words: Step count, IMU, machine learning, space-time, aging

Description: Aging changes human walking patterns, affects locomotor function, and increases the risk of falls in elderly adults. The objective identification of these changes using wearable sensors and computational models is relevant to mechanical engineering and biomechanics. This study compared the gait of young adults and older adults using machine learning models applied to kinematic and spatiotemporal data obtained with inertial sensors, with the aim of identifying biomechanical changes associated with aging. Thirty healthy subjects were analyzed: 15 young adults (ages 19–35) and 15 older adults (ages 56+), selected from the NONAN GaitPrint database, with data captured using Noraxon Ultium Motion™ IMU sensors. Twenty-four spatiotemporal biomarkers were extracted, and a sequential statistical protocol (Shapiro-Wilk, Levene, Student's t-test, Welch's t-test, and Mann-Whitney U test) was applied, supplemented by effect size measures using Hedges' g. The significant biomarkers were used as input variables in three supervised classifiers: Logistic Regression, SVM with RBF kernel, and Random Forest, evaluated using Leave-One-Subject-Out (LOSO) cross-validation. The results revealed seven biomarkers with statistically significant differences between groups ($p < 0.05$), all associated with temporal parameters of the gait cycle: Right Stance Time, Right Swing Time, Single Support Time, Right Stride Time, Left Step Time, Left Swing Time, and Left Stride Time, with large effect sizes. No spatial or percentage parameters reached statistical significance, indicating that locomotor aging in functionally healthy adults' manifests first in the temporal dimension. Random Forest achieved the best overall performance (AUC-ROC = 0.707, Accuracy = 0.733, F1 = 0.733), outperforming linear models. We conclude that temporal biomarkers are the most sensitive indicators for characterizing biomechanical changes associated with aging and that machine learning is a viable approach for classifying walking patterns.

* Degree Work

** Faculty of Physio Mechanical Engineering. School of Mechanical Engineering. Mechanical Engineering. Director: Diana Carolina Martínez Reyes, M.Sc. in Mechanical Engineering. Co-director: Diego Fernando Villegas, PhD in Mechanical Engineering

Introducción

En Colombia, el envejecimiento poblacional es una realidad que avanza a un ritmo que demanda respuestas concretas del sistema de salud y de la comunidad científica. Según el Departamento Administrativo Nacional de Estadística, la población de 60 años o más crece aproximadamente un 3% anual, lo que proyecta un incremento de su proporción del 15% en 2015 la 21% para el año 2050 (DANE, 2023). Este cambio demográfico no es uniforme en sus consecuencias: en el año 2020 se registró que el 18,7% de la población mayor presentaba una o más discapacidades, de las cuales el 40% correspondía a dificultades para caminar, mover el cuerpo o subir y bajar escaleras (DANE, 2023). Estas cifras evidencian que el deterioro de la función locomotora representa una de las manifestaciones más significativas y con mayor impacto sobre la autonomía funcional y la calidad de vida en la vejez, y subrayan la necesidad urgente de desarrollar herramientas diagnósticas que permiten detectar, caracterizar y monitorear dicho deterioro de forma accesible.

La marcha humana es una de las funciones motoras más sensibles al proceso de envejecimiento. Los cambios locomotores que acompañan el envejecimiento se expresan como una reorganización del ritmo y la temporalización del ciclo locomotor, es decir, en la modificación de los tiempos de apoyo y balanceo, reducción del tiempo de una zancada, disminución del apoyo unilateral y adopción de una alternativa cautelosa que prioriza la seguridad postural sobre la eficiencia mecánica (Murray et al., 1969; Perry y Burnfield, 2010). Estos cambios preceden frecuentemente la aparición de caídas y el deterioro funcional avanzado, lo que convierte el análisis cuantitativo de la marcha en una herramienta para detección temprana del riesgo en adultos mayores. Sin embargo, la evaluación clínica tradicional se apoya en la observación directa de

terapeutas o instrumentos como Timed Up and Go, cuya resolución es insuficiente para capturar las sutiles modificaciones temporales que caracterizan el envejecimiento locomotor saludable (Hollman et al., 2011).

A pesar del avance conjunto de la instrumentación y aprendizaje automático, persisten preguntas abiertas sobre la capacidad de biomarcadores espaciotemporales (obtenidos de unidad de sensores inerciales) para diferenciar de forma automatizada a adultos jóvenes de adultos mayores funcionalmente sanos. La literatura existente se ha concentrado predominantemente en poblaciones con deterioro locomotor. Además, la validación de modelos de clasificación mediante esquemas robustos que prevengan el sobreajuste en muestras pequeñas ha sido abordado de forma limitada. En el contexto colombiano, la disponibilidad de herramientas computacionales validadas para la caracterización objetiva del envejecimiento locomotor es escasa, lo que refuerza la pertinencia de contribuir desde la ingeniería mecánica a este campo de aplicación clínica y biomecánica de alto impacto social.

El presente trabajo propone comparar los patrones de marcha entre adultos jóvenes y adultos mayores mediante el análisis de biomarcadores espaciotemporales extraídos a través de una señal IMU y con ayuda de modelos de aprendizaje automático supervisados. A partir de una base de datos de NONAN GaitPrint, se calculan 24 biomarcadores espaciotemporales para una muestra de 30 sujetos (15 adultos jóvenes y 15 adultos mayores sanos), obtenidos mediante un pipeline de procesamiento desarrollado en Python. Las diferencias entre grupos se evaluaron mediante análisis estadístico inferencial con estimación del tamaño del efecto, y tres clasificadores supervisados (Regresión Logística, Máquinas de Vectores de Soporte y Random Forest), son evaluados por medio de validación cruzada Leave-One-Subject-Out, esquema apropiado para datos con medidas repetidas por sujeto. El trabajo busca determinar qué biomarcadores

espaciotemporales son susceptibles a la hora de capturar las diferencias locomotoras entre grupos etarios, y si un modelo de aprendizaje automático puede clasificar el grupo etario con un nivel de desempeño relevante a partir de dichos parámetros.

Este trabajo representa un aporte desde la ingeniería mecánica a la comprensión cuantitativa del envejecimiento locomotor en adultos colombianos, articulando cinemática, biomecánica computacional y aprendizaje automático en una metodología reproducible, construida sobre datos de acceso abierto y herramientas de código libre. Sus resultados sientan una base para el desarrollo de sistemas de evaluación funcional no invasivos aplicables en entornos clínicos con recursos limitados, y contribuyen a estrategias de rehabilitación adaptadas al perfil biomecánico del adulto mayor. La combinación de estadística, interpretabilidad biomecánica y validación del modelo otorga al estudio solidez metodológica para su replicación y extensión en investigaciones con muestras de mayor tamaño y diversidad clínica.

1. Planteamiento de la investigación

1.1 Planteamiento del problema

En Colombia, el envejecimiento poblacional es una realidad creciente. Según el DANE se estima que la población de 60 años o más crece 3% anual, lo que indica que para el año 2050 pasará de 15% de 2015 a 21% (DANE, 2023). Estas cifras indican que con el tiempo habrá mayor proporción de adultos mayores (60 años o más) en comparación con la población adulta joven (UNFPA, 2023). Lo que traerá consigo afectaciones biológicas, fisiológicas y neurológicas relacionadas al envejecimiento.

Además, en el 2020 se registró que el 18,7% de la población mayor presentaba una o más incapacidades, de las cuales el 40% correspondía a adultos mayores con dificultades para caminar, mover el cuerpo o subir y bajar escaleras (DANE, 2023). Como se observa en la Tabla 1, estos datos representan una alerta para el sistema de salud, ya que evidencia la necesidad de desarrollar estrategias médicas más eficaces que contribuyan a mejorar la calidad de vida a la población adulta mayor.

Tabla 1

Porcentajes y números de personas de 60 años y más con incapacidad

Actividad	Oír la voz o los sonidos?		Hablar o conversar?		Ver de cerca, de lejos o alrededor?		Mover el cuerpo, caminar o subir y bajar escaleras?		Agarrar o mover objetos con las manos?		Entender, aprender, recordar o tomar decisiones por sí mismo/a?		Comer, vestirse o bañarse por sí mismo/a?		Relacionarse o interactuar con las demás personas?	
Personas de 60 años y más	Total personas	%	Total personas	%	Total personas	%	Total personas	%	Total personas	%	Total personas	%	Total personas	%	Total personas	%
	263	22,4	103	8,8	656	55,8	478	40,7	178	15,2	149	12,6	179	15,2	92	7,8

Nota. Esta tabla es representativa debido a que muestra como la mayoría de las personas durante el estudio presentan discapacidad para caminar y/o mover el cuerpo. Tomado de: [Personas mayores en Colombia: hacia la inclusión y participación](#).

Adicionalmente, existen trastornos asociados a alteraciones biomecánicas, los cuales pueden ser indicadores de enfermedades como síndrome de Parkinson, accidente cerebrovascular, problemas del sistema músculo esquelético, entre otros. Estas condiciones requieren observaciones, estudios y análisis para generar soluciones que fortalezcan la atención y rehabilitación (Cárdenas et al., 2023). Más aún, la biomecánica de la marcha no sólo es relevante en adultos mayores, sino también en niños, deportistas y pacientes en recuperación quienes se exponen diariamente a fracturas, fallas músculo esqueléticas y alteraciones en la movilidad.

Debido a esta problemática, se vuelve fundamental encontrar una solución eficiente, accesible e innovadora que permita estudiar y analizar los patrones de la marcha, mejorando así, el futuro bienestar de la población adulta joven y adulto mayor. En este contexto, los modelos de inteligencia artificial basados en aprendizaje automático ofrecen una herramienta eficaz para optimizar el análisis de la marcha, diferenciando patrones entre adultos jóvenes y mayores, y fortaleciendo la atención médica en Colombia.

1.2 Justificación

La aplicación de la inteligencia artificial en la biomecánica de la marcha permite analizar y comprender el deterioro progresivo de la locomoción desde la adultez joven hasta la vejez. Con el paso del tiempo, factores como la pérdida de fuerza muscular, la reducción del equilibrio y la disminución de la coordinación afectan la marcha, aumentando el riesgo de caídas y lesiones. Actualmente, muchas evaluaciones de marcha requieren equipos especializados y la presencia de profesionales en entornos clínicos, lo que limita su accesibilidad.

La implementación de sensores inerciales y dispositivos wearables (IBV, 2020), facilitan la evaluación de la marcha en entornos cómodos para los pacientes sanos y patológicos eliminando

la necesidad de acudir a centros especializados (Lim, 2022). La integración de un modelo de Machine Learning permite procesar datos en tiempo real y monitorear continuamente la evolución del paciente y facilita la detección temprana de anomalías a lo largo de este proceso, permitiendo intervenciones oportunas que ayuden a retrasar el deterioro funcional y mejorar la movilidad a lo largo de la vida (Mollá, 2022).

En definitiva, la inteligencia artificial no solo facilita la identificación de patrones de marcha diferenciados entre adultos jóvenes y mayores, sino que también permite una evaluación más accesible y continua de los cambios biomecánicos asociados al envejecimiento. Su implementación en el sistema de salud colombiano representa una oportunidad para optimizar la asignación de recursos, agilizar los procesos de diagnóstico y promover estrategias preventivas más eficaces. De este modo, se contribuye a una atención más personalizada y oportuna, lo que impacta positivamente en la movilidad y calidad de vida de la población adulta.

1.3 Alcance y delimitaciones

La presente investigación propone que existen diferencias biomecánicas significativas en los parámetros espaciotemporales de la marcha que permiten la clasificación de sujetos mediante modelos de aprendizaje automático, distinguiendo con precisión entre 15 adultos jóvenes (19 a 35 años) y 15 adultos mayores (56 años en adelante).

A través de la extracción y análisis estadístico de la base de datos GaitPrint (Wiles, T.M., Mangalam, M., Sommerfeld, J.H. et al., 2023), se proyecta que variables como la cadencia, la amplitud y la simetría del paso mostrarán alteraciones características del proceso de envejecimiento. El alcance de esta investigación es de carácter analítico y predictivo, está sujeto a limitaciones específicas, incluyendo un tamaño muestral final de 76 participantes, una alta

dependencia de la calidad de segmentación de las señales inerciales, y una generalización limitada de los resultados al emplear una sola base de datos para el entrenamiento y validación del modelo.

1.4 Pregunta de investigación

¿Qué características biomecánicas derivadas de datos cinemáticos y espaciotemporales, permiten diferenciar patrones de marcha entre adultos jóvenes y adultos mayores?

2. Objetivos

2.1 Objetivo General

Comparar patrones de marcha entre adultos jóvenes y adultos mayores mediante la implementación de un modelo de inteligencia artificial basado en el análisis de datos cinemáticos y espaciotemporales de sensores inerciales, para identificar cambios biomecánicos asociados al envejecimiento.

2.2 Objetivos Específicos

Identificar biomarcadores de la marcha como cadencia, tiempo de apoyo y balanceo, amplitud, ancho de paso, y simetría del paso a partir del análisis de datos cinemáticos extraídos de la base de datos GaitPrint.

Analizar estadísticamente los indicadores de marcha mediante pruebas de hipótesis para identificar las características biomecánicas más relevantes en la diferenciación de los grupos.

Adaptar un modelo de inteligencia artificial empleando algoritmos de aprendizaje automático que evalúen su desempeño con métricas de clasificación, identificando patrones de marcha característicos del envejecimiento.

3. Fundamentación teórica y estado del arte

3.1 Antecedentes bibliográficos

En los últimos años, los avances biomecánicos han impulsado una mayor investigación sobre la marcha y sus cambios a lo largo del envejecimiento, desde la etapa de adulto joven hasta el adulto mayor. Con el auge de la inteligencia artificial, cada vez más investigadores estudian cómo el análisis de variables biomecánicas y espaciotemporales, de la mano con modelos de aprendizaje automático, permite identificar patrones de marcha, predecir riesgos y mejorar la detección temprana de alteraciones en la locomoción.

Desde el proyecto "Análisis de la marcha en el adulto mayor, simulador de estado funcional" (Oquendo & Soto, 2015) de la Universidad Pontificia Bolivariana, identifica variables biomecánicas y espacio temporales que diferencian la marcha en adultos jóvenes y mayores. La creación de un simulador de estado funcional proporciona una base de referencia para la comparación de los cambios de marcha y apoya el desarrollo de un modelo de inteligencia artificial.

Un estudio realizado en Países Bajos “Age-related gait patterns classification using Deep Learning based on time-series data from one accelerometer” evaluó la clasificación de patrones de marcha relacionados con la edad en adultos jóvenes y adultos mayores. Los resultados demuestran que el modelo Deep Learning, supera enfoques convencionales de aprendizaje automático, ya que, es capaz de identificar características importantes de la marcha relacionadas con el envejecimiento que no habían sido investigadas (Zheng; Wilhelm; Otten & Reneman, 2024). Además, se destaca que los ciclos de la marcha juegan un papel fundamental para mejorar la clasificación.

Por otro lado, “Análisis dinámico de los momentos articulares en la marcha humana en adultos y adultos mayores usando el análisis de componentes principales (PCA)” es un referente fundamental para identificar las variaciones en el patrón de la marcha en adultos y adultos mayores, utilizando el método de componentes principales en pares articulares. Los resultados de esta investigación evidencian que el deterioro del sistema musculoesquelético es una de las principales causas del riesgo de caídas, lo que orienta el diseño de dispositivos de asistencia para mejorar la movilidad y prevenir accidentes (Garcia; Rodriguez, Jayakumar, Romero & Alonso, 2021).

La tesis doctoral “Aprendizaje automático para la detección de inicio/fin de la marcha mediante dos sensores inerciales y modelado de datos usando aprendizaje profundo” destaca la importancia del análisis de la marcha en la identificación de anomalías y posibles tratamientos clínicos. Esta investigación abarca la toma de datos, diseño de un modelo cinemático y la predicción de eventos mediante Deep Learning, obteniendo consigo características para entrenamiento de algoritmos de Machine Learning. Este estudio resalta el potencial de la inteligencia artificial en la clasificación y predicción de características de la marcha para aplicaciones clínicas (Teran Pineda; 2024).

Estas investigaciones resaltan la importancia del análisis de la marcha y su cambio con la edad. El aprendizaje automático y el Deep Learning tienen un impacto significativo en la clasificación de patrones de marcha a partir de variables biomecánicas y espaciotemporales. En particular, Deep Learning se impone como un enfoque práctico y eficaz en la detección de características de la marcha asociadas al envejecimiento. Estas investigaciones consolidan la necesidad de desarrollar un modelo de inteligencia artificial que diferencie con precisión la marcha en adultos jóvenes y mayores mediante datos de sensores inerciales, proporcionando una base sólida para la clasificación de variaciones biomecánicas de la marcha para la prevención de caídas.

3.2 Revisión sistemática de la literatura

3.2.1 Criterios de búsqueda y selección.

Se desarrolló una revisión sistemática bajo el método PRISMA, con el fin de asegurar rigurosidad y transparencia en la selección y análisis de estudios. La búsqueda bibliográfica se realizó en cinco bases de datos especializadas: IEEE Xplore, Taylor & Francis, ScienceDirect, Scopus y Google Scholar, para la construcción de las ecuaciones de búsqueda que emplearon las palabras “Gait Analysis, Machine Learning, IMU, Wearable Sensors y Pattern Classification, combinadas mediante operadores booleanos (AND, OR). La Tabla 2 presenta las rutas de búsqueda específicas utilizadas en cada base de datos.

Tabla 2

Rutas de búsqueda utilizadas en bases de datos científicas, autoría propia

Base de datos	Ruta de búsqueda
Google Academic	"gait analysis normal and pathological function research gait analysis normal and pathological function gait analysis machine learning model wearable sensors gait analysis"
Science Direct	"gait AND analysis AND imu AND patterns AND gait AND machine AND learning AND classification AND people"
Nature	"gait AND analysis AND imu AND patterns AND gait AND machine AND learning AND classification AND young AND people AND older AND people"
Taylor & Francis	[All: gait] AND [All: analysis] AND [All: imu] AND [All: patterns] AND [All: gait] AND [All: machine] AND [All: learning] AND [All: classification] AND [All: young] AND [All: people] AND [All: older and people]
IEEE Xplore	("All Metadata":gait AND "All Metadata":analysis AND "All Metadata":imu AND "All Metadata":patterns AND "All Metadata":gait AND "All Metadata":machine AND "All Metadata":learning AND "All Metadata":classification AND "All Metadata":young AND "All Metadata":people AND "All Metadata":older)

A partir de la búsqueda inicial se identificaron más de 4.000 registros. Para sistematizar su selección, se establecieron criterios de inclusión y exclusión que se describen a continuación.

Criterios de inclusión:

- Artículos publicados en inglés o español entre 2015 y 2025.

- Estudios que apliquen modelos de aprendizaje automático al análisis de patrones de marcha con datos provenientes de sensores inerciales (IMU).
- Trabajos que reporten métricas cuantitativas de desempeño del modelo.

Criterios de exclusión:

- Estudios teóricos sin validación experimental o sin acceso a texto completo.
- Investigaciones basadas exclusivamente en sensores ópticos, plataformas de fuerza u otros dispositivos distintos a IMU.
- Trabajos que no diferencien grupos poblacionales por edad o que omitan resultados cuantitativos

La aplicación de estos criterios sobre los títulos y resúmenes de los registros identificados permitió reducir el universo de estudio a 66 artículos con potencial de inclusión. Posteriormente, mediante la lectura del texto completo, se redujo la selección final a 50 artículos. La Figura 1 ilustra este proceso de selección mediante el diagrama de flujo PRISMA 2020.

Figura 1

Diagrama de flujo PRISMA para selección de estudios





De cada artículo incluido se extrajeron las siguientes variables: año de publicación, tipo y ubicación corporal de los sensores IMU, algoritmos de aprendizaje automático aplicados, métricas de desempeño reportadas, tamaño muestral, principales hallazgos y limitaciones declaradas, los cuales se observan en Apendiz C y Apendiz D. La información extraída fue sometida a análisis estadístico descriptivo para identificar patrones, tendencias y vacíos en la literatura existente.

3.2.2 Resultados y características de estudios incluidos

El análisis de los 50 artículos seleccionados permite caracterizar el campo desde tres dimensiones complementarias: los dispositivos de captura empleados, las poblaciones estudiadas y los algoritmos reportados con su desempeño asociado.

Las unidades de medición inercial (IMU) constituyen la tecnología predominante, parecen plataformas de fuerza y acelerómetros independientes (5 estudios cada uno), plantillas instrumentadas (4), sistemas ópticos 3D (3), electromiografía —EMG— (2), Kinect/RGB-D (1) y etiquetas de localización (1). En cuanto a la configuración, la mayoría de los estudios emplea entre uno y tres sensores. Respecto a la ubicación corporal, las Figuras 2 y 3 resumen la distribución registrada. El tobillo y el pie (23 estudios) constituyen la zona más instrumentada por su capacidad para capturar eventos clave del ciclo de marcha como el contacto inicial y el despegue.

Figura 2*Distribución por tipo de sensor***Figura 3***Distribución por ubicación corporal*

Las poblaciones abordadas reflejan una orientación predominantemente clínica. Los adultos mayores constituyen el grupo más frecuente, presentes en aproximadamente 18 estudios, con énfasis en evaluación de riesgo de caídas, fragilidad y deterioro cognitivo. Los adultos jóvenes sanos se emplean principalmente como grupo de control o para validación de algoritmos, con presencia en doce estudios. Es importante resaltar que tres estudios abordan específicamente la diferenciación entre adultos jóvenes y adultos mayores mediante clasificación automática, lo que guarda relación directa con el objetivo de la presente investigación. En la Figura 4 se observa que los tamaños muestrales presentan alta variabilidad, con valores entre 3 y 803 participantes (mediana: 37; media: ≈ 93), solo cinco estudios superan los 240 participantes. En la Figura 5 se realizó una proporción de los estudios por área de aplicación.

Figura 4

Histograma de tamaño de muestras






Figura 5

Proporción de estudios por área de aplicación en porcentaje



El análisis de las técnicas de aprendizaje automático reportadas en los 50 estudios incluidos revela patrones claros tanto en la preferencia metodológica como en el desempeño alcanzado. La Figura 6 presenta la distribución de frecuencias de los algoritmos identificados. Las redes neuronales convolucionales CNN (Precisión 92 -99%) y las arquitecturas de memoria a largo y corto plazo LSTM (Precisiones 94,3- 99,81%) registran 9 menciones cada una, especialmente en tareas de detección de eventos y modelación de secuencias temporales, posicionándose como las técnicas de aprendizaje profundo más adoptadas en el campo. El desempeño de todos los métodos está fuertemente condicionado por el tamaño muestral: estudios con menos de 30 participantes tienden a reportar precisiones extremas poco generalizables. Las tareas de clasificación binaria superan consistentemente el 90%, mientras que las tareas multiclase y de regresión presentan mayor variabilidad.

Figura 6*Algoritmos más utilizados en Machine Learning*

3.2.3 Síntesis y vacíos identificados


La revisión de los 50 estudios incluidos confirma que el análisis de marcha basado en IMU y aprendizaje automático es un campo en consolidación, con crecimiento sostenido desde 2019 y orientación predominantemente clínica, como se representa en la Figura 7. SVM y Random Forest dominan la literatura por su robustez ante muestras pequeñas, mientras que CNN y LSTM ganan terreno progresivamente en tareas de mayor complejidad temporal y espacial.

El 62% de los estudios emplea muestras inferiores a 51 participantes, lo que compromete la generalización de los modelos. La heterogeneidad en las métricas reportadas impide comparaciones directas entre algoritmos, y la concentración geográfica en países desarrollados limita la representatividad de los hallazgos. El vacío más significativo identificado es la escasez de estudios que aborden de forma directa y exclusiva la clasificación de patrones de marcha entre

adultos jóvenes y adultos mayores utilizando únicamente sensores inerciales y modelos de aprendizaje automático

Figura 7

Distribución anual de publicaciones entre 2015 y 2025



3.3 Marco teórico

3.3.1 Definición de marcha

La marcha se define como la combinación de distintos sistemas tanto superiores como inferiores involucradas en el caminar con el objetivo de lograr una locomoción bípeda, siendo las extremidades inferiores las que logran esta acción.

También suele definirse como la capacidad de un cuerpo de desplazar su centro de gravedad con la participación del sistema músculo esquelético (Cifuentes et al., 2010).


3.3.2 Fases de la marcha

En el estudio de la marcha se ha encontrado que se divide dos fases, siendo una de ellas la fase de apoyo y la segunda la fase de balanceo, la primera fase corresponde al 60% y la segunda

al 40%, respectivamente, del ciclo de la marcha (Webster, J. & Darter, B., 2019). Como se representa en la Figura 8.

Figura 8

Representación fases de la marcha



Fuente. Principles of Normal and Pathologic Gait. Webster, J. B. & Darter, B. J. (2019).

En la fase de apoyo el pie en contacto con el suelo absorbe la carga corporal para impulsarlo hacia el siguiente paso. Para la inmovilidad de un pie durante la fase de apoyo se necesita más que la actividad neuronal y nerviosa, también depende de los rockers en el tobillo, pie y antepié (figura 1). Esta fase del ciclo suele dividirse en fases como: contacto inicial (golpe talón), respuesta de carga (pie plano), se ve expresada como doble apoyo en las extremidades; apoyo medio, comienza cuando el pie contralateral abandona el suelo y dura hasta que el talón ipsilateral abandona el suelo; apoyo terminal (talón quitado) esta etapa comienza cuando el talón ipsilateral abandona el suelo hasta el contacto inicial del pie contralateral, pre-swing (despegue de la punta), esta es la fase final del apoyo y dura desde en el momento que el pie contralateral entra en contacto inicial con el suelo hasta el pie ipsilateral se despega del sueño. Esta última etapa, tiene un doble soporte de apoyo (Maceira, E., 2003).

Durante la fase de balanceo encontramos que se divide en tres etapas, balanceo inicial que tiene como objetivo posicionar el pie para despejar el suelo a medida que avanza. Este abarca el tiempo desde que el pie abandona el suelo hasta que el pie ipsilateral se alinea con el tobillo contralateral. El balanceo medio corresponde al tiempo desde la alineación del tobillo y pie hasta que la tibia de la pierna que se impulsa esté vertical. Finalmente, el balanceo terminal, está enfocado en el tiempo que transcurre desde que la tibia está en posición vertical hasta que el contacto con el suelo del pie de balanceo (Webster, J. B. & Darter, B. J., 2019).


3.3.3 Planos y direcciones anatómicas

En el estudio de la marcha humana es necesario tener en cuenta tres planos anatómicos principales que permiten el análisis de la locomoción de manera estructurada y precisa (Marieb, E., 2008). En la Figura 9 se representa cada uno de ellos.

Plano sagital: Este corte longitudinal divide el cuerpo en partes iguales, una parte derecha y una parte izquierda.

Plano coronal (Frontal): Corte longitudinal sobre el cuerpo que lo divide en partes anteriores y posteriores.

Plano transversal: Corte horizontal y que divide el cuerpo en superior e inferior.

Figura 9*Planos anatómicos del cuerpo*

Fuente. Anatomía y fisiología humana (Marieb, E., 2008)

Adicionalmente existen unas direcciones que describen con exactitud la ubicación y comportamiento de segmentos corporales de la marcha, como: superior o inferior, ventral o dorsal, medial o lateral, proximal o distal (Marieb, E., 2008).

3.3.4 Eventos de la marcha y Segmentación del ciclo Locomotor

Perry y Burnfield (2010) denominan el ciclo de la marcha como el intervalo temporal comprendido entre dos contactos iniciales consecutivos del mismo pie en el suelo. Su delimitación precisa constituye el fundamento sobre el cual se calculan todas las variables espaciotemporales, cinemáticas y cinéticas usadas en la caracterización biomecánica del individuo.

3.3.4.1 Definición y significado biomecánico de Heel Strike y Toe – Off . El Heel Strike o también denominado *contacto inicial* en la nomenclatura de Perry y Burnfield (2010), el instante en que el talón de pie de referencia establece contacto con la superficie de soporte, marcando el inicio de la fase de apoyo y, por convención, el inicio del ciclo de marcha. En términos mecánicos, el HS representa la transición de la fase de balanceo a la fase de apoyo, momento en el que el miembro inferior pasa de recibir impulso muscular a soportar la transferencia progresiva del peso corporal.

Desde el punto de vista cinemático, el HS se caracteriza por el pico de extensión de rodilla combinado con la flexión máxima de cadera al final del balanceo (O'Connor et al., 2007). Adicional, el HS corresponde a la transición de la señal plantar del estado inactivo (sin presión) al estado activo (presión detectada).

El Toe – Off también denominado *contacto terminal*, es el instante en que el gordo del pie se despegue de la superficie de soporte, marcando el fin de la fase de apoyo e inicio de la fase de balanceo. Mecánicamente, el TO precede a la aceleración activa del miembro en el plano sagital para la fase de oscilación.

Cinemáticamente, el TO se detecta mediante el pico máximo de la velocidad angular de rodilla durante la transición al balanceo, validado por la aceleración positiva de la cadera (O'Connor et al., 2007).

3.3.4.2 Métodos de detección de Eventos de Marcha. La detección precisa y automática del HS y el TO es un problema en el análisis de la marcha con sistemas de captura de movimiento. Históricamente, las plataformas de fuerza han sido el patrón de referencia para la identificación de estos eventos, pues la transición entre fuerza de reacción del suelo nula y no nula distingue con alta precisión temporal el inicio y el fin del contacto plantar. Sin embargo, las plataformas de fuerzas imponen restricciones importantes al número de pasos analizables y por supuesto requieren laboratorios de alto costo (O'Connor et al., 2007).

Ante estas limitaciones, se han desarrollado múltiples métodos alternativos de detección basados en datos cinemáticos, señales inerciales y sensores de presión plantar. Taborri et al. (2016), en su revisión sistemática sobre métodos de partición del ciclo de marcha, identificaron y categorizaron alrededor de 80 algoritmos publicados entre 2000 y 2015, clasificados según el tipo de sensor y la colocación corporal. Los tres enfoques más relevantes para los sistemas de captura inercial son:

a) Detección cinemática por velocidad de marcadores: Zeni et al. (2008) propusieron dos algoritmos que determinan los instantes de HS y TO exclusivamente a partir de datos cinemáticos, sin necesidad de información de fuerza. El método basado en *coordenadas* identifica el HS como el instante de mínima posición anteroposterior del marcador del talón relativa al centro de masa, y el TO como el instante de mínima posición anteroposterior del marcador del dedo. Este método fue validado en sujetos sanos, con esclerosis múltiple y con secuelas de ACV, obteniendo errores de sincronización menores a 20 ms respecto a la plataforma de fuerza.

b) Detección por velocidad angular de la pierna (giroscopio): Métodos basados en la velocidad angular de la tibia o el pie han demostrado alta precisión para detectar HS y TO en sistemas con IMU. El HS se asocia al pico de desaceleración angular al final del balanceo y el TO

al mínimo de velocidad angular durante el apoyo final (Taborri et al., 2016). Este enfoque es robusto frente a variaciones de velocidad de marcha.

c) Detección por transiciones de señales de contacto plantar: Cuando el sistema de captura incluye sensores de presión plantar o señales de contacto binarias de alta resolución temporales, la detección de eventos puede realizarse directamente a partir de las transiciones entre los estados de contacto y no contacto (Zeni et al., 2008).

3.3.4.3 Relación entre Segmentación y exactitud de los Biomarcadores Espaciotemporales. La segmentación del ciclo de marcha es una etapa crítica de la cadena de procesamiento, dado que los errores de segmentación se propagan y amplifican hacia todos los biomarcadores calculados a partir de los eventos de marcha, como se presenta en la Tabla 3. Esta dependencia es marcada para los parámetros temporales, cuya precisión está directamente limitada por la precisión temporal de la detección de eventos (Trojaniello et al., 2014).

Tabla 3

Dependencia de biomarcadores espaciotemporales respecto a la segmentación

Biomarcador	Eventos Requeridos	Efecto de error de segmentación
Tiempo de zancada	HS(i) y HS(i+1)	Error directo en Tiempo de Zancada propagándose a % Stance y %Swing.
Tiempo de apoyo	HS(i) y TO(i)	Un TO mal detectado infla o deflata Tiempo de Apoyo, alterando %doble apoyo.
Longitud de zancada	Posición del talón en HS (i) y HS (i+1)	Ciclos con HS erróneos producen longitudes negativas
Longitud de paso	HS_R y HS_L en el ciclo	Afecta el componente mediolateral, también produce longitudes negativas.
Ancho de paso	HS_R y HS_L en el ciclo	Igual que la longitud de paso, puede afectar el componente mediolateral.
Cadencia	Nº de HS totales / Tiempo ciclo total	HS falsos o pérdidas distorsionan la cuenta, conlleva a cadencia ficticia.
Velocidad de zancad	Longitud Zancada y Tiempo Zancada	Errores en ambos parámetros se acumulan.

Nota. Adaptado de Trojaniello et al. (2014) y Taborri et al. (2016).

Trojaniello et al. (2014), en su estudio de validación de cinco métodos de estimación de parámetros temporales con IMU en pacientes geriátricos, demostraron que los errores en la detección de eventos se traducen en errores sistemáticos en los parámetros de tiempo de apoyo, tiempo de balanceo y tiempo de doble apoyo, con la particularidad de que el tiempo de doble apoyo

es el parámetro más sensible a los errores de detección, acumulando en algunos métodos errores superiores al 20 % del valor real.

3.3.4.4 Normalización Temporal del Ciclo de Marcha. Los ciclos de marcha segmentados entre pares de HS consecutivos tienen duraciones variables en número de muestras, pues la cadencia y la velocidad del sujeto fluctúan entre ciclos. Para poder comparar formas de onda entre sujetos, entre sesiones o entre condiciones, es necesario transformar cada ciclo a una escala de tiempo normalizada y común. La convención estándar en análisis de marcha clínica consiste en representar cada ciclo como el intervalo 0–100 %, donde 0 % corresponde al HS inicial y 100 % al HS final (Davis et al., 1991).

3.3.5 Cinemática de la marcha

La cinemática analiza y estudia el movimiento de la marcha humana, como las variaciones angulares y movimientos relativos. En ella se han encontrado diferentes parámetros característicos para analizar los tipos patrones.

Los parámetros espaciotemporales constituyen indicadores cuantitativos del comportamiento del sistema locomotor y son reconocidos como biomarcadores sensibles del envejecimiento. Estudios longitudinales documentan que el proceso de envejecimiento produce reducciones significativas en la velocidad de marcha, la longitud de zancada y la cadencia, acompañadas de un incremento en el tiempo de doble apoyo como estrategia adaptativa de estabilidad (Murray et al., 1969); (White, 2007). En el contexto del presente proyecto, estos parámetros son extraídos a partir de las trayectorias tridimensionales registradas por el sistema de captura de movimiento inercial Noraxon MyoMotion, empleando las ecuaciones matemáticas que se desarrollan en las secciones siguientes.

Los parámetros temporales y espaciales de este proyecto están referenciados bajo el libro de Lesmes, J., (2007) que se resumen en la Tabla 4.

Tabla 4


Resumen de variables espaciotemporales calculadas con sus respectivas unidades y ecuaciones

Variable	Unidad	Descripción
Stride Length D / I	cm	Distancia euclidiana entre HS consecutivos del mismo pie
Step Length D / I	cm	Proyección longitudinal del vector entre talones sobre D
Step Width D / I	cm	Componente medio lateral del vector entre talones
Stride Time D / I	s	Duración del ciclo completo
Step Time D / I	s	Duración del semiciclo
Stance Time D / I	s	Tiempo de contacto del pie con el suelo
Swing Time D / I	s	Tiempo de vuelo del pie
Double Support Time	s	Tiempo de apoyo bilateral simultaneo
Single Support Time	s	Tiempo de apoyo unipodal
% Stance D / I	%	Fracción del ciclo en fase de apoyo
% Swing D / I	%	Fracción del ciclo en fase de vuelo
% Double Support	%	Fracción del ciclo en doble apoyo
% Single Support	%	Fracción del ciclo en apoyo simple
Stride Speed D / I	m/s	Velocidad de avance por zancada
Cadencia	pasos/min	Numero de pasos por minuto
Distancia total	m	Integración de trayectoria de la pelvis
Velocidad promedio	m/s	Velocidad media de la caminata

3.3.5.1 Parámetros temporales de la marcha. La Figura 10 representa los parámetros temporales que detallan la distribución del tiempo dentro del ciclo locomotor. Son los más sensibles al envejecimiento en poblaciones funcionalmente sanas (Hollman et al., 2011) y los más discriminantes para modelos de clasificación (Boyer et al., 2017).

Figura 10

Representación gráfica de los parámetros temporales de la marcha



a) Tiempo de zancada: es el intervalo temporal entre dos eventos de contacto inicial consecutivos del mismo pie.

$$T_{zanc} = t_{HS(i+1)} - t_{HS(i)}(6)$$

Donde:

Símbolo	Variable	Descripción	Unidad
T_{zanc}	Tiempo de zancada	Duración de un ciclo de marcha completo	s
$t_{HS(i+1)}$	Tiempo HS siguiente	Instante del (i+1)-ésimo heel strike ipsilateral	s
$t_{HS(i)}$	Tiempo HS actual	Instante del i-ésimo heel strike ipsilateral	s

b) Tiempo de Paso: es el intervalo entre el contacto inicial de un pie y el contacto inicial de pie contralateral. Dos tiempos de paso (derecho + Izquierdo) componen un tiempo de zancada (Whittle, 2007).

$$T_{paso} = t_{HS,contra} - t_{HS,ipsi} (7)$$

Donde:

Símbolo	Variable	Descripción	Unidad
T_paso	Tiempo de paso	Intervalo entre HS de pies alternos	s
t_HS,contra	Tiempo HS contralateral	Instante del HS del pie contralateral	s
t_HS,ipsi	Tiempo HS ipsilateral	Instante del HS del pie de referencia	s

c) Tiempo de apoyo: fase de apoyo que comprende el periodo en que el pie permanece en contacto con la superficie de soporte, desde el contacto inicial del talón hacia el despegue del pie (toe-off).

$$T_{apoyo} = t_{TO} - t_{HS} (8a)$$

$$\% T_{apoyo} = \left(\frac{T_{apoyo}}{T_{zanc}} \right) \times 100 (8b)$$

Donde

Símbolo	Variable	Descripción	Unidad
T_apoyo	Tiempo de apoyo	Duración de la fase de apoyo del pie	s
%T_apoyo	% de apoyo	Fracción del ciclo en fase de apoyo	%
t_TO	Instante de toe-off	Momento de despegue completo del pie del suelo	s
t_HS	Instante de heel strike	Momento de contacto inicial del talón	s
T_zanc	Tiempo de zancada	Duración del ciclo completo	s

d) Tiempo de balanceo: fase de balanceo u oscilación corresponde al periodo en que el pie se desplaza libremente sin contacto con el suelo, desde el toe-off hasta el siguiente heel strike del mismo pie. Es el complemento temporal del apoyo respect al ciclo (Whittle, 2007).

$$T_{swing} = T_{zanc} - T_{apoyo} (9a)$$

$$\% T_{swing} = \left(\frac{T_{swing}}{T_{zanc}} \right) \times 100 \quad (9b)$$

Donde:

Símbolo	Variable	Descripción	Unidad
T_swing	Tiempo de balanceo	Duración de la fase de oscilación del pie	s
%T_swing	% de balanceo	Fracción del ciclo en fase de oscilación	%
T_zanc	Tiempo de zancada	Duración del ciclo completo	s
T_apoyo	Tiempo de apoyo	Duración de la fase de apoyo	s

e) Tiempo de doble y simple apoyo: Inicialmente, doble apoyo, es el periodo en que ambos pies se encuentran simultáneamente en contacto con el suelo. Ocurre dos veces por ciclo: durante el cambio de carga del peso al inicio de la fase de apoyo y durante el pre-swing al final. En la implementación sobre datos Noraxon, el doble apoyo se detecta como los instantes en que la señal binaria de contacto (Contact RT + Contact LT) alcanza el valor codificado de doble contacto. El tiempo de doble apoyo y el tiempo de apoyo simple se calculan como:

$$T_{doble} = \frac{n_{doble}}{f_s} \quad (10a)$$

$$T_{simple} = T_{ciclo} - T_{doble} \quad (10b)$$

$$\% T_{doble} = \left(\frac{T_{doble}}{T_{ciclo}} \right) * 100 \quad (10c)$$

$$\% T_{simple} = \left(\frac{T_{simple}}{T_{ciclo}} \right) * 100 \quad (10d)$$

Donde:

Símbolo	Variable	Descripción	Unidad
T_doble	Tiempo de doble apoyo	Duración del período de contacto bilateral simultáneo	s
T_simple	Tiempo de apoyo simple	Duración del período de contacto unilateral	s
n_doble	Muestras doble apoyo	Número de muestras con ambos pies en contacto	muestras
f_s	Frecuencia de muestreo	Tasa de adquisición del sistema Noraxon MyoMotion®	Hz
T_ciclo	Tiempo de ciclo	Duración del ciclo de marcha.	s

f) Cadencia: expresa la frecuencia de paso, definida como el número de pasos realizados por unidad de tiempo (Neumann, 2010). Dado que cada evento de contacto inicial del talón (tanto derecho como Izquierdo) constituyen un paso. La cadencia puede calcularse a partir del conteo total de eventos HS en la duración de la prueba:

$$Cadencia = \frac{(N_{HS,D} + N_{HS,I})}{T_{total}} * 60 \quad (11)$$

Donde:

Símbolo	Variable	Descripción	Unidad
C	Cadencia	Número de pasos por minuto	pasos/min
N _{HS,D}	Heel strikes derechos	Total de eventos de contacto inicial del pie derecho	eventos
N _{HS,I}	Heel strikes izquierdos	Total de eventos de contacto inicial del pie izquierdo	eventos
T _{total}	Tiempo total de prueba	Duración de la sesión de marcha analizada	s
× 60	Factor de conversión	Conversión de pasos/s a pasos/min	—

g) Velocidad promedio: Extraído a partir de la trayectoria pélvica y se estima a partir de la trayectoria de la pelvis, cuyo centro de masa es una aproximación al centro de masa corporal total (Tesio et al., 1998). La distancia total recorrida se obtiene integrando la trayectoria discreta del marcador pélvico:

$$D_{total} = \sum \sqrt{\frac{(\Delta x_{pelvis(k)})^2 + (\Delta y_{pelvis(k)})^2}{1000}}$$

$$V_{prom} = \frac{D_{total}}{T_{total}}$$

Donde:

Símbolo	Variable	Descripción	Unidad
D _{total}	Distancia total	Longitud acumulada de la trayectoria pélvica	m
Δx _{pelvis(k)}	Incremento AP pelvis	Diferencia en coordenada x entre muestras k y k-1	mm
Δy _{pelvis(k)}	Incremento ML pelvis	Diferencia en coordenada y entre muestras k y k-1	mm
/ 1000	Factor de conversión	Conversión de mm a metros	—
V _{prom}	Velocidad media	Velocidad promedio de desplazamiento corporal	m/s

T _{total}	Tiempo total de prueba	Duración de la sesión de marcha	s
--------------------	------------------------	---------------------------------	---

h) Velocidad de Zancada (Stride Speed): La velocidad de zancada es la relación entre la longitud de una zancada individual y su tiempo de duración, expresada en metros por segundo (Rampp et al., 2015).

$$V_{zanc} = \frac{\left(\frac{L_{zanc} [cm]}{T_{zanc} [s]} \right)}{100}$$


Donde:

Símbolo	Variable	Descripción	Unidad
V _{zanc}	Velocidad de zancada	Velocidad media durante una zancada individual	m/s
L _{zanc}	Longitud de zancada	Extensión espacial de la zancada (Ec. 2)	cm
T _{zanc}	Tiempo de zancada	Duración de la zancada (Ec. 6)	s
/ 100	Conversión	cm/s → m/s	—

3.3.5.2 Parámetros espaciales de la marcha

Figura 11

Representación gráfica de los parámetros espaciales de la marcha



a) Longitud de zancada: se define como la distancia lineal recorrida por un pie entre dos eventos de contacto inicial consecutivos del mismo pie, es decir, la extensión espacial de un ciclo de marcha completo (Perry & Burnfield, 2010). A diferencia del paso, que involucra dos pies alternos, la zancada representa el contacto de un Heel Strike hasta el siguiente Heel Strike del mismo pie.

Debido a que, la trayectoria del talón no es totalmente rectilínea, la longitud de zancada se puede obtener mediante la norma euclídea del vector de desplazamiento del talón entre los dos eventos de contacto (Trojaniello et al., 2014):

$$L_{zanc} = \|\mathbf{v}\| = \frac{\sqrt{[(x_{HS(i+1)} - x_{HS(i)})^2 + (y_{HS(i+1)} - y_{HS(i)})^2]}}{10}$$

Donde:

Símbolo	Descripción	Unidad
L_zanc	Distancia entre contactos ipsilaterales sucesivos	cm
$\ \mathbf{v}\ $	Magnitud del vector de desplazamiento del talón	mm a cm
x_HS(i+1)	Posición anteroposterior del talón en el siguiente HS	mm
x_HS(i)	Posición anteroposterior del talón en el HS actual	mm
y_HS(i+1)	Posición mediolateral del talón en el siguiente HS	mm
y_HS(i)	Posición mediolateral del talón en el HS actual	mm

La distancia entre dos puntos consecutivos de trayectoria se calcula mediante la norma euclídea bidimensional en el plano horizontal, es decir, plano x-y anteroposterior/medio lateral, que constituye el plano de progresión de la marcha (Winter, 2009).

$$D = \frac{\sqrt{[(x_2 - x_1)^2 + (y_2 - y_1)^2]}}{10}$$

Donde:

Símbolo	Variable	Descripción	Unidad
D	Distancia entre puntos	Distancia euclídea entre dos posiciones en el plano horizontal	cm
x_1, y_1	Coordenadas punto inicial	Posición (mm) del marcador en el instante t_1	mm
x_2, y_2	Coordenadas punto final	Posición (mm) del marcador en el instante t_2	mm
/ 10	Factor de conversión	Conversión de milímetros a centímetros	—

Este vector garantiza que los cálculos de Step Length y Step Width sean independientes de la orientación del sujeto en el laboratorio, siendo válidos para trayectorias no rectilíneas.

b) Longitud de paso: cuantifica la distancia longitudinal entre el talón de referencia y el talón contralateral en el instante del Heel Strike intermedio. Se obtiene mediante la proyección escalar del vector entre talones sobre el vector unitario de dirección:

$$v_{contra} = r_{contralateral}(HS_L) - r_{referencia}(HS_i)$$

$$L_{paso} = \frac{(v_{contra} \cdot D)}{10} [cm]$$

El operador $(\cdot)$ denota el producto punto (proyección escalar). v_{contra} es el vector desde el talón de referencia hasta el talón contralateral en el instante del Heel Strike intermedio. Para el paso izquierdo, el talón de referencia es el derecho; para el paso derecho, el talón de referencia es el izquierdo.

Símbolo	Variable	Descripción	Unidad
L_{paso}	Longitud de paso	Componente AP del desplazamiento entre HS alternos	cm
v_L	Vector al contralateral	Vector del talón ipsilateral al contralateral en el HS contralateral	mm
D	Vector director	Vector unitario en dirección de avance (Ec. 3b)	adim.
$v_L \cdot D$	Producto punto	Proyección escalar de v_L sobre la dirección de progresión	mm
/ 10	Conversión	mm hacia cm	—

c) Ancho de paso: Se define como la distancia existente entre dos puntos iguales, pueden ser los talones. Muchas personas con patologías neurológicas suelen evidenciarlo en esta distancia incrementándose para mejorar su estabilidad. Representa la separación medio lateral entre los pies durante el paso. Se obtiene mediante la descomposición vectorial: se resta la componente longitudinal (longitud de paso) al vector entre talones, conservando únicamente la componente perpendicular a la dirección de avance:

$$v_{lateral} = v_{contra} - (v_{contra} \cdot D) \times D$$

$$A_{paso} = \frac{|v_{lateral}|}{10} \quad [cm]$$

Donde:

Símbolo	Variable	Descripción	Unidad
A _{paso}	Ancho de paso	Distancia mediolateral entre puntos de contacto alternos	cm
v _{lat}	Vector lateral	Componente perpendicular a la dirección de progresión	mm
v _L	Vector contralateral	Vector al pie contralateral (Ec. 4a)	mm
D	Vector director	Dirección unitaria de avance (Ec. 3b)	adim.
v _{lat}	Norma del vec. lat.	Magnitud de la componente mediolateral	mm


d) Ángulos de paso: Se refiere a la orientación del pie durante la marcha. El pie suele formar un ángulo con un eje longitudinal. En marchas normales este ángulo suele estar entre 5 y 6 grados. Existen marchas donde la extremidad inferior puede aumentar o disminuir este ángulo y está relacionado con deficiencias de origen pélvico, femoral o tibial.

3.3.6 Cinética de la marcha

3.3.6.1 Fuerza de reacción del suelo. Se define como Ground reaction force, ésta describe el comportamiento de la fuerza que se genera al momento en que la extremidad inferior hace contacto inicial, esta fuerza se da exactamente en la fase de apoyo de la marcha. El vector de la fuerza puede cambiar a medida que avanza la fase como se puede observar en la Figura 12 (Webster, J. & Darter, B., 2010).

Figura 12

Vector de la fuerza de reacción del suelo según el apoyo de la extremidad




Fuente. Principles of Normal and Pathologic Gait. (Webster & Darter, 2010)

En el análisis de la marcha, las articulaciones que también actúan sobre esta son la cadera, el tobillo y la rodilla. La reacción del suelo ejerce sobre estos una fuerza debido a la tercera ley de Newton, Kataoka, N. et al. (2017) dentro de estudios encuentran cómo se comporta esta fuerza a medida el porcentaje del ciclo de marcha en el eje vertical, como se muestra en la Figura 13.

Figura 13

Variación de la fuerza de reacción del suelo con relación al ciclo de marcha en fase de apoyo





Nota: Perfil de la fuerza de reacción vertical del suelo (V-GRF), expresada como porcentaje del peso corporal, durante un ciclo de marcha para tres condiciones: sin soporte de peso corporal (non-BWS), soporte mediante arnés (Harness-type BWS) y soporte mediante asiento tipo silla de montar (Saddle-seat-type BWS) Kataoka, N. et al. (2017)


3.3.6.2 Torque articular. El torque articular se comprende como una fuerza interna causada por las energías que actúan sobre la articulación, influye en la acción muscular y las restricciones óseas, adicional de las fuerzas de fricción y de contacto, la distancia que genera el torque es entre la fuerza y la distancia del eje articular (Lesmes, J., 2007). Las fuerzas internas son generadas por el impacto de la fuerza externa (Fuerza de reacción del suelo).


A continuación, por medio de las siguientes Tablas 5a, 5b, 5c, 5d y 5e se especificará el comportamiento del torque de las tres articulaciones involucradas en el ciclo de la marcha:


Tabla 5

Comportamiento torque de cada articulación en el contacto inicial. b) en la respuesta a la carga. c) en el soporte medio. d) en el soporte terminal. e) en pre-balanceo en el plano sagital

Análisis de marcha normal: contacto inicial				
	Articulación y posición articular al final de la fase	Torque generado	Acción Muscular	Tipo de contracción
	Tobillo Neutro 0°	Plantiflexor	Dorsiflexores: extensión común de los dedos.	Contracción excéntrica, esto con la finalidad de mantener el equilibrio del tobillo. Músculos dorsiflexores impulsan la tibia hacia delante.
	Rodilla Neutro 0°	Extensor	Cuádriceps e isquiotibiales	Los cuádriceps tienen una contracción concéntrica y los isquiotibiales una contracción excéntrica, esto permite tener la rodilla inmovilizada.
	Cadera Flexión 30°	Flexor	Glúteo mayor e isquiotibiales	Excéntrica para restringir el torque flexor.
Análisis de marcha normal: respuesta a la carga				
	Articulación y posición articular al final de la fase	Torque generado	Acción Muscular	Tipo de contracción
	Tobillo Flexión 10° a 15°	Plantiflexor	Dorsiflexores: extensión común de los dedos.	Contracción excéntrica, esto con la finalidad de mantener el equilibrio del tobillo. Músculos dorsiflexores impulsan la tibia hacia delante.
	Rodilla Flexión 15° a 20°	Flexión	Cuádriceps	Excéntrica, previene el colapso de la rodilla, sin embargo, la flexión amortigua el impacto y sirve como mecanismo de control del centro de masa.
	Cadera Flexión 30°	Flexor	Glúteo mayor e isquiotibiales	Excéntrica para promover el movimiento de la extremidad y amortiguar el impacto de la carga.

Análisis de marcha normal: soporte medio				
	Articulación y posición articular al final de la fase	Torque generado	Acción Muscular	Tipo de contracción
	Tobillo Dorsiflexión 5° a 8°	Dorsiflexión	Plantiflexores: gemelos	Tipo de contracción excéntrica, con el objetivo de controlar el torque previniendo el colapso de la extremidad apoyada.
	Rodilla Flexión 5°	Extensor	Cuádriceps al inicio y disminuye su acción al final de la fase	Excéntrica al inicio pero disminuye según el pie contralateral se separe del suelo, generando un fuerte momento extensor de la rodilla en el pie de soporte.
	Cadera Flexión 10°	Extensor	Extensores, al final no hay posición muscular	Glúteo mayor activo como abductor de cadera.

Análisis de marcha normal: soporte terminal				
	Articulación y posición articular al final de la fase	Torque generado	Acción Muscular	Tipo de contracción
	Tobillo Dorsiflexión 10° a 12°	Dorsiflexión	Plantiflexores: gemelos	Concéntrica, esto controla el avance de la tibia hacia adelante para elevar el talón.
	Rodilla Neutro 0°	Extensor	No hay actividad muscular	Estabilidad de la articulación se da de forma pasiva.
	Cadera Extensión 10° (5° Extensión de cadera y 5° rotación pélvica)	Extensor	Flexores de cadera	Excéntrica para controlar el torque extensor

Análisis de marcha normal: prebalanceo				
	Articulación y posición articular al final de la fase	Torque generado	Acción Muscular	Tipo de contracción
	Tobillo Plantiflexión 20°	Dorsiflexión	Plantiflexores: gemelos	Al comienzo concéntrico, pero la actividad muscular disminuye hasta llegar a cero, cuando los dedos pierden el contacto con el piso.
	Rodilla Flexión 30° a 40°	Flexor	Cuádriceps	Inicialmente, flexión de rodilla controlada por acción excéntrica del cuádricep, luego es control pasivo debido a que el peso es transferido a los dedos ipsilaterales y a la extremidad contralateral.
	Cadera Neutro 0°	Flexor	Flexor de cadera	Concéntrica, la actividad muscular de los flexores se favorece gracias al torque flexor generado.

Nota. Adaptado de Daza, J., Nárvaez, M.,

3.3.7 Clasificación de marcha patológica.

a) Según problemas neurológicos: Los problemas de la marcha pueden estar relacionados con patologías neurológicas, se estima que alrededor del 60% de los pacientes presentan esta dificultad (Cerda, L., 2010).

b) Marcha en tijeras: Los dorsiflexores del tobillo están débiles y los pies no suelen despegarse del suelo. Pasos cortos y mucho esfuerzo, en esta patología los pies se cruzan al caminar. Causas: espondilosis cervical (degradación de los huesos en los discos del cuello).

c) Marcha parkinsoniana: Es la marcha de la enfermedad de Parkinson, se trata de pasos cortos, lentos y sin despegar los pies del suelo. La persona mantiene la flexión de caderas, rodillas y codos, inclinación de tronco hacia adelante y ausencia de movimientos de los brazos (Pirker, W. & Katzenschlager, R., 2016).

d) **Marcha atáxica:** Pisadas fuertes y con un ancho grande. Las personas suelen perder el sentido de la posición, por lo que no saben dónde tienen sus pies. Adicional, los talones tocan primero el suelo y tienen problemas de equilibrio. (Pirker, W. & Katzenschlager, R., 2016).

d) **Problemas musculoesqueléticos:** La artrosis y deformaciones esqueléticas de las extremidades inferiores son las causas más frecuentes de trastornos de la marcha. El 40% de los pacientes presentan trastornos de la marcha debido a problemas musculoesqueléticos (Cerdeira, L., 2010).

- **Marcha pingüino:** Inclínación del tronco por fuera del pie, elevándose por debilidad en el glúteo medio y la no posibilidad para estabilizar el peso de la cadera. Estas personas tienen problemas para subir escaleras y levantarse de sitios bajos.
- **Marcha antiálgica:** El pie se mantiene plano en el suelo con poco despegue del suelo para evitar la transmisión de las fuerzas a través de la cadera y agravación del dolor. En este caso, la longitud del paso es más corta en el lado bueno y existe disminución de la velocidad de la marcha. Esta marcha puede ser provocada por los juanetes, callosidades, uñas deformes (Pirker, W. & Katzenschlager, R., 2016).

3.3.8 Tecnologías usadas para captura de movimiento en laboratorios de marcha.

3.3.8.1 Non Wearable Sensors

- **Sensores Ópticos:** Estos son usualmente usados en laboratorios y capturan datos de la marcha a través de cámaras analógicas o digitales, toman medidas de los diferentes parámetros por medio del procesamiento de imágenes. Otros tipos suelen ser los escáneres de alcance láser, los sensores infrarrojos (Muro-De-La-Herrán, A. et al., 2014).

- **Plataformas de fuerza:** Se usan sensores de presión y sensores de fuerza de reacción del suelo que miden la fuerza ejercida por los pies del sujeto sobre el suelo cuando camina para luego procesar los datos y adquirir las fuerzas internas por medio de dinámica inversa.

3.3.8.2 Wearable Sensors

- **Acelerómetros:** Dispositivos usados en el cuerpo de las personas, captan la aceleración por medio de un cambio en el voltaje durante el ciclo de marcha y bajo ciertos cálculos matemáticas posterior encontrar los parámetros espaciotemporales. Se caracteriza por ser uno de los dispositivos de medición más usado en este campo debido a su portabilidad, sin embargo, existen unas limitaciones dadas por el ruido, ya que, al momento de encontrar la velocidad y aplicar integradores se acumula error provocando que los resultados no sean tan precisos. Estos acelerómetros suelen tener dos componentes: el componente de la aceleración interna, es decir, analiza los cambios de velocidad y en el otro analiza la fuerza de la aceleración gravitacional en el centro de gravedad de la persona (Jarchi et al., 2018).
- **Sensores giroscópicos:** Después de los acelerómetros, de los dispositivos más usados viene siendo este ya que analiza los movimientos rotacionales del cuerpo brindando con mayor exactitud que los acelerómetros, en la velocidad angular del pie y detecta distintas fases de la marcha. Estos suelen incorporarse en los pies. La particularidad de estos sensores a diferencia de los acelerómetros que detectan aceleraciones centrífugas es que se enfocan en la aceleración de Coriolis, la cual indica el movimiento en el eje un radio rotacional.
- **Electromiografía:** Una de las técnicas más utilizadas para estudiar cómo funcionan los músculos al caminar es la electromiografía dinámica. Esta prueba usa electrodos en la piel para registrar la actividad eléctrica de los músculos en las diferentes fases de la marcha.

Gracias a esto, se han identificado patrones que muestran cuándo se activan y desactivan los músculos durante un paso completo. Con esta información, junto a datos biomecánicos, se han creado modelos que simulan cómo trabajan los músculos y las articulaciones, ayudando a entender mejor el movimiento. Estos modelos permiten identificar qué músculos son los más importantes para caminar, estimar la fuerza que generan y calcular los momentos articulares.

3.3.9 Inteligencia Artificial

La inteligencia artificial (IA) es una rama de la ciencia que busca desarrollar sistemas capaces de realizar tareas de manera eficiente, analizando grandes volúmenes de datos, reconociendo patrones y haciendo predicciones automáticas con rapidez (IBV, 2021). Esta evolución en la inteligencia de datos dió lugar a nuevos modelos, donde cada uno se usa para diferentes técnicas, varios de estos son los que se explicarán a continuación (Sarker, I., 2022):

3.3.9.1 Machine Learning. Este subconjunto de la inteligencia artificial tiene como objetivo analizar datos y modificar patrones en caso su comportamiento, a diferencia del Deep Learning este requiere mayor supervisión para el correcto funcionamiento, usa algoritmos como regresión lineal o árboles de decisión. El aprendizaje automático es una rama que estudia aquellos algoritmos capaces de mejorar su desempeño de manera automática a partir de la experiencia.

a) Machine Learning supervisado: Dentro de esta situación, el aprendizaje supervisado es la modalidad en que el algoritmo aprende a partir de pares de datos entrada-salida previamente etiquetados. La clasificación supervisada es la tarea específica de asignar una instancia de entrada a una de varias categorías discretas predefinidas.

b) Modelos Candidatos: La selección de algoritmos para la clasificación de patrones de marcha se basa en estudios que comparan su desempeño sobre datos cinemáticos y espaciotemporales de poblaciones etarias:

- Máquina de Vectores de Soporte: La SVM es una máquina de aprendizaje para problemas de clasificación de dos grupos; implementa la siguiente idea: los vectores de entrada se mapean no linealmente a un espacio de características de alta dimensión, en el que se construye una superficie de decisión lineal de máximo margen entre clases. En clasificación de grupos etarios a partir de aceleraciones tridimensionales del tronco de 239 sujetos, la SVM con reducción dimensional mediante KPCA alcanzó una exactitud de clasificación del 89%.
- Bosque Aleatorio (Random Forest, RF): Los bosques aleatorios son una combinación de predictores de árbol en la que cada árbol depende de los valores de un vector aleatorio muestreado de forma independiente con la misma distribución para todos los árboles del bosque. Random Forest, puede trabajar con conjuntos de datos de tamaño reducido, categoriza los sujetos mediante múltiples árboles de decisión en paralelo y, a diferencia de SVM y ANN, permite identificar directamente las características más relevantes para la clasificación.
- K-Vecinos más cercanos: El método KNN identificó patrones de marcha diferenciados en pacientes con parálisis cerebral y esclerosis múltiple frente a adultos sanos con una exactitud del 85 %, y en pacientes con hemiplejía, enfermedad de Parkinson y dolor de espalda con exactitudes del 90–98 %; no obstante, una limitación del KNN es que es un método de aprendizaje basado en instancias, lo que implica que solo utiliza los datos de entrenamiento para la clasificación sin aprender de ellos de manera generalizable.

- **Árbol de Decisión:** Estructura jerárquica de reglas que divide recursivamente el espacio de características. Métodos de árbol de decisión y Naive Bayes han obtenido resultados de clasificación similares a KNN en tareas de discriminación de poblaciones por patrones de marcha.

c) **Métricas de evaluación:** El desempeño de un clasificador binario se analiza a través de la matriz de confusión, que contabiliza cuatro resultados: Verdaderos Positivos, Verdaderos Negativos, Falsos Positivos y Falsos Negativos. Las métricas estándar derivadas son:

- **Exactitud (Accuracy):** proporción de predicciones correctas sobre el total de instancias.

$$Exactitud = \frac{(VP + VN)}{(VP + VN + FP + FN)}$$

- **Precisión (Precision):** fracción de instancias clasificadas como positivas que son realmente positivas. Elimina los falsos positivos.

$$Precisión = \frac{VP}{VP + FP}$$

- **Sensibilidad / Recall:** fracción de instancias realmente positivas que el modelo identifica correctamente. Elimina falsos negativos.

$$Sensibilidad = \frac{VP}{VP + FN}$$

- **Puntuación F1 (F1-Score):** media armónica entre precisión y recall. Equilibra ambas métricas en un solo valor.

$$F1 = 2 \times \frac{(Sensibilidad \times Precisión)}{Precisión + Sensibilidad}$$

$$F1 = \frac{2VP}{(2VP + FP + FN)}$$

- Área bajo la curva ROC (AUC): mide la capacidad del modelo para discriminar entre clases a través de todos los umbrales de decisión posibles. Un valor de 1.0 indica discriminación perfecta; 0.5 equivale a clasificación aleatoria.

$$AUC = \int_0^1 TPR(t) \cdot d[FPR(t)]$$

Donde $TPR(t)$ es la tasa de verdaderos positivos y $FPR(t)$ es la tasa de falsos positivos para un umbral de decisión t . Un valor AUC igual a 1.0 puede indicar discriminación perfecta; AUC igual a 0.5 equivale a clasificación aleatoria. El AUC-ROC es particularmente adecuado para comparar clasificadores independientes del umbral de decisión fijado, lo que lo convierte en la métrica preferida en estudios biomédicos.

Es necesario aclarar que, las métricas de evaluación presentan sesgos intrínsecos y no deben usarse sin una comprensión clara de dichos sesgos y de los niveles de referencia correspondientes al azar. (Powers, D., 2011)

d) Interpretabilidad y Generalización: Dos criterios fundamentales deben guiar la selección y validación del modelo en este proyecto:

- Generalización: capacidad del modelo de producir predicciones correctas sobre datos no vistos durante el entrenamiento. El error de generalización puede descomponerse en dos fuentes: sesgos, que refleja la incapacidad del modelo de capturar patrones estadísticos complejos asociados a las etiquetas reales, y varianza, que es el error adicional producido cuando el modelo interpreta picos aleatorios del conjunto de entrenamiento como señal predictiva robusta. Este equilibrio se conoce como el dilema sesgo-varianza, genera que el modelo sea suficientemente complejo para aprender los patrones de envejecimiento en la marcha, pero no tanto como para memorizar el ruido

de los datos de entrenamiento. La validación cruzada puede ser una estrategia para garantizar el rendimiento de la generalización, dividiendo el conjunto de datos en múltiples subconjuntos para entrenar y evaluar el modelo en distintas combinaciones.

Interpretabilidad: Se refiere a la capacidad de explicar por qué el modelo toma una decisión determinada. En aplicaciones biomédicas y clínicas, constituye un requisito fundamental para respaldar la confianza y la adopción de estos sistemas. Por ello, se utilizan métodos como LIME (Local Interpretable Model-agnostic Explanations), con el propósito de identificar las variables con mayor contribución a las predicciones de cada condición evaluada. Aunque modelos como la regresión logística y los árboles de decisión presentan interpretabilidad intrínseca, algoritmos como Support Vector Machine (SVM) y Random Forest (RF) requieren técnicas de interpretabilidad post hoc para explicar sus predicciones (Bulgarelli et al., 2023).

3.3.9.2 Modelos de Validación. Es el conjunto de técnicas estadísticas estándar para estimar el error de generalización cuando el tamaño del conjunto de datos es limitado. El principio común consiste en dividir los datos de forma sistemática en subconjuntos de entrenamiento y prueba, entrenar el modelo en el subconjunto de entrenamiento, evaluarlo en el de prueba, y repetir el proceso en distintas divisiones para obtener una estimación robusta (Kohavi, 1995).

a) División Simple Hold – Out: es una técnica básica de validación que divide el conjunto de datos en dos particiones: un subconjunto de entrenamiento (típicamente del 70% - 80% de los datos) y subconjunto de prueba (suele ser el 20% - 30% faltante), reservado exclusivamente para la evaluación final. La división se realiza una sola vez de forma aleatoria. El estimador del error de generalización es simplemente el error cometido sobre el subconjunto de prueba (Hastie et al.,

2009). Sin embargo, existen limitaciones, el rendimiento estimado presenta alta varianza cuando el conjunto es pequeño, pues depende de la partición aleatoria escogida. Además, no aprovecha la totalidad de los datos para el entrenamiento.

b) K – Fold Cross – Validation: la validación cruzada de k pliegues divide el conjunto en k subconjuntos de tamaño aproximadamente igual. En cada una de las k iteraciones, un pliegue diferente actúa como conjunto de pruebas mientras $k-1$ pliegues restantes forman el conjunto de entrenamiento. El estimador del error de generalización es la media de los errores obtenidos en las k iteraciones (Kohavi, 1995):

$$Error_{CV} = \left(\frac{1}{k}\right) \times \sum_{i=1}^k Error_i$$

Los valores más empleados son $k = 5$ y $k = 10$, siendo este último el estándar recomendado por Kohavi (1995) como equilibrio entre sesgo y varianza del estimador. Cuando $k = n$ (número total de observaciones), la técnica se denomina Leave – One – Out Cross – Validation (LOO CV).

La limitación existente en este modelo parte de una fuga de datos o data leakage, esto debido a que en estudios donde cada sujeto puede aportar múltiples ensayos de marcha correlacionados entre sí (como puede ocurrir en la base de datos GaitPrint, donde cada individuo contribuye con hasta 18 ensayos distribuidos en dos días), la asignación aleatoria de ensayos a pliegues puede colocar registros del mismo sujeto simultáneamente en el conjunto de entrenamiento y en el conjunto de prueba. Lo que termina en fuga de datos a nivel de sujeto. Como consecuencia, las métricas de rendimiento resultan artificialmente infladas, no porque el modelo haya aprendido a generalizar nuevos individuos, sino porque esencialmente memorizó al sujeto de prueba. Bulgarelli et al. (2026) demostraron empíricamente este efecto de clasificación biomecánica con medidas repetidas, donde la validación k -fold sin control de sujetos sobreestimó

la exactitud por 25 puntos porcentuales respecto a la validación por sujeto (0.91 frente a 0.66, respectivamente).

c) Leave One Subject Out: esta validación también llamada Leave – One – Participant – Out Cross – Validation, es una variante del k-fold diseñada específicamente para conjuntos de datos biomecánicos y clínicos con medidas repetidas por sujeto. En cada iteración i del total de n iteraciones, el sujeto i -ésimo actúa como conjunto de prueba exclusivo, mientras los $n - 1$ sujetos restantes forman el conjunto de entrenamiento (Xu y Hang, 2012):

$$\text{Iteración } i: \text{Train} = \{S_1, \dots, S_n\} \setminus \{S_i\} \mid \text{Test} = \{S_i\}$$

$$\text{Error}_{\text{LOSO}} = \left(\frac{1}{n}\right) \times \sum_{i=1}^n \text{Error}(f_i(X_{Si}))$$

Donde f_i es el modelo entrenado en los $n - 1$ sujetos de la iteración i , y X_{Si} son los datos del sujeto de prueba. Al finalizar las n iteraciones se dispone de una predicción para cada sujeto obtenida a partir de un modelo que nunca vio sus datos durante el entrenamiento.

Esta técnica tiene unas propiedades estadísticas como independencia por diseño, bajo sesgo y mayor varianza que k-fold, esta última propiedad es indiferente al estimador y aceptable cuando $n < 50$ sujetos. (Kohavi, 1995; Xu y Huang, 2012).

d) Bootstrap: se considera una técnica de remuestreo con reemplazo que construye B conjuntos de entrenamiento mediante muestreo aleatorio del conjunto original. Las observaciones no seleccionadas en cada muestra constituyen el conjunto de prueba. El estimador del error es:

$$\text{Error}_{\text{boot}} = \left(\frac{1}{B}\right) \times \sum_{b=1}^B \text{Error}(f_b(OOB_b))$$

Es especialmente útil para muestras muy reducidas ($n < 20$), pues aumenta artificialmente el tamaño efectivo del conjunto de entrenamiento mediante el remuestreo. A diferencia de LOSO,

no garantiza por defecto la independencia a nivel de sujeto, por lo que debe implementarse con remuestreo por sujeto (no por fila) en datos biomecánicos.

3.3.9.3 Aprendizaje profundo. Dentro de estos modelos también se encuentra una rama del Machine Learning, este modelo tiene la capacidad de entrenar computadoras para funcionar similar a un cerebro humano, a partir de este concepto surgió el uso de las redes neuronales artificiales, que por medio de capas de neuronas interconectadas permite automatizar tareas y reconocer patrones (Sarker, I., 2021).

3.3.9.4 Descubrimiento de conocimiento y análisis avanzado. Proceso de extracción y análisis de patrones, y conocimiento de grandes volúmenes de datos. Para el procesamiento de la información se basa en la ciencia de datos donde usa la estadística para investigar realidades a través de los datos.

3.3.9.5 Lógica difusa. Dentro de la IA se encuentra que la lógica difusa intenta analizar datos parcialmente verdaderos por lo tanto maneja incertidumbres e imprecisión y permite clasificar datos dentro de categorías con límites flexibles.

3.3.10 Estadística aplicada al estudio

3.3.10.1 Estadística descriptiva. La estadística descriptiva permite caracterizar la distribución de los biomarcadores de marcha en cada grupo etario. Cuando los datos siguen una distribución aproximadamente normal, se emplea la media ($\bar{x}$) y la desviación estándar (DE) como medidas de tendencia central y dispersión, respectivamente. Cuando la distribución es asimétrica o presenta valores atípicos se prefiere la mediana y el rango intercuartílico ($IQR = Q3 - Q1$), por su robustez frente a valores extremos (Field, 2018). La representación gráfica mediante boxplots permite comparar visualmente ambos grupos e identificar outliers antes de aplicar pruebas inferenciales.

3.3.10.2 Estadística inferencial

a) Verificación de normalidad: prueba de Shapiro-Wilk: Antes de seleccionar la prueba de comparación, se verifica el supuesto de normalidad mediante la prueba de Shapiro-Wilk, considerada la más potente para muestras pequeñas ($n < 50$). La hipótesis nula establece que los datos provienen de una distribución normal; un valor $p < 0.05$ indica desviación significativa de la normalidad (Shapiro & Wilk, 1965).

b) Homogeneidad de varianzas: prueba de Levene: Confirmada la normalidad, se evalúa la igualdad de varianzas entre grupos mediante la prueba de Levene. Un valor $p > 0.05$ indica homocedasticidad y permite aplicar la t de Student; un valor $p \leq 0.05$ indica varianzas heterogéneas y obliga a utilizar la corrección de Welch (Levene, 1960).

c) Elección de hipótesis: La selección de la prueba sigue el árbol de decisión siguiente:

- T de Student: Datos normales y varianzas homogéneas. Compara las medias de dos grupos independientes asumiendo varianzas iguales.


- T de Welch: Datos normales y varianzas heterogéneas. Es una adaptación de la t de Student que ajusta los grados de libertad mediante la ecuación de Welch-Satterthwaite, manteniendo el control del error tipo I cuando las varianzas difieren. West (2021) recomienda su uso por defecto frente a la t de Student clásica
- U de Mann-Whitney: Datos no normales o muestras con alta inestabilidad. Prueba no paramétrica basada en rangos, más robusta ante valores atípicos, adecuada para comparar dos grupos independientes cuando no se cumplen los supuestos paramétricos (Mann & Whitney, 1947).

3.3.10.3 Tamaño del efecto: d de Cohen. El valor p indica si una diferencia es estadísticamente significativa, pero no su magnitud ni relevancia práctica. Para cuantificar esta magnitud se utiliza la d de Cohen, definida como la diferencia entre medias dividida por la desviación estándar combinada. (Cohen,1988) establece los umbrales de interpretación: $d = 0.20$ (pequeño), $d = 0.50$ (mediano) y $d = 0.80$ (grande). En estudios gerontológicos, (Brydges, 2019) señala que estos umbrales tienden a sobreestimar el efecto y propone valores ajustados al campo: $g = 0.15$ (pequeño), 0.40 (mediano) y 0.75 (grande). Cuando se utiliza Mann-Whitney, el complemento no paramétrico equivalente es la correlación de rango biserial (r).

4. Metodología

4.1 Tipo y diseño del estudio

La presente investigación se enmarca en un diseño mixto explicativo secuencial, propuesto por Creswell (2014), en el que una fase cuantitativa precede y orienta una fase cualitativa posterior. En la primera fase se lleva a cabo la recolección, preprocesamiento y análisis de datos cinemáticos provenientes de la base de datos GaitPrint, la extracción de biomarcadores de marcha, el análisis estadístico inferencial y el entrenamiento de modelos de aprendizaje automático. Los resultados cuantitativos obtenidos alimentan la segunda fase, de naturaleza cualitativa, en la que se realiza la interpretación biomecánica de los patrones diferenciadores identificados entre adultos jóvenes y adultos mayores. La integración de ambas fases permite no solo clasificar grupos etarios con precisión, sino también explicar el significado funcional de las diferencias detectadas. Como se resume en la Figura 14.

Figura 14*Diseño explicativo secuencial*

4.2 Base de datos y muestra

4.2.1 Origen

La base de datos utilizada es NONAN GaitPrint (Nonlinear Analysis Core GaitPrint), desarrollada por el laboratorio de biomecánica de la Universidad de Nebraska Omaha. Está compuesta por dos conjuntos complementarios: uno de adultos jóvenes (Wiles et al., 2023) y uno de adultos mayores (Wiles et al., 2025), ambos disponibles en acceso abierto a través de Scientific Data (Nature Portfolio).

4.2.2 Muestra inicial y grupos etarios

El conjunto de adultos jóvenes incluye 35 sujetos sanos (19–35 años; 18 hombres y 17 mujeres; edad: $24,6 \pm 2,7$ años; talla: $1,73 \pm 0,78$ m; masa corporal: $72,44 \pm 15,04$ kg). El conjunto de adultos mayores incluye 41 sujetos (56+ años; 20 hombres y 21 mujeres; edad: $64,7 \pm 7,5$ años; talla: $1,7 \pm 0,1$ m; masa corporal: $81,1 \pm 17,8$ kg). La muestra total inicial es de $n = 76$ sujetos sanos sin patología neurológica o musculoesquelética reportada.

4.2.3 Sensores y protocolo de registro


Los datos fueron capturados mediante sensores IMU Noraxon Ultium Motion™ de cuerpo completo durante la marcha a velocidad libre en una pista interior de 200 m, a lo largo de 18

ensayos de 4 minutos distribuidos en dos días. Las variables registradas incluyen aceleración, velocidad, posición, orientación, velocidad rotacional de cada segmento corporal y ángulos articulares.

4.2.4 Criterios de inclusión y exclusión aplicados

Se filtraron 15 sujetos por cada grupo con registros completos en los 18 ensayos, donde se excluyeron ensayos con interrupciones de señal o artefactos de movimiento no corregibles durante el preprocesamiento.

4.2.5 Flujo metodológico



4.3 Preprocesamiento de señales

4.3.1 Estructura de los datos brutos y carga.

Los datos crudos de cada sujeto se ordenaron jerárquicamente según la estructura del protocolo de adquisición: Noraxon nombra a cada sujeto (S001-S040) según el grupo al que

pertenezca (G01: adultos jóvenes 19-35 años; G03: adultos mayores 60-75 años) y posee un total de 18 ensayos distribuidos en 2 días (D01, D02), 3 bloques (B01-B03) y 3 repeticiones por bloque (T01-T03). Cada ensayo se almacenó como un archivo CSV independiente con el formato de nomenclatura.

La función *load_and_clean_csv()* del módulo *Data Loader.py* del repositorio *Gait-Reorganization* (Martínez, 2024) carga cada archivo mediante la librería *Pandas* – *pandas.read_csv* e inmediatamente se aplica la primera fase de preprocesamiento.

4.3.2 Recortes de bordes de señal (*Trimming*)

Las señales biomecánicas capturadas durante las sesiones de marcha presentan disrupciones en los extremos temporales del registro: al inicio, el sujeto está acelerando y adoptando el patrón estable de la marcha; al final, está desacelerando o anticipando la detención. Hacer uso de estas regiones en el análisis puede llevar a una variabilidad no representativa del patrón estacionario de la marcha libre (Whittle, 2007; Perry y Burnfield, 2010).

La función *trim_signal_edges(df, fs, trim_seconds)* implementada en *PP_pipeline.py* del repositorio *Gait-Reorganization* (Martínez, 2024) elimina los primeros y últimos *trim_seconds* segundos de cada ensayo. Expresado en número de muestras:

$$n_{trim} = \text{int}(\text{trim}_{seconds} * fs); df_{trimmed} = df.iloc[n_{trim}:-n_{trim}]$$

Donde *fs* es la frecuencia de muestreo (200 Hz en los archivos brutos) y *trim_seconds* = 10 s, valor determinado durante la exploración de los datos como suficiente para excluir las fases de arranque y frenado. Los archivos recortados se guardan en la subcarpeta *trimmed/* del directorio del sujeto correspondiente.

4.4 Segmentación y detección de eventos de marcha

Los eventos de la marcha (Heel Strike y Toe-Off) se detectan a partir de las señales de contacto plantar registradas por los sensores Noraxon Ultium Motion. El sistema asigna el valor 1000 cuando el pie está en contacto con el suelo y el valor 0 cuando está en el aire, produciendo una señal binaria de alta confiabilidad para cada pie.

Se implementaron y evaluaron dos estrategias de detección en el módulo `gait_events.py`, repositorio Gait-Reorganization (Martínez, 2024) descritas en la siguiente sección.

4.4.1 Estrategias usadas para detección de eventos:

- Estrategia A: Detección biomecánica (`gait_events_HC_JA`) repositorio Gait-Reorganization (Martínez, 2024)

Este método detecta los eventos de marcha a partir de la cinemática articular de rodilla y cadera, combinada con las señales de contacto plantar. El Heel Strike se identifica en los picos de flexión de rodilla validados por contacto activo. El procedimiento fue el siguiente:

$$HS_{candidatos} = find_peaks(knee_flexion_R, height = 0)$$

$$HS_R = \{i \in HS_candidatos : contact_R(i) = 1000\}$$

El Toe-Off se detecta identificando el pico máximo de velocidad angular de rodilla dentro de cada ciclo, validados por aceleración positiva de cadera:

$$Knee_vel_R(t) = d/dt [Knee_Flexion_R(t)]$$

$$TO_R = \operatorname{argmax} \{knee_vel_R(p) : p \in peaks(knee_vel_R), hip_acc_R(p) > 0\}$$

- Estrategia B: Detección por transición de contacto (`gait_events_simple`) repositorio Gait-Reorganization (Martínez, 2024)

Este método detecta los eventos de marcha directamente a partir de las transiciones de las señales de contacto plantar, sin requerir información cinemática articular. Un Heel Strike ocurre

cuando la señal de contacto pasa de inactiva (0) a activa (1000), y un Toe-Off ocurre con la transición inversa:

$$HS_R = \{i: \text{Contact_R}(i-1) = 0 \wedge \text{Contact_R}(i) = 1000\}$$

$$TO_R = \{i: \text{Contact_R}(i-1) = 1000 \wedge \text{Contact_R}(i) = 0\}$$

La implementación en NumPy utiliza operaciones vectoriales sobre arrays booleanos, haciendo el proceso eficiente para grandes volúmenes de datos:

$$HS_R = \text{np.where}((\sim \text{contact_R}[:, -1]) \& (\text{contact_R}[1:]))[0] + 1$$

$$TO_R = \text{np.where}((\text{contact_R}[:, -1]) \& (\sim \text{contact_R}[1:]))[0] + 1$$

4.4.2 Comparación de estrategias

Tabla 6

Comparación de estrategias de detección de eventos de marcha

Criterio	<i>gait_events_HC_JA</i>	<i>gait_events_simple</i>
Señales requeridas	Knee Flexion + Hip Flexion + Contact RT/LT	Solo Contact RT/LT
Robustez ante ruido	Moderada (depende de cinemática articular)	Alta (señal binaria y limpia)
Costo computacional	Alto (find peaks + derivadas numéricas)	Muy bajo (operaciones vectoriales)
Precisión temporal	Indirecta desde cinemática	Directa desde sensor de contacto
Método seleccionado	No seleccionado	Seleccionado

Se seleccionó *gait_events_simple* repositorio Gait-Reorganization (Martínez, 2024) para el pipeline final porque las señales de contacto plantar del sistema Noraxon son inherentemente binarias, limpias y de alta precisión temporal. Esto hace innecesario el procesamiento adicional de señales cinemáticas articulares para determinar los eventos de contacto, reduciendo la complejidad computacional y eliminando posibles fuentes de error asociadas a la diferenciación numérica de señales ruidosas.

4.4.3 Algoritmo de Segmentación

Una vez detectados los índices de Heel Strike mediante *gait_events_simple* repositorio Gait-Reorganization (Martínez, 2024), la función *segment_cycles_simple* del módulo

segment_utils.py divide cada ensayo trimmed en ciclos individuales. Para cada par de Heel Strikes consecutivos del pie derecho, se extrae el segmento correspondiente del DataFrame:

```
hs_R, hs_L, to_R, to_L = gait_events_simple(df)
```

```
for i in range(len(hs_R) - 1):
```

```
    ciclo = df.iloc[hs_R[i] : hs_R[i+1] + 1]
```

La inclusión del índice $hs_R[i+1] + 1$ garantiza que el punto de contacto inicial que cierra el ciclo quede incluido en el segmento, asegurando la completitud temporal de cada ciclo sin solapamiento entre ciclos consecutivos.

4.4.4 Criterios de Aceptación y Descarte de Ciclos

Se aplicaron los siguientes criterios de control de calidad en orden secuencial para garantizar la validez de los ciclos utilizados en el análisis:

- Criterio 1 — Recorte temporales (trimming)

Antes de la segmentación, cada ensayo fue recortado eliminando los primeros y últimos 10 segundos de grabación. A la frecuencia de muestreo de 200 Hz, eso equivale a eliminar 2000 muestras en cada extremo:

$$N_{recorte} = f_s \times t_{recorte} = 200 \text{ Hz} \times 10 \text{ s} = 2000 \text{ muestras}$$

Este criterio elimina los periodos de aceleración y desaceleración al inicio y final del ensayo, conservando únicamente los ciclos correspondientes a la marcha estacionaria a ritmo libre.

- Criterio 2 — Mínimo de Heel Strikes por ensayo

Se requiere un mínimo de dos Heel Strikes detectados en el pie derecho para que el ensayo sea segmentable ($\text{len}(\text{hs_R}) \geq 2$). Si esta condición no se cumple, el ensayo es descartado completamente. Este criterio protege contra ensayos con señales de contacto defectuosas o grabaciones demasiado cortas.

4.4.5 Validación visual de los ciclos

La validación visual de los ciclos segmentados se realizó mediante el notebook *Visualization.ipynb*, repositorio Gait-Reorganization (Martínez, 2024) que permite inspeccionar de forma interactiva las señales de la marcha en diferentes etapas del procesamiento. Para cada ensayo de los sujetos seleccionados, se verificaron tres aspectos fundamentales:

- Correspondencia entre transiciones detectadas y eventos reales de contacto: se graficaron las señales Contact RT y Contact LT junto con los índices de Heel Strike y Toe-Off detectados, confirmando que cada biomarcador coincidía visualmente con el cambio de estado de la señal.
- Coherencia morfológica interciclo: se superpusieron todos los ciclos segmentados de un mismo ensayo tras normalización temporales a 100 puntos, graficando señales claves como Knee Flexion RT e Hip Flexion RT. La superposición de ciclos individuales permite identificar visualmente ciclos atípicos como consecuencia de tropiezos, pausas o artefactos de sensor.
- Simetría bilateral: se compraron los patrones del pie derecho e izquierdo.

4.4.6 Relación entre segmentación y cálculo de variables espaciotemporales

La segmentación de ciclos es el paso previo y súper importante para el cálculo de todas las variables espaciotemporales descritas en la sección 3.3.4 Eventos de la marcha y Segmentación del ciclo Locomotor. Cada variable se calcula por ciclo individual, utilizando los índices temporales de los eventos detectados y las trayectorias de los marcadores dentro de la ventana del ciclo (Trojaniello et al., 2014; Rampp et al., 2015).

$$Variable_X(ciclo_i) = f(HS_R(i), HS_R(i+1), TO_R(j), Señal [HS_R(i) : HS_R(i+1)])$$

Esta estructura del sistema ciclo a ciclo tiene dos consecuencias importantes para el proyecto. En primer lugar, permite cuantificar la variabilidad intra-sujeto del patrón de marcha. En segundo lugar, permite construir un conjunto de datos con múltiples observaciones independientes por sujeto y por ensayo, este enfoque permite obtener múltiples observaciones independientes por sujeto y por ensayo, lo que enriquece tanto el análisis estadístico comparativo entre grupos como el conjunto de datos disponible para entrenar modelos de clasificación.

4.5 Extracción de Biomarcadores Espaciotemporales

En este proyecto se calcularon 24 biomarcadores espaciotemporales por ciclo de marcha, organizados en cuatro categorías: variables de distancia, variables de tiempo, variables porcentuales y variables de velocidad. Estos biomarcadores se extraen a partir de los eventos de marcha detectados (Heel Strike y Toe-Off) y de las trayectorias de talón y pelvis registradas por el sistema de Noraxon Ultium Motion, tal como se describe en el módulo `spatiotemporales_calculation.py`, el cual fue modificado y adaptado del repositorio Gait-Reorganization (Martínez, 2024) y este puede ser observado en la sección de Apendice E adjunto. Esta extracción tiene dos objetivos, primeramente, identificar un análisis biomecánico y estadístico entre adultos jóvenes y adultos mayores; por otro lado, identificar cuáles son esas variables con mayor poder discriminante entre grupos, lo que permite la interpretación de las representaciones aprendidas por el modelo de aprendizaje automático.

4.5.1 Lista de biomarcadores calculados

La Tabla 7 presenta el listado de los 24 biomarcadores calculados, organizados por categoría, con sus unidades y la notación usada en el código.

Tabla 7

Listado de biomarcadores espaciotemporales calculados a partir del módulo

spatiotemporal_calculation2.py

Nº	Biomarcador	Unidad	Función en el código	Interpretación biomecánica
1	Right Stride Length	cm	compute_L_step_width_and_length()	Distancia entre dos HS ipsilaterales derechos consecutivos. Disminuye con el envejecimiento como estrategia de estabilidad.
2	Left Stride Length	cm	compute_R_step_width_and_length()	Idéntico para el pie izquierdo. Su asimetría con el derecho indica desequilibrio locomotor.
3	Right Step Length	cm	compute_L_step_width_and_length()	Distancia AP del HS derecho al HS izquierdo siguiente. Refleja el alcance del paso en la dirección de avance.
4	Left Step Length	cm	compute_L_step_width_and_length()	Idéntico para el paso izquierdo. La asimetría D/I puede indicar compensación neuromuscular.
5	Right Step Width	cm	compute_L_step_width_and_length()	Separación mediolateral entre pies. Aumenta con la edad como estrategia de ampliación de la base de sustentación.
6	Left Step Width	cm	Compute_R_step_width_and_length()	Identico lado izquierdo.
7	Right Stride Time	s	Compute_L_step_width_and_length()	Duración del ciclo derecho. Aumenta con la edad al reducirse la cadencia.
8	Left Stride Time	s	compute_R_step_width_and_length()	Identico para lado izquierdo

9	Right Step Time	s	compute_L_step_width_and_length()	Tiempo entre HS_R(i) y el siguiente HS_L. Parámetro temporal de paso asimétrico.
10	Left Step Time	s	compute_R_step_width_and_length()	Tiempo entre HS_L(i) y el siguiente HS_R.
11	Right Stance Time	s	compute_stance_time_detailed()	Duración de la fase de apoyo derecha. Aumenta con la edad.
12	Left Stance Time	s	compute_stance_time_detailed()	Idéntico lado izquierdo.
13	Right Swing Time	s	compute_swing_time()	Tiempo en que el pie derecho está en el aire. Disminuye con la edad.
14	Left Swing Time	s	compute_swing_time()	Idéntico lado izquierdo.
15	Double Support Time	s	compute_support_times()	Periodo de contacto bilateral simultáneo por ciclo. Marcador sensible del envejecimiento: aumenta del 20% al 26% con la edad.
16	Single Support Time	s	Compute_support_times()	Tiempo de apoyo unilateral. Disminuye con la edad.
17	Percentage Double Support	%	compute_support_times()	Fracción del ciclo en doble apoyo. Indicador de estabilidad conservadora.
18	Percentage Single Support	%	compute_support_times()	Complemento del doble apoyo.
19	Right % Stance	%	Compute_spatiotemporal_variables()	$(T_{\text{apoyo_D}} / T_{\text{zanc_D}}) \times 100$. Nomal: 60%; mayores: 65-67%
20	Left % Stance	%	Compute_spatiotemporal_variables()	Idéntico lado izquierdo.
21	Right % Swing	%	Compute_spatiotemporal_variables()	$(T_{\text{balanceo_D}} / T_{\text{zanc_D}}) \times 100$. Complemento del % apoyo

22	Left % Swing	%	Compute_spatiotemporal_variables()	Idéntico lado izquierdo
23	Right Stride Speed	m/s	compute_stride_speed()	$L_zanc_D (cm) / T_zanc_D (s) \times 100$. Velocidad media durante una zancada derecha.
24	Left Stride Speed	m/s	Compute_stride_speed()	Idéntico lado izquierdo. La velocidad de marcha disminuye progresivamente con la edad.

4.5.2 Criterios de calidad y manejo de variables no calculables

No todos los ciclos segmentados producen valores válidos para la totalidad de los 24 biomarcadores. Esto ocurre cuando alguno de los eventos de referencia requeridos (contacto inicial o despegue del pie) no fue detectado dentro de la ventana temporal del ciclo. En estos casos, el código implementa tres estrategias de manejo según la naturaleza del evento ausente:

Condición detectada	Implementación en el código	Biomarcadores afectados
Vector de zancada con norma = 0 (dos CI en la misma posición).	If norm == 0: continue	Stride Length, Step Length, Step Width, Stride Speed
No existe TO válido entre CI _i y CI _(i+1)	stance_times.append (np.nan)	Stance Time, swing time, % Stance, % Swing
T _{apoyo} calculado es negativo (DO anterior a CI)	If stance >= 0: ... else: np.nan	Stance Time, Swing Time, % Stance, % Swing
T _{zancada} = 0 (CI duplicado en el tiempo)	np.where(stride_time == 0, np.nan,...)	% Stance, % Swing, Stride Speed

Condición detectada	Implementación en el código	Biomarcadores afectados
Ensayo sin CI contralateral dentro del stride	If not candidates: continue	Step Length, Step Width, Step Time

Los valores de NaN resultantes son propagados a las etapas de agregación, donde la función `np.nanmean()` y `np.nanstd()` los excluye automáticamente del cálculo de la media y desviación estándar por ensayos, sin eliminar el ciclo completo. Este tratamiento preserva la máxima cantidad de datos válidos disponibles, siguiendo la recomendación de Robertson et al. (2014) para el manejo de datos faltantes en biomecánica.

4.5.3 Verificación de consistencia interna

Por construcción, los biomarcadores espaciotemporales calculados satisfacen un conjunto de identidades matemáticas que permiten verificar la coherencia interna del proceso de extracción. Estas relaciones no son criterios adicionales de filtrado, sino consecuencias algebraicas directas de las ecuaciones implementadas:

Identidad I – complementariedad apoyo – balanceo

$$T_{apoyo} + T_{balanceo} = T_{zancada}$$

Identidad II – complementariedad doble – simple apoyo

$$T_{doble\ apoyo} + T_{simple} = T_{zancada}$$

Identidad III – relación velocidad – longitud – cadencia

$$V_{zancada} \left(\frac{m}{s} \right) = \frac{L_{zancada}(m) \times Cadencia \left(\frac{pasos}{minuto} \right)}{120}$$

La identidad 3 conecta la velocidad de zancada con la cadencia, lo que permite verificar la consistencia entre biomarcadores calculados por funciones independientes del código. Una diferencia significativa existe entre el valor de $V_{zancada}$ calculados directamente y el estimado

mediante la cadencia y longitud de zancada indicaría un error en alguna de las tres funciones de cálculo.

4.5.5 Interpretación biomecánica en el contexto del envejecimiento

Los 24 biomarcadores se organizan en siete grupos funcionales que pueden capturar dimensiones complementarias del patrón locomotor. La Tabla 8 presenta esta organización junto con la dirección esperada del cambio con el envejecimiento, según la literatura biomecánica de referencia.

Tabla 8

Organización funcional de los 24 biomarcadores y dirección esperada del cambio con el envejecimiento. D: derecho; I: Izquierdo

Grupo funcional	Biomarcadores	Cambio esperado con el envejecimiento
Longitudes espaciales	Stride Length D/I, Step Length D/I.	Disminución. La reducción de longitud de zancada es el marcador espacial más consistente del envejecimiento locomotor (Murray et al., 1969; Whittle, 2007).
Anchura de paso	Step Width D/I.	Aumento. La ampliación de la base de sustentación lateral es una estrategia adaptativa de estabilidad postural (Maki, 1997; Winter, 2009).
Tiempos de ciclo	Stride Time D/I, Step Time D/I.	Aumento. La mayor duración del ciclo está asociada a la reducción de cadencia y velocidad de marcha (Whittle, 2007).

Apoyo y balanceo	Stance Time D/I, Swing Time D/I, % Stance D/I, % Swing D/I.	Aumento del porcentaje de apoyo. Reducción del porcentaje de balanceo. (Perry y Burnfield, 2010).
Doble apoyo	Double Support Time, Single Support Time, % Double Support, % Single Support	El doble apoyo es el marcador temporal más sensible al envejecimiento: aumenta del 20 al 26% del ciclo, reflejando la reducción del control postural unilateral (Murray et al., 1969).
Velocidad de zancada	Right/Left Stride Speed	Disminución. Consecuencia combinada de menor longitud y mayor tiempo de zancada (Whittle, 2007; Winter, 2009)
Cadencia	Cadence	Aumento. Estrategia compensatoria para conservar la velocidad de marcha con pasos más cortos (Judge et al., 1996; Winter et al., 1990).

4.5.6 Niveles de Resumen Estadístico

Los biomarcadores fueron calculados y organizados en tres niveles de resolución temporal. Cada nivel responde a un objetivo analítico específico dentro de la metodología del proyecto.

Tabla 9

Niveles de agregación de los biomarcadores espaciotemporales y su uso en el proyecto

Nivel	Resolución	Descripción y uso en el proyecto
Nivel 1 – Por ciclo	1 valor por ciclo	Resolución máxima. Producido directamente por <i>compute_spatiotemporal_variables()</i> en la salida <i>spatiotemporal_df</i> . Cada fila corresponde a un ciclo individual. Permite

		analizar la variabilidad intra-ensayos e intra-sujeto del patrón locomotor. Es la unidad de entrada para los modelos de clasificación con aprendizaje automático.
Nivel 2 – Por ensayo	Media $\pm$ DE por ensayo	Para cada uno de los 18 ensayos por sujeto se calcula la media (<i>np.nanmean()</i>) y la desviación estándar (<i>np.nanstd()</i>) de cada biomarcador sobre todos los ciclos válidos del ensayo. Generado por <i>process_spatiotemporal_for_patient_()</i> y guardado en archivos <i>spatiotemporal_mean_preprocessing_final.csv</i> y <i>spatiotemporal_std_preprocessing_final.csv</i> . Se usa para el análisis de fiabilidad test-retest entre sesiones.
Nivel 3 – Por sujeto	Media de ensayos válidos	Se promedian los valores de todos los ensayos válidos de un sujeto para obtener una representación individual robusta. Con $n = 15$ sujetos por grupo, este nivel alimenta la tabla maestra utilizada en el análisis estadístico comparativo entre grupo y en la clasificación supervisada con validación LOSO.

4.5.7 Entorno y herramientas computacionales

El procesamiento, extracción de biomarcadores y análisis estadístico se realizaron en el lenguaje de programación **Python 3.10**, empleando un entorno de desarrollo basado en Jupyter Notebook integrado con el sistema de gestión de paquetes conda. Las librerías utilizadas, con sus versiones exactas verificadas desde el archivo *requirements.txt* del repositorio Gait-Reorganization (Martínez, 2024), se detallan en la Tabla 10.

Tabla 10

Entorno computacional del proyecto

Librería	Uso en el proyecto
NumPy	Operaciones vectoriales y matriciales, cálculo de normas euclídeas, manejo de NaN, pad de arrays (Harris et al., 2020).

Pandas	Gestión de DataFrames de biomarcadores, lectura/escritura de CSV y Excel, sistematización por ensayo y sujeto (McKinney, 2010).
SciPy	Reducción de la frecuencia de muestreo (Decimación antialiasing), detección de picos (find_peaks), pruebas estadísticas (Virtanen et al., 2020).
scikit – learn	StandardScaler, SVM, Random Forest, Regresión Logística, LeaveOneOut (Pedregosa et al., 2011)
Matplotlib	Generación de figuras, curvas ROC, matrices de confusión (Hunter, 2007).
OpenPyXL	Lectura y escritura de tablamaestra.xlsx y archivos de resultados.
Tqdm	Seguimiento del progreso en el procesamiento por lotes de sujetos
PyTorch	Entrenamiento del autoencoder BiLSTM (módulo <i>AE_pipeline_pytorch.py</i>).
Seaborn	Violin plots y box plots por sujeto y grupo.

4.6 Procedimiento de análisis estadístico

4.6.1 Agregación de datos por sujeto

Cada sujeto dispone de 18 ensayos de caminata distribuidos en dos días. Para obtener un valor representativo por individuo se calculó la media de los ensayos válidos por biomarcador. Previamente se aplicó un criterio de depuración basado en la comparación con rangos de referencia (Moe-Nilssen, 1998). reportados en la literatura biomecánica: los ensayos cuyos valores se encontraban fuera de los límites esperados para población sana adulta, o que presentaban errores de señal del sensor, fueron excluidos del promedio.

4.6.2 Construcción de tablas maestras y estadística descriptiva

A partir de los valores agregados por sujeto se construyeron dos tablas maestras. La primera consolida los registros individuales de todos los biomarcadores por sujeto y grupo. La segunda

resume por biomarcador y grupo los siguientes estadísticos: media ($\bar{x}$), desviación estándar (DE), mediana, primer cuartil (Q1), tercer cuartil (Q3), rango intercuartílico (IQR), mínimo y máximo, con la estructura:

La elección entre media $\pm$ DE o mediana [IQR] como estadístico representativo en el reporte de resultados se determinó en función del cumplimiento del supuesto de normalidad evaluado en la sección siguiente. Complementariamente, se generaron boxplots individuales por biomarcador para visualizar la distribución, la dispersión y la presencia de valores atípicos en cada grupo.

4.6.3 Evaluación de normalidad

La verificación del supuesto de normalidad se realiza con la aplicación de la prueba de Shapiro-Wilk con $\alpha = 0.05$ (Shapiro & Wilk, 1965) y como indicador auxiliar el cálculo de los coeficientes de asimetría (skewness) y curtosis como indicadores cuantitativos de la forma de la distribución, la cual fue realizada en el Apéndice F. Los resultados de esta evaluación, incluyendo el p-valor por biomarcador y grupo, se presentan en la sección de resultados 5.4 Estadística inferencial. Los valores de asimetría (skewness) y curtosis por biomarcador se presentan en el Apéndice A.

4.6.4 Homogeneidad de varianzas y selección de prueba

Una vez determinada la normalidad por biomarcador, se evaluó la homogeneidad de varianzas mediante la prueba de Levene (Levene, 1960). La selección de la prueba inferencial siguió el árbol de decisión aplicado de forma independiente a cada biomarcador en Apéndice F.

- t de Student — normalidad confirmada en ambos grupos y varianzas homogéneas (p Levene > 0.05).
- t de Welch — normalidad confirmada y varianzas heterogéneas (p Levene ≤ 0.05).

- U de Mann-Whitney — normalidad no confirmada en alguno de los grupos, independientemente de la homogeneidad de varianzas; más robusta ante valores atípicos frecuentes en datos de adultos mayores (Mann & Whitney, 1947).

Los resultados de la prueba de Levene y la prueba asignada a cada biomarcador se presentan en la sección de resultados 5.4 Estadística inferencial .

En todos los casos se fijó $\alpha = 0.05$ como umbral de significancia estadística.

4.6.5 *Tamaño del efecto*

Adicionalmente al p-valor, se calculó el tamaño del efecto para cuantificar la magnitud práctica de las diferencias detectadas. Para las comparaciones paramétricas se empleó la d de Cohen y la g de Hedges (recomendada para muestras pequeñas por su corrección del sesgo), mientras que para las comparaciones no paramétricas se utilizó la correlación de rango biserial (r). Los umbrales de interpretación adoptados fueron: trivial ($d < 0.20$), pequeño ($0.20 \leq g < 0.50$), mediano ($0.50 \leq g < 0.80$) y grande ($d \geq 0.80$), ajustados para contextos gerontológicos según Brydges (2019). La tabla de resultados inferenciales consolidó por biomarcador: estadístico de prueba, p-valor, intervalo de confianza al 95%, d de Cohen, g de Hedges e interpretación del tamaño del efecto.

El análisis se ejecutó en Python 3.12 sobre Jupyter Notebook en Visual Studio Code, Apéndice F. Las librerías empleadas se detallan en la Tabla 11.

Tabla 11

Librerías utilizadas en Python para el análisis

Librería	Módulo específico	Función usada	Uso en el estudio
numpy	numpy	np.std, np.mean, np.isnan, np.nan, np.sqrt	Cálculo de medias, desviaciones estándar y operaciones numéricas para d de Cohen y g de Hedges

Librería	Módulo específico	Función usada	Uso en el estudio
scipy	scipy.stats.shapiro	shapiro()	Prueba de normalidad de Shapiro-Wilk por biomarcador y grupo
scipy	scipy.stats.ttest_ind	ttest_ind()	Prueba t de Student para muestras independientes cuando se cumple normalidad
scipy	scipy.stats.mannwhitneyu	mannwhitneyu()	Prueba U de Mann-Whitney cuando no se cumple normalidad
pandas	pandas	pd.DataFrame, pd.set_option	Construcción y visualización de la tabla de resultados inferenciales

4.7 Modelos de aprendizaje automático

4.7.1 Variables de entrada y variable objetivo

Las variables de entrada corresponden a los biomarcadores espaciotemporales que resultaron estadísticamente significativos ($p < 0.05$) en el análisis inferencial previo, con un tamaño de efecto mínimo de magnitud mediana (Hedges $g \geq 0.595$). Este doble criterio garantiza que las variables seleccionadas no solo presentan diferencias estadísticamente significativas entre grupos, sino que dichas diferencias tienen relevancia práctica en términos biomecánicos (Hedges, 1981; Kohavi & John, 1997).

La variable objetivo es el grupo etario, codificada como variable binaria discreta: adulto joven = 0 y adulto mayor = 1. La matriz de entrada al clasificador tiene dimensión **X = (30 sujetos × 7 biomarcadores)**, con clases perfectamente balanceadas (15 observaciones por clase).

4.7.2 Modelos evaluados y configuración de hiper-parámetros

Se evaluaron tres clasificadores supervisados ampliamente utilizados en la literatura de análisis de marcha y señales biomédicas (Tran et al., 2021). Cada modelo fue implementado mediante `sklearn.pipeline.Pipeline`, Apendice F, integrando la estandarización de variables

y el clasificador en un único flujo de procesamiento, lo que garantiza que la transformación de escala se ajusta exclusivamente con los datos de entrenamiento en cada iteración LOSO, previniendo fuga de datos hacia el conjunto de prueba (Kaufman & Rosset, 2012).

Previo al entrenamiento de cada modelo, las variables de entrada (7 parámetros espaciotemporales significativos) se estandarizaron mediante `StandardScaler`, Apéndice F, transformando cada biomarcador a media cero y desviación estándar unitaria, permitiendo que el clasificador trate todas las variables con el mismo peso inicial, independientemente de su escala numérica, y que esa transformación sea siempre honesta respecto al sujeto que se está evaluando. Esta estandarización opera sobre los valores de los biomarcadores ya calculados, y no sobre la magnitud aplicada sobre la señal IMU cruda en la etapa de preprocesamiento (sección 4.3 Preprocesamiento de señales). Al integrarlo en el pipeline, el ajuste del escalador se recalcula en cada partición LOSO usando únicamente los datos de entrenamiento, aplicándose luego al sujeto de prueba sin que este influya en la transformación. Este procedimiento es especialmente relevante para Regresión Logística y SVM, cuyo desempeño es sensible a la escala de las variables (Géron, 2022).

4.7.2.1 Regresión Logística. Clasificador lineal que estima la probabilidad de pertenencia a cada clase mediante la función sigmoide. Se configuró con regularización L2 ($C = 1.0$), optimizador lbfgs adecuado para conjuntos de datos de tamaño pequeño a mediano, y un máximo de 1.000 iteraciones para asegurar convergencia (Hosmer et al., 2013).

4.7.2.2 Máquina de Soporte Vectorial — SVM (kernel RBF). Clasificador de margen máximo que proyecta los datos a un espacio de mayor dimensión mediante el kernel de función de base radial (RBF), permitiendo separar clases no linealmente separables. Se habilitó la estimación de probabilidades (*probability = True*) para el cálculo del AUC-ROC. El parámetro $\gamma = \text{scale}$ ajusta automáticamente la influencia de cada muestra en función de la varianza de los datos (Cortes & Vapnik, 1995).

4.7.2.3 Random Forest. Conjunto de árboles de decisión entrenados sobre submuestras aleatorias de los datos y las variables (*bagging*). La predicción final se obtiene por votación mayoritaria entre los 300 árboles. La profundidad máxima ($\text{max_depth} = 4$) y el mínimo de muestras por hoja ($\text{min_samples_leaf} = 2$) Apéndice F, actúan como regularización implícita, reduciendo el sobreajuste en muestras pequeñas (Breiman, 2001).

4.7.2.4 Estrategia de validación. Dado el tamaño muestral reducido ($n = 30$), se adoptó la validación cruzada Leave-One-Subject-Out (LOSO) como estrategia de evaluación. Este esquema es una variante de la validación cruzada de k-iteraciones (*k-fold cross-validation*) donde k es igual al número total de sujetos; en cada iteración un sujeto actúa como conjunto de prueba y los 29 restantes conforman el conjunto de entrenamiento, generando 30 predicciones completamente independientes entre sí (Arlot & Celisse, 2010).

La elección de LOSO sobre otras estrategias de partición responde a dos razones metodológicas. Primera, maximiza el tamaño del conjunto de entrenamiento en cada iteración, lo

cual es crítico cuando el número de sujetos es pequeño. Segunda, y más importante, garantiza que el modelo nunca es entrenado con datos del sujeto que está siendo evaluado, simulando de forma realista el escenario de generalización a nuevos individuos no vistos. Esta propiedad es especialmente relevante en estudios biomecánicos, donde la variabilidad puede introducir sesgo si los datos de un mismo individuo aparecen simultáneamente en entrenamiento y prueba.

La implementación se realizó mediante `sklearn.model_selection.LeaveOneOut`, ver en Apéndice F. integrada dentro del pipeline.

Figura 15

Pseudocódigo del procedimiento de validación cruzada Leave-One-Subject-Out

Entrada: X: matriz de biomarcadores espaciotemporales (n = 30 sujetos, p predictores)
 y: vector de etiquetas de grupo (0 = adulto joven, 1 = adulto mayor)
 C: conjunto de clasificadores {nombre : pipeline}

Salida: R: métricas de desempeño por clasificador

```

1: R ← vacío
2: particiones ← LOSO(X) // n pliegues: un sujeto de prueba por pliegue
3: para cada (nombre, pipeline) en C hacer
4:   y_real ← [ ]; y_pred ← [ ]; y_proba ← [ ]
5:   para cada (entrenamiento, prueba) en particiones hacer
6:     X_tr, y_tr ← X[entrenamiento], y[entrenamiento] // 29 sujetos
7:     X_te, y_te ← X[prueba], y[prueba] // 1 sujeto
8:     ajustar pipeline con (X_tr, y_tr) // estandarización + modelo
9:     pred ← pipeline.predecir(X_te)
10:    proba ← pipeline.predecir_probabilidad(X_te)[clase = 1]
11:    agregar y_te a y_real, pred a y_pred, proba a y_proba
12:  fin para
13:  acc ← Exactitud(y_real, y_pred)
14:  f1 ← PuntajeF1(y_real, y_pred) // 0 si el denominador es
nulo
15:  auc ← AUC-ROC(y_real, y_proba)
16:  cm ← MatrizDeConfusión(y_real, y_pred)
17:  R[nombre] ← {acc, f1, auc, cm, y_real, y_pred, y_proba}
18:  reportar nombre, acc, f1, auc
19: fin para
20: retornar R

```

Nota. El pipeline se ajusta dentro de cada pliegue, de modo que la estandarización se estima únicamente con los 29 sujetos de entrenamiento, lo que impide la fuga de información hacia el sujeto de prueba. Las métricas de las líneas 13 a 16 se calculan sobre el vector acumulado de las 30 predicciones y no como promedio de métricas por pliegue, dado que con un solo sujeto de prueba el AUC y el puntaje F1 individuales no están definidos. Elaboración propia.

La muestra fue diseñada con 15 sujetos por clase: adultos jóvenes (clase 0) y adultos mayores (clase 1), resultando en una distribución perfectamente balanceada (50% / 50%), el clasificador no tiene incentivo estadístico para favorecer ninguna clase durante el entrenamiento.

El balance perfecto entre clases elimina la necesidad de aplicar técnicas de ajuste como:

- SMOTE (Synthetic Minority Oversampling Technique) genera muestras sintéticas de la clase minoritaria.
- Submuestreo (undersampling) reduce la clase mayoritaria.

Adicionalmente, garantiza que métricas como exactitud y F1-score sean directamente interpretables sin corrección por desbalance, y que el AUC-ROC refleje fielmente el poder discriminativo real de cada modelo (Saito & Rehmsmeier, 2015).

4.7.2.5 Métricas de evaluación. El desempeño de cada clasificador se evaluó mediante las siguientes métricas, calculadas sobre las 30 predicciones independientes generadas por la validación LOSO mediante `sklearn.metrics` ver Apéndice F.

- Exactitud (Accuracy) proporción de clasificaciones correctas sobre el total mediante `accuracy_score(y_real, y_pred)` ver Apéndice F.

- F1-Score calculada mediante `f1_score(y_real, y_pred, zero_division=0)`.

Corresponde a la media armónica entre precisión y *recall* ver Apéndice F.

- AUC-ROC corresponde al área bajo la curva ROC; calculada mediante `roc_auc_score(y_real, y_proba)`, donde `y_proba` contiene las probabilidades

continuas de pertenencia a la clase adulto mayor (1), obtenidas con

`pipeline.predict_proba(X_te)[ :, 1]`. ver Apéndice F. A diferencia de la

exactitud, el AUC-ROC evalúa el poder discriminativo del modelo a través de todos los umbrales posibles, siendo más informativa en clasificación binaria (Fawcett, 2006). Por esta razón se adoptó como criterio principal de selección del mejor modelo.

- Matriz de confusión analiza errores por clase Verdaderos Positivos (VP), Verdaderos Negativos (VN), Falsos Positivos (FP) y Falsos Negativos (FN), permitiendo identificar el tipo de error predominante por clase y los sujetos mal clasificados, es generada mediante `confusion_matrix(y_real, y_pred)` y visualizada con `ConfusionMatrixDisplay` ver Apéndice F.
- Reporte de clasificación completo: Ejecutado únicamente sobre el modelo ganador mediante `classification_report(y_real, y_pred, target_names=["Joven (0)", "Mayor (1)"], digits=3)`, reporta precisión, *recall* y F1-score discriminados por clase, permitiendo evaluar si el modelo clasifica con igual eficacia adultos jóvenes y adultos mayores.

La selección del mejor modelo se basó en el AUC-ROC como criterio primario por ser más informativo que la exactitud en tareas de clasificación binaria

4.7.2.6 Importancia de variables y análisis exploratorio. Con el fin de interpretar el comportamiento interno de los modelos e identificar qué biomarcadores contribuyen más a la clasificación, se realizaron tres análisis complementarios:

a) Importancia por permutación: Sobre el modelo ganador se calculó la importancia de cada variable mediante `permutation_importance` de `sklearn.inspection` ver Apéndice F.. Este método evalúa cuánto disminuye el desempeño del modelo cuando los valores de un biomarcador son permutados aleatoriamente: una caída grande en el AUC indica que esa variable es crítica para la clasificación, mientras que una caída pequeña o nula indica que el modelo puede prescindir de ella (Breiman, 2001). La importancia por permutación es más confiable para variables correlacionadas.

b) Análisis de componentes principales (PCA 2D): Se aplicó PCA de dos componentes sobre la matriz X estandarizada para visualizar la separabilidad de los grupos en el espacio reducido de biomarcadores. Los dos primeros componentes explicaron en conjunto el 93.4% de la varianza total, lo que indica que la estructura discriminante entre jóvenes y adultos mayores se concentra en pocas dimensiones. Cada punto en el gráfico representa un sujeto, permitiendo evaluar visualmente si los grupos son linealmente separables antes de aplicar los clasificadores (Jolliffe & Cadima, 2016).

c) Curvas ROC por clasificador: Se generó una curva ROC individual para cada uno de los tres clasificadores, trazando la tasa de verdaderos positivos (*recall*) frente a la tasa de falsos positivos para todos los umbrales de decisión posibles. La comparación visual de las tres curvas permite identificar qué modelo mantiene mejor equilibrio entre sensibilidad y especificidad a lo largo del espacio de umbrales, complementando la comparación numérica por AUC (Fawcett, 2006).

4.7.2.7 Selección del mejor modelo. El modelo ganador se determinó automáticamente seleccionando el clasificador con mayor AUC-ROC sobre las 30 predicciones LOSO debido a que, este evalúa el poder discriminativo global del modelo a través de todos los umbrales de decisión posibles, siendo más robusto e informativo en tareas de clasificación binaria.

Sobre el modelo ganador se identificaron los sujetos mal clasificados comparando la etiqueta real contra la predicha, permitiendo determinar si los errores se concentran en una clase específica (jóvenes clasificados como mayores o viceversa), lo que proporciona información sobre los límites de generalización del modelo y orienta la interpretación biomecánica de los casos atípicos.

Los resultados numéricos completos: Accuracy, F1 y AUC por clasificador, sujetos mal clasificados y reporte de clasificación detallado se presentan en el capítulo 5.5.4 Desempeño comparativo de los clasificadores

4.7.2.8 Librerías de ML utilizadas

Librería	Versión	Componentes utilizados	Función en el estudio
scikit-learn	1.8.0	SVC, RandomForestClassifier, LogisticRegression	Implementación de los tres clasificadores evaluados
	1.8.0	StandardScaler, Pipeline	Preprocesamiento y flujo integrado de entrenamiento
	1.8.0	LeaveOneOut	Validación cruzada LOSO
	1.8.0	permutation_importance	Importancia de variables sobre el modelo ganador
	1.8.0	accuracy_score, f1_score, roc_auc_score, confusion_matrix, classification_report	Cálculo de métricas de evaluación
sklearn.decomposition	1.8.0	PCA	Análisis de componentes principales
matplotlib	3.10.9	pyplot, gridspec	Curvas ROC, matrices de confusión, importancia de variables, PCA
seaborn	0.13.2	boxplot, stripplot	Visualización de distribuciones por grupo
openpyxl	3.1.5	From pandas	Exportación de resultados a Excel

4.8 Identificación e interpretación de biomarcadores relevantes

Los biomarcadores identificados como más discriminantes se interpretaron en el marco de la biomecánica del envejecimiento, relacionando los cambios en los parámetros temporales del ciclo de marcha con los mecanismos fisiológicos asociados al envejecimiento documentados en la literatura, como lo son: la reducción de la velocidad de conducción nerviosa, disminución de la fuerza muscular de miembros inferiores y alteraciones en el control postural (Pirker & Katzenschlager, 2017; Aboutorabi et al., 2016).

5. Resultados

5.1 Caracterización de la muestra

5.1.1 Descripción de la muestra y criterios de selección

La muestra del presente estudio estuvo conformada por 30 sujetos seleccionados de la base de datos NONAN GaitPrint (Wiles et al., 2023; Wiles et al., 2025), distribuidos en dos grupos de igual tamaño: 15 adultos jóvenes (Grupo 01, 19 – 35 años) y 15 adultos mayores (Grupo G03, 56+ años). Los datos fueron registrados a 200 Hz mediante 16 unidades de medición inercial Noraxon Ultium Motion™ durante 18 ensayos de 4 minutos distribuidos en dos días, sobre una pista de marcha de 200 metros en ambiente controlado.

Durante el estudio, se indica que los criterios de inclusión de la base de datos original comprenden: (i) capacidad para otorgar consentimiento informado, (ii) capacidad para caminar de forma independiente sin dispositivo de asistencia, (iii) ausencia de diagnóstico autorreportado de enfermedad neurológica; y (iv) ausencia de diagnóstico autorreportado de discapacidad, lesión o enfermedad en miembros inferiores (Wiles et al., 2023). Adicionalmente, los adultos mayores debían completar la prueba de *Timed Up and Go* entre 5 y 15 segundos, obligatorio obtener una puntuación superior a 24 en el Examen del Estado Mental Mínimo (Mini-Mental State Examination) previo a la participación (Wiles et al., 2025).

El diseño balanceado de 15 sujetos por grupo fue seleccionado intencionalmente para garantizar la igualdad de representación entre grupos y evitar la necesidad de técnicas de sobremuestreo sintético como SMOTE (Synthetic Minority Oversampling Technique), las cuales pueden introducir patrones biomecánicos artificiales no representativos de la población real al interpolar entre observaciones existentes.

Sujetos seleccionados por grupo	
Adultos jóvenes (G01)	Adultos mayores (G03)
S001, S002, S004, S006, S007, S008, S011, S014, S015, S016, S018, S020, S021, S023, S024	S019, S107, S109, S120, S139, S140, S141, S142, S143, S145, S146, S154, S156, S157, S158

Cabe aclarar que el sujeto S120 (adulto mayor, 68 años, sexo femenino) regresó para su segunda sesión dos semanas después de la primera, en lugar de los 7 días establecidos por el protocolo estándar de GaitPrint. Este caso fue documentado por Wiles et al. (2025) y se mantuvo en la muestra dado que los autores originales lo incluyeron en la base de datos validada.

5.1.2 Características demográficas y antropométricas

La Tabla 12 presenta las características demográficas y antropométricas de los 30 sujetos incluidos en el análisis, extraídas del archivo *GaitPrint_Subject_Characteristics* de la base de datos NONAN GaitPrint. Los valores corresponden a los datos individuales de los sujetos seleccionados, no a los estadísticos del conjunto completo reportados por Wiles et al. (2023, 2025).

Tabla 12

Características demográficas y antropométricas de la muestra

Variable	Adultos jóvenes (n = 15)	Adultos mayores (n = 15)	p
Edad (años)			
Media $\pm$ DE	24.6 $\pm$ 2.7	64.5 $\pm$ 7.5	-
Rango	19 – 35	56 - 84	-
Sexo			
Hombre, n (%)	11 (73.3%)	8 (53.3%)	-
Mujeres, n (%)	4 (26.7%)	7 (46.7%)	-
Talla (m)	1.78 $\pm$ 0.08	1.72 $\pm$ 0.07	0.066

Masa corporal (kg)	75.0 ± 13.8	80.9 ± 14.3	0.264
IMC (kg/m²) †	23.7 ± 3.7	27.1 ± 3.7	0.019

Nota. Los valores p corresponden a la prueba t de Student de dos muestras independientes (Welch). IMC = índice de masa corporal. † Diferencia estadísticamente significativa entre grupos ($p < 0.05$).

Fuente. Elaboración propia a partir de los archivos GaitPrint_Subject_Characteristics.csv de Wiles et al. (2023) y Wiles et al. (2025).

Como se observa en la tabla 4.1, el grupo de adultos jóvenes presentó una edad media de 24.6 ± 2.7 con predominancia masculina (11 hombres). El grupo de adultos mayores registró una edad media de 64.5 ± 7.5 , con distribución más equilibrada entre sexos (8 hombres, 53.35). La diferencia entre grupos fue, por diseño de la base de datos, la principal variable de clasificación.

5.1.3 Protocolo de recolección de datos de GaitPrint

Todos los datos utilizados en el presente estudio fueron obtenidos de la base de datos NONAN GaitPrint, cuyo protocolo de recolección fue estandarizado para ambas subpoblaciones. Cada sujeto completó 18 ensayos de marcha (9 por día x 2 días) a velocidad libre y autopercebida sobre una pista de 200 metros en interior, con un intervalo de 7 días entre sesiones. Cada ensayo tuvo una duración de 4 minutos, distribuidos en 3 bloques de 3 ensayos cada uno con un descanso opcional de hasta 5 minutos entre bloques.

El sistema Noraxon Ultium Motion® registró los datos a 200 Hz con 16 IMUs ubicadas en cabeza, miembros torácicos superiores e inferiores, pelvis, brazos, antebrazos, manos, muslos, piernas y pies. Los parámetros espaciotemporales disponibles en la base de datos incluyen longitud de paso, longitud de zancada, ancho de paso, cadencia, tiempos de apoyo y balanceo, porcentajes de fases, tiempos doble y simple apoyo, velocidad de marcha y velocidad de zancada (Wiles et al., 2023; Wiles et al., 2025). Como se observa en la Tabla 13.

Tabla 13*Resumen de protocolo de recolección de datos de la base NONAN GaitPrint*

Parámetro	Descripción
Sistema de captura	Noraxon Ultium Motion – 16 IMUs (200 Hz)
Número de ensayos	18 por sujeto (9 por día x 2 días)
Duración de cada ensayo	4 minutos a velocidad autopercebida
Estructura de sesión	3 bloques x 3 ensayos. Descanso opcional < 5 min entre bloques
Intervalo entre días	7 días (protocolo estándar).
Entorno	Pista de marcha de 200 m en interior.
Calibración	Procedimiento funcional previo a cada ensayo (2.5 s estático, 15 s marcha, 2.5 s estático)
Frecuencia de muestreo	200 Hz. Formato de exportación: 48 000 filas x 321 columnas por ensayo
Variables espaciotemporales	24 variables por ensayo, incluyendo parámetros espaciales, temporales, temporofásicos y espaciotemporales

Nota. Elaborado con base en Wiles et al. (2023) y Wiles et al. (2025)

5.2 Resultados del preprocesamiento y segmentación

La aplicación del procedimiento de validación visual descrito en la sección 4.4.5 confirmó la correcta segmentación de los ciclos de marcha para los ensayos analizados. A continuación se presenta los resultados de los tres aspectos verificados: correspondencia entre eventos detectados y señal de contacto, coherencia morfológica interciclo y simetría bilateral.

5.2.1 Coherencia morfológica interciclo


La figura 16 presenta la superposición de todos los ciclos de marcha segmentados del ensayo D01-B01-T01 del sujeto S001 (G01), normalizados temporalmente al 0-100 % del ciclo mediante interpolación lineal a 100 puntos. Los ángulos graficados corresponden a la flexión de rodilla derecha (Knee Flexion RT) y la flexión de cadera derecha (Hip Flexion RT).

La estrecha similitud morfológica entre los ciclos individuales evidencia un patrón locomotor estable a lo largo del ensayo. En la flexión de rodilla se identifican con claridad los picos característicos del ciclo de marcha: el primer pico (aproximadamente 25°) alrededor de los primeros 10 – 15% del ciclo, asociado a la repuesta de carga durante el apoyo inicial, y el segundo pico (aprox. 65°) alrededor del 70 - 75% correspondiente a la flexión de rodilla durante la fase de balanceo. En la flexión de cadera se observa un patrón sinusoidal esperado: extensión durante el apoyo (valores negativos) y flexión durante balanceo (valores positivos).

La dispersión entre ciclos es mínima en ambas señales, confirmando que el algoritmo de detección de eventos basado en transiciones de contacto plantar identificó correctamente los instantes de Heel Strike sin inclusión de ciclos atípicos asociados a tropiezos pausas o artefactos del sensor.

Figura 16

Coherencia morfológica interciclo de los ángulos de flexión de rodilla y cadera durante la marcha del sujeto S001 (G01, ensayo D01-B01-T01).




5.2.2 Simetría bilateral

La figura 17 presenta la comparación bilateral de los patrones de flexión de rodilla y cadera para el mismo ensayo, superponiendo los ciclos del pie derecho (azul) y el pie izquierdo (rojo) en los mismos ejes, con referencia temporal en el Heel Strike derecho.

Los patrones de ambas partes presentan morfologías equivalentes con un desfase temporal de aproximadamente el 50% del ciclo, consistente con la alternancia fisiológica esperada durante la marcha bipedal (Perry y Burnfield, 2010). Las curvas azul y roja se cruzan alrededor del 25% y el 75% del ciclo, instante en los que uno de los pies transiciona entre apoyo y balanceo mientras el otro hace lo contrario, confirmando así la correcta detección bilateral de los Heel Strikes.

Figura 17

Simetría bilateral de ángulos de flexión de rodilla y cadera durante la marcha del sujeto S001 (G01, ensayo D01-B01-T01).




La Figura 18 presenta la señal de dorsiflexión del tobillo derecho del sujeto S002 (G01, ensayo D01-B01-T01) tras la aplicación del recorte temporal de los primeros y últimos 10 segundos del ensayo y la reducción de la frecuencia de muestreo de 200 Hz a 50 Hz mediante decimación antialiasing. La señal resultante exhibe un patrón estacionario, con amplitudes regulares descritas entre -40° y $+10^\circ$, consistentes con el movimiento de dorsiflexión – flexión plantar durante la marcha a velocidad auto percibida.

La ausencia de transición al inicio o al final de la señal confirma que el recorte temporal de 10 segundos eliminó eficazmente las fases de aceleración y desaceleración del sujeto al inicio y final del ensayo, estos pueden reproducir ciclos biomecánicamente atípicos. Lo que garantiza la validez de los ciclos extraídos en la etapa de segmentación.

Figura 18

Señal de dorsiflexión del tobillo derecho (S002, G01, D01-B01-T01) tras el recorte temporal (10 s en cada extremo). El eje horizontal representa el número de muestra tras el recorte; el eje vertical representa el ángulo de dorsiflexión en grados



5.3 Biomarcadores espaciotemporales: estadística descriptiva

5.3.1 Tabla descriptiva por biomarcador y grupo

La Tabla 14 presenta los estadísticos descriptivos de los 24 biomarcadores espaciotemporales organizados en tres categorías: parámetros temporales, espaciales y porcentuales de velocidad, para ambos grupos etarios: adultos jóvenes y adultos mayores: media, desviación estándar (DE), mediana, cuartiles Q1 y Q3, rango intercuartílico (IQR).

Tabla 14

Estadísticos descriptivos de los 24 biomarcadores espaciotemporales

Biomarcador	Jóvenes (n = 15)			Adultos mayores (n = 15)		
	Media $\pm$ DE	Mediana	[Q1 – Q3]	Media $\pm$ DE	Mediana	[Q1 – Q3]
Parámetros temporales (s)						
Right stride time	1,090 $\pm$ 0,0816	1,095	[1,050 – 1,128]	1,012 $\pm$ 0,084	1,032	[0,982 – 1,060]
Left stride time	1,104 $\pm$ 0,197	1,115	[1,060 – 1,136]	1,013 $\pm$ 0,075	1,031	[0,979 – 1,052]

Biomarcador	Jóvenes (n = 15)			Adultos mayores (n = 15)		
	Media $\pm$ DE	Mediana	[Q1 – Q3]	Media $\pm$ DE	Mediana	[Q1 – Q3]
Left step time	0,547 $\pm$ 0,041	0,559	[0,526 – 0,564]	0,509 $\pm$ 0,040	0,506	[0,482 – 0,530]
Right step time	0,540 $\pm$ 0,049	0,546	[0,521 – 0,575]	0,513 $\pm$ 0,029	0,518	[0,494 – 0,530]
Right stance time	0,512 $\pm$ 0,044	0,515	[0,503 – 0,536]	0,468 $\pm$ 0,042	0,468	[0,440 – 0,481]
Left stance time	0,523 $\pm$ 0,101	0,515	[0,473 – 0,534]	0,471 $\pm$ 0,035	0,465	[0,465 – 0,453]
Right swing time	0,590 $\pm$ 0,041	0,588	[0,575 – 0,616]	0,552 $\pm$ 0,035	0,559	[0,533 – 0,575]
Left swing time	0,609 $\pm$ 0,093	0,601	[0,579 – 0,623]	0,549 $\pm$ 0,041	0,550	[0,524 – 0,577]
Double support time	0,256 $\pm$ 0,039	0,259	[0,238 – 0,281]	0,237 $\pm$ 0,030	0,237	[0,220 – 0,254]
Single support time	0,833 $\pm$ 0,056	0,839	[0,795 – 0,863]	0,776 $\pm$ 0,064	0,794	[0,757 – 0,800]
Parámetros espaciales (cm)						
Right stride length	163,745 $\pm$ 20,9	159,845	[153,55 – 179,42]	161,431 $\pm$ 12,8	161,603	[156,06 – 172,13]
Left stride length	166,010 $\pm$ 32,9	163,805	[153,58 – 181,39]	161,697 $\pm$ 11,9	158,671	[155,50 – 171,99]
Right step length	82,247 $\pm$ 9,7	80,605	[75,10 – 88,16]	82,130 $\pm$ 4,72	82,175	[78,92 – 85,67]
Left step length	83,538 $\pm$ 8,5	81,036	[76,68 – 89,51]	81,452 $\pm$ 5,95	81,433	[78,26 – 85,18]
Right step width	7,279 $\pm$ 3,7	5,788	[4,36 – 10,37]	7,466 $\pm$ 4,02	7,161	[4,30 – 9,82]
Left step width	7,637 $\pm$ 4,2	5,756	[3,99 – 10,76]	7,703 $\pm$ 4,37	7,013	[4,23 – 9,00]
Parámetros porcentuales y de velocidad						
Right stride speed (m/s)	1,498 $\pm$ 0,25	1,444	[1,344 – 1,650]	1,585 $\pm$ 0,13	1,534	[1,496 – 1,691]
Left stride speed (m/s)	1,472 $\pm$ 0,30	1,439	[1,322 – 1,649]	1,588 $\pm$ 0,13	1,536	[1,485 – 1,688]
Right % stance	46,490 $\pm$ 1,2	46,799	[45,464 – 47,471]	45,873 $\pm$ 1,5	46,147	[45,090 – 46,723]
Left % stance	46,184 $\pm$ 1,2	46,222	[45,460 – 46,793]	46,268 $\pm$ 1,5	46,669	[45,300 – 47,086]
Right % swing	53,510 $\pm$ 1,2	53,201	[52,529 – 54,536]	54,127 $\pm$ 1,5	53,853	[53,277 – 54,910]
Left % swing	53,816 $\pm$ 1,2	53,778	[53,207 – 54,540]	53,732 $\pm$ 1,5	53,331	[52,914 – 54,700]
% double support	23,775 $\pm$ 2,7	23,895	[22,257 – 24,521]	24,064 $\pm$ 3,1	22,931	[22,277 – 25,642]
% single support	76,225 $\pm$ 2,7	76,105	[75,479 – 77,743]	75,936 $\pm$ 3,1	77,069	[74,358 – 77,723]

Nota. DE = desviación estándar; Q1 = primer cuartil; Q3 = tercer cuartil. Los valores de Mediana [Q1–Q3] se reportan para todos los biomarcadores dada la distribución no normal de un subconjunto de variables (verificada mediante prueba de Shapiro-Wilk, $p < 0.05$).

En los parámetros temporales, los adultos jóvenes presentan valores consistentemente superiores a los adultos mayores en la totalidad de las variables. Las diferencias más notorias a nivel descriptivo se observan en Right Stride Time (1,090 $\pm$ 0,082 s vs. 1,012 $\pm$ 0,084 s), Single Support Time (0,833 $\pm$ 0,056 s vs. 0,776 $\pm$ 0,064 s) y Right Stance Time (0,512 $\pm$ 0,044 s vs. 0,468 $\pm$ 0,042 s). Esta tendencia sugiere que los adultos jóvenes emplean más tiempo en cada fase del

ciclo de marcha, lo que es consistente con una cadencia más pausada y controlada en comparación con los adultos mayores.

En los parámetros espaciales, las diferencias entre grupos son visualmente menores. Las longitudes de zancada y paso son ligeramente superiores en jóvenes (*Right Stride Length*: $163,7 \pm 20,9$ cm vs. $161,4 \pm 12,8$ cm), aunque los rangos intercuartílicos se solapan considerablemente entre grupos, sugiriendo variabilidad intragrupo elevada. Los anchos de paso son prácticamente idénticos entre grupos (*Right Step Width*: $7,279 \pm 3,7$ cm vs. $7,466 \pm 4,02$ cm).

En los parámetros porcentuales y de velocidad, destaca que los adultos mayores presentan velocidades de zancada ligeramente superiores (*Right Stride Speed*: $1,585 \pm 0,13$ m/s vs. $1,498 \pm 0,25$ m/s), aunque con menor dispersión, indicando un patrón más homogéneo dentro del grupo. Los porcentajes de apoyo y balanceo son equivalentes entre grupos, con diferencias inferiores a 1% en todos los casos.

En conjunto, la inspección descriptiva sugiere que las diferencias entre grupos se concentran principalmente en la dimensión temporal del ciclo de marcha, mientras que los parámetros espaciales y porcentuales no muestran patrones diferenciadores evidentes. Esta hipótesis se contrasta formalmente en la sección 5.4 Estadística inferencial.

5.4 Estadística inferencial

5.4.1 Comparación estadística y tamaño del efecto

La Tabla 15 presenta los resultados de la prueba de Shapiro-Wilk aplicada a cada biomarcador por grupo, el p-valor y la prueba inferencial asignada según el cumplimiento del supuesto de normalidad.

Tabla 15*Resultados de la prueba de Shapiro-Wilk*

Biomarcador	Normalidad joven	Normalidad mayor	Homogeneidad	Prueba	P valor	Significativo	Hedges'g	Magnitud
Right Stance Time (s)	Normal	Normal	Homogéneo	t-test	0,00917	Si	0,994451	Grande
Right Swing Time (s)	Normal	Normal	Homogéneo	t-test	0,01206	Si	0,953749	Grande
Single Support Time (s)	Normal	Normal	Homogéneo	t-test	0,01439	Si	0,927134	Grande
Right Stride Time (s)	Normal	Normal	Homogéneo	t-test	0,01647	Si	0,906476	Grande
Left Step Time (s)	Normal	Normal	Homogéneo	t-test	0,01736	Si	0,898398	Grande
Left Swing Time (s)	No normal	Normal	No aplica	Mann-Whitney	0,01140	Si	0,810879	Grande
Left Stance Time (s)	No normal	Normal	No aplica	Mann-Whitney	0,05123	No	0,657577	Mediano
Right Step Time (s)	Normal	Normal	Homogéneo	t-test	0,07953	No	0,646462	Mediano
Left Stride Time (s)	No normal	Normal	No aplica	Mann-Whitney	0,02253	Si	0,594507	Mediano
Double Support Time (s)	Normal	Normal	Homogéneo	t-test	0,14969	No	0,526276	Mediano
Left Stride Speed (m/s)	Normal	Normal	Homogéneo	t-test	0,18680	No	-0,48078	Pequeño
Right Percentage Swing (%)	Normal	Normal	Homogéneo	t-test	0,22488	No	-0,44092	Pequeño
Right Percentage Stance (%)	Normal	Normal	Homogéneo	t-test	0,22488	No	0,440921	Pequeño
Right Stride Speed (m/s)	Normal	Normal	Homogéneo	t-test	0,26223	No	-0,40651	Pequeño
Left Step Length (cm)	Normal	Normal	Homogéneo	t-test	0,44573	No	0,274795	Pequeño
Left Stride Length (cm)	Normal	Normal	No homogéneo	Welch t-test	0,63945	No	0,169355	Trivial
Right Stride Length (cm)	Normal	Normal	Homogéneo	t-test	0,71776	No	0,129719	Trivial
Percentage Double Support (%)	Normal	Normal	Homogéneo	t-test	0,78730	No	-0,09678	Trivial

Biomarcador	Normalidad joven	Normalidad mayor	Homogeneidad	Prueba	P valor	Significativo	Hedges'g	Magnitud
Percentage Single Support (%)	Normal	Normal	Homogéneo	t-test	0,78730	No	0,096782	Trivial
Left Percentage Swing (%)	Normal	Normal	Homogéneo	t-test	0,86824	No	0,05948	Trivial
Left Percentage Stance (%)	Normal	Normal	Homogéneo	t-test	0,868246	No	-0,05948	Trivial
Right Step Width (cm)	No normal	Normal	No aplica	Mann-Whitney	0,933886	No	-0,0468	Trivial
Left Step Width (cm)	No normal	No normal	No aplica	Mann-Whitney	0,966915	No	-0,01492	Trivial
Right Step Length (cm)	Normal	Normal	No homogéneo	Welch t-test	0,967335	No	0,01473	Trivial

De los 24 biomarcadores analizados, 17 cumplieron el supuesto de normalidad en ambos grupos (Shapiro-Wilk, $p > 0.05$). De estos, 15 presentaron homogeneidad de varianzas (Levene, $p > 0.05$), aplicándose t-test de Student, mientras que 2 (Left Stride Length y Right Step Length) mostraron varianzas heterogéneas, por lo que se aplicó Welch t-test. Los 7 biomarcadores restantes no cumplieron el supuesto de normalidad en al menos un grupo, empleándose Mann-Whitney U.

Se identificaron 7 biomarcadores con diferencias significativas ($p < 0.05$) entre adultos jóvenes y mayores, todos correspondientes a parámetros temporales


El tamaño del efecto se estimó mediante Hedges' g para todos los biomarcadores. Los 7 biomarcadores significativos presentaron efectos grandes ($g \geq 0.595$), confirmando relevancia práctica además de estadística.

5.4.2 Tamaño del efecto

La Figura 19 presenta el tamaño del efecto (Hedges g) de los 24 biomarcadores analizados, ordenados de mayor a menor magnitud. Las barras azules corresponden a los biomarcadores con diferencia estadísticamente significativa.

Figura 19

Tamaño del efecto (Hedges g) de los 24 biomarcadores analizados



Se evidencia que *Left Stance Time* ($g = 0.658$) y *Right Step Time* ($g = 0.646$) presentan tamaños de efecto de magnitud mediana (superiores incluso a *Left Stride Time*, que sí resultó significativo ($g = 0.595$)) sin alcanzar significancia estadística. Esto indica que la prueba de hipótesis tiene potencia estadística limitada, por lo que un efecto de magnitud relevante puede no traducirse en un p-valor significativo. Esto refuerza la necesidad de reportar el tamaño del efecto como complemento obligatorio al valor p, y no como un dato secundario.

Adicionalmente, se observa que la totalidad de los biomarcadores significativos corresponde a parámetros temporales del ciclo de marcha. Ningún parámetro espacial ni porcentual alcanzó siquiera un efecto de magnitud mediana, lo que sugiere que, en esta muestra, el


envejecimiento se expresa de forma más marcada en la dimensión temporal de la marcha que en su componente espacial.

5.4.3 Distribución de biomarcadores significativos

A continuación, en la Figura 20, se presentan los box plots de los siete biomarcadores con diferencia estadísticamente significativa entre grupos ($p < 0.05$), anotados con el p-valor y el tamaño del efecto correspondiente.

Figura 20

Distribución de biomarcados significativos por grupo etario



En los siete biomarcadores se observa un patrón consistente: la mediana del grupo joven se ubica por encima de la mediana del grupo mayor, sin superposición entre cajas en la mayoría de los casos, lo que confirma visualmente las diferencias detectadas por el análisis inferencial.

Right Stance Time muestra la separación más clara entre grupos, con cajas prácticamente sin superposición ($g = 0.99$), mientras que *Left Stride Time* presenta la mayor superposición entre distribuciones, consistente con su menor tamaño de efecto ($g = 0.59$).

La dispersión también difiere entre grupos: el grupo mayor presenta cajas más amplias en *Right Stance Time*, *Right Swing Time* y *Single Support Time*, lo que indica mayor heterogeneidad en estas fases del ciclo de marcha, un hallazgo consistente con la literatura sobre variabilidad de la marcha en el envejecimiento. En contraste, el grupo joven muestra mayor dispersión en *Left Swing Time*, atribuible a un valor atípico extremo (≈ 0.90 s) que se aleja considerablemente del resto de la distribución.

Se identifican valores atípicos (círculos sin relleno) en ambos grupos, principalmente en *Right Stance Time*, *Single Support Time*, *Right Stride Time* y *Left Stride Time*, concentrados mayoritariamente en los extremos inferiores del grupo joven y superiores del grupo mayor. La presencia de estos casos no afecta la tendencia general observada, pero señala sujetos cuyo patrón de marcha se aparta del comportamiento típico de su grupo etario.

5.5 Resultados del modelo de aprendizaje automático

5.5.1 Selección de variables (features) para el modelo

A partir del análisis inferencial presentado en la sección 5.4 Estadística inferencial, se seleccionaron como variables de entrada al modelo de clasificación los siete biomarcadores que cumplieron simultáneamente los criterios de significancia estadística ($p < 0.05$) y tamaño de efecto mínimo mediano (Hedges $g \geq 0.595$)-


De los 24 biomarcadores evaluados, los siete seleccionados corresponden exclusivamente a parámetros temporales del ciclo de marcha, confirmando lo observado en el análisis descriptivo e inferencial: ninguna variable espacial ni porcentual alcanzó el umbral de selección. Seis de los

siete biomarcadores presentan un tamaño de efecto de magnitud grande ($g \geq 0.811$), siendo *Right Stance Time* el de mayor magnitud ($g = 0.994$) y *Left Stride Time* el único de magnitud mediana ($g = 0.595$).

La matriz de entrada resultante tiene dimensión $\mathbf{X} = (30, 7)$, correspondiente a 30 sujetos y 7 biomarcadores, con la variable objetivo-codificada de forma binaria: 15 adultos jóvenes (0) y 15 adultos mayores (1), manteniendo el balance perfecto entre clases.

5.5.2 Visualización PCA

Previo al entrenamiento de los modelos de clasificación, se realizó un Análisis de Componentes Principales (PCA) sobre la matriz estandarizada de los siete biomarcadores seleccionados, con el fin de visualizar la separabilidad de los grupos en un espacio reducido de dos dimensiones. La Figura 21 presenta la proyección de los 30 sujetos sobre los dos primeros componentes principales.

Figura 21*Espacio de biomarcadores*

El primer componente principal (PC1) explica el 79.0% de la varianza total y el segundo (PC2) un 14.4% adicional, acumulando entre ambos el 93.4% de la varianza, lo que indica que la estructura de los siete biomarcadores se concentra mayoritariamente en una sola dimensión latente.

A pesar de esta alta concentración de varianza, la inspección visual del gráfico no muestra una separación clara entre grupos. Los sujetos jóvenes (azul) y mayores (rojo) se distribuyen de forma considerablemente entremezclada a lo largo del eje PC1, particularmente en la región central (PC1 entre -2 y 2), donde ambos grupos comparten el mismo espacio. Se identifican algunos sujetos jóvenes en posiciones extremas —S015 ($PC2 \approx 4.5$) y S067 ($PC2 \approx -2.8$)— que se alejan considerablemente del resto de su grupo, mientras que en el extremo izquierdo ($PC1 < -3$) se observa una agrupación mixta de sujetos de ambos grupos con valores muy similares entre sí.

Esta ausencia de separación visual clara en el espacio de dos componentes anticipa un desempeño moderado, si los grupos fueran linealmente separables en este espacio reducido, se esperaría un desempeño de clasificación considerablemente superior. El resultado sugiere que la diferenciación entre adultos jóvenes y adultos mayores, no se traduce en una frontera de decisión simple cuando los biomarcadores se consideran de forma conjunta, lo que respalda el uso de clasificadores no lineales como SVM (RBF) y Random Forest sobre modelos lineales.

5.5.3 Clasificación con *Leave-One-Subject-Out (LOSO)*

Se aplicó validación cruzada *Leave-One-Subject-Out* sobre la matriz de entrada (30 sujetos $\times$ 7 biomarcadores). En cada una de las 30 iteraciones, un sujeto fue utilizado como conjunto de prueba y los 29 restantes como entrenamiento, garantizando que ningún modelo evaluara datos previamente vistos durante su ajuste. El procedimiento generó un conjunto de 30 predicciones independientes por clasificador, sobre las cuales se calcularon las métricas de desempeño reportadas a continuación.

5.5.4 Desempeño comparativo de los clasificadores

Se presenta el desempeño de los tres clasificadores evaluados, medido mediante exactitud (*Accuracy*), F1-Score y AUC-ROC en la Tabla 16.

Tabla 16

Resumen de los tres clasificadores evaluados

Clasificador	Accuracy	F1-Score	AUC-ROC
Regresión Logística	0.667	0.667	0.676
SVM (RBF)	0.767	0.774	0.689
Random Forest	0.733	0.733	0.707

Random Forest obtuvo el mayor AUC-ROC (0.707), siendo seleccionado como el mejor modelo conforme al criterio definido en la sección 3.9.7. Cabe destacar que SVM (RBF) presentó

la mayor exactitud y F1-Score (0.767 y 0.774, respectivamente), pero un AUC-ROC inferior (0.689) al de Random Forest, lo que evidencia que un modelo puede clasificar correctamente una mayor proporción de casos sin necesariamente tener el mejor poder discriminativo global a través de todos los umbrales de decisión. Esta discrepancia confirma la pertinencia de haber adoptado el AUC-ROC —y no la exactitud— como criterio primario de selección.


En conjunto, los tres modelos superaron el desempeño de un clasificador aleatorio ($AUC = 0.5$), aunque ninguno alcanzó valores de AUC superiores a 0.75, lo que sugiere una capacidad discriminativa moderada entre adultos jóvenes y adultos mayores a partir exclusivamente de los siete biomarcadores temporales seleccionados.

5.5.5 Matrices de confusión

La Figura 22 presenta las matrices de confusión de los tres clasificadores evaluados, construidas a partir de las 30 predicciones independientes generadas por la validación LOSO.

Figura 22

Matrices de confusión



Regresión Logística clasificó correctamente 10 de 15 jóvenes y 10 de 15 adultos mayores, con un error simétrico de 5 sujetos mal clasificados en cada clase (5 jóvenes confundidos como

mayores y 5 mayores confundidos como jóvenes). SVM (RBF) obtuvo el mejor balance de aciertos: clasificó correctamente 11 jóvenes y 12 adultos mayores, con solo 4 y 3 errores respectivamente, siendo el modelo con menor número total de errores (7 de 30 sujetos). Random Forest presentó un desempeño intermedio en error absoluto, acertando 11 jóvenes y 11 adultos mayores, con 4 errores en cada clase (8 de 30 sujetos en total).

Un hallazgo relevante es que ningún modelo muestra sesgo marcado hacia una clase los errores se distribuyen de forma relativamente simétrica entre falsos jóvenes y falsos mayores en los tres clasificadores. Esto indica que el diseño balanceado de la muestra (15/15) cumplió su propósito de evitar que los modelos favorecieran sistemáticamente una clase sobre otra, y que las confusiones observadas responden a la dificultad intrínseca de la tarea —ya anticipada en la sección 4.5.2 mediante la visualización PCA— y no a un artefacto del balance de clases.


Resulta también informativo que SVM, a pesar de tener el menor número de errores absolutos (7), no fue el modelo con mejor AUC-ROC (0.689 vs. 0.707 de Random Forest). Esto reafirma lo señalado en la sección 5.5.4 Desempeño comparativo de los clasificadores el número de aciertos en un único umbral de decisión no necesariamente refleja el mejor poder discriminativo del modelo a través de todos los umbrales posibles, justificando nuevamente la elección de Random Forest como modelo final mediante el criterio AUC-ROC.

5.5.6 Curvas ROC por clasificador

A continuación, se muestran las curvas ROC (*Receiver Operating Characteristic*) de los tres clasificadores evaluados, construidas a partir de las probabilidades predichas en la validación LOSO en la Figura 23.

Figura 23

Curvas ROC (Receiver Operating Characteristic) de los tres clasificadores evaluados



Las tres curvas se ubican por encima de la línea de referencia aleatoria ($AUC = 0.500$) a lo largo de la mayor parte del espacio de umbrales, confirmando que los tres modelos poseen capacidad discriminativa superior al azar. Random Forest ($AUC = 0.707$) muestra el mejor desempeño global, alcanzando una sensibilidad de 0.87 con una tasa de falsos positivos de apenas 0.27, lo que indica que logra detectar a la mayoría de los adultos mayores manteniendo una tasa de error relativamente baja en ese rango de umbral. SVM ($AUC = 0.689$) presenta un comportamiento intermedio, mientras que Regresión Logística ($AUC = 0.676$) muestra el desempeño más bajo de los tres, con una curva que se aproxima más a la diagonal de azar en los umbrales bajos ($FPR < 0.2$), donde su sensibilidad apenas alcanza 0.20.

Es relevante notar que las tres curvas convergen hacia un punto común en la región de umbrales altos ($FPR \approx 0.93-1.0$, sensibilidad $\approx 0.93-1.0$), lo que es esperable dado que, en el límite, todo clasificador alcanza sensibilidad perfecta al clasificar todos los casos como positivos.

La diferencia real entre modelos se concentra en la región intermedia de la curva (FPR entre 0.2 y 0.4), donde Random Forest mantiene consistentemente la mayor sensibilidad para una misma tasa de falsos positivos, razón por la cual fue seleccionado como modelo final.

En conjunto, la forma escalonada e irregular de las tres curvas (característica de conjuntos de prueba pequeños como el de este estudio ($n = 30$)) y la magnitud moderada de los AUC obtenidos (0.676–0.707) son consistentes con la ausencia de separación clara observada en el análisis PCA (sección 4.5.2), confirmando que la clasificación entre adultos jóvenes y adultos mayores, aunque posible por encima del azar, no constituye una tarea de fácil resolución con los biomarcadores temporales disponibles.

5.5.7 Reporte detallado del mejor clasificador

Random Forest fue seleccionado como modelo final por presentar el mayor AUC-ROC (0.707) entre los tres clasificadores evaluados. La Tabla 17 presenta el reporte de clasificación completo, con precisión, *recall* (sensibilidad) y F1-score discriminados por clase.

Tabla 17

Clasificación por clase, precisión, Recall y F1-Score

Clase	Precisión	Recall	F1-Score	n
Joven (0)	0.733	0.733	0.733	15
Mayor (1)	0.733	0.733	0.733	15

El modelo presenta un desempeño idéntico y simétrico en ambas clases (precisión, recall y $F1 = 0.733$ para jóvenes y mayores), lo que indica que no existe sesgo hacia ninguno de los dos grupos: el clasificador tiene la misma capacidad para identificar correctamente a un adulto joven que a un adulto mayor. Esta simetría es consistente con el diseño balanceado de la muestra (15/15) y confirma que el desempeño moderado del modelo (73.3% de exactitud) refleja la dificultad real de la tarea, y no un artefacto de desbalance entre clases.

De los 30 sujetos evaluados, 8 fueron clasificados incorrectamente (26.7%), distribuidos de forma equilibrada entre ambas direcciones de error: 4 adultos jóvenes fueron clasificados como mayores (S007, S008, S016, S018) y 4 adultos mayores fueron clasificados como jóvenes (S109, S158, S142, S143).

El equilibrio en la distribución de errores (4 y 4) refuerza la ausencia de sesgo direccional ya observada en la matriz de confusión sección 5.5.5 Matrices de confusión. Es relevante notar que los cuatro jóvenes mal clasificados (S007, S008, S016, S018) presentan un patrón de marcha que el modelo interpreta como característico de un adulto mayor, lo que podría sugerir biomecánicamente que estos sujetos exhiben parámetros temporales de marcha más conservadores o pausados de lo típico para su grupo etario.

5.6 Biomarcadores más relevantes para la clasificación

Esta sección integra los resultados del análisis estadístico sección 5.4 Estadística inferencial y de modelo de aprendizaje automático sección 5.5 Resultados del modelo de aprendizaje automático, con el propósito de identificar cuáles biomarcadores espaciotemporales son más relevantes para diferenciar a los adultos jóvenes de los adultos mayores. Para ello se presenta la importancia de variables del clasificador *Random Forest* junto con los tamaños del efecto estadístico, construyendo una visión conjunta de los biomarcadores más discriminantes.

El resultado más destacado es que los 7 biomarcadores significativos son exclusivamente temporales: ningún parámetro espacial, porcentual o de velocidad alcanzó significancia estadística. Eso indica que las diferencias entre grupos se evidencian en el ritmo del ciclo de la marcha, no en distancias recorridas.

5.6.1 Biomarcadores más importantes para la clasificación

En los 7 biomarcadores significativos, los adultos jóvenes presentaron valores superiores respecto a los adultos mayores. La Tabla 18 resume la diferencia de estrategia locomotora entre grupos.

Tabla 18

Comparación de estrategias locomotoras entre grupos basada en biomarcadores discriminantes

Dimensión	Adultos jóvenes (G01)	Adultos mayores (G03)
Duración del ciclo	Ciclos más largos	Ciclos más cortos
Apoyo unilateral	Mayor tiempo apoyo simple	Menor tiempo sin apoyo bilateral
Balanceo	Fase de balanceo más prolongada	Balance reducido
Resultado global	Pocos pasos largos	Pasos cortos y frecuentes

Ningún parámetro espacial resultó significativo ni fue seleccionado por el modelo. Las longitudes de zancada presentaron efectos intrascendentes, confirmando que las diferencias entre grupos son exclusivamente temporales en esta muestra. Este hallazgo contrasta con estudios que reportan reducción de la longitud de zancada con el envejecimiento (Murray, et al., 1969).

5.6.2 Comparación entre métodos de evaluación de importancia

La importancia de variables fue evaluada mediante dos métodos: la importancia Gini y la importancia de permutación. La Tabla 19 presenta los valores y rangos obtenidos por ambos métodos para los 7 biomarcadores del modelo.


Tabla 19

Comparación de importancia Gini e importancia de permutación por biomarcador

Biomarcador	Imp. Gini	Rango Gini	Imp. Permut	Rango Permut.	Diferencia de rangos
Left Step Time (s)	0.1402	#3	0.0211	#1	2
Right Stride Time (s)	0.1131	#6	0.0178	#2	4
Right Swing Time (s)	0.1184	#5	0.0133	#3	2
Left Stride Time (s)	0.1237	#4	0.0133	#3	1
Single Support Time (s)	0.1036	#7	0.0078	#5	2
Right Stance Time (s)	0.2355	#1	0.0044	#6	5
Left Swing Time (s)	0.1655	#2	-0.002	#7	5

Para cinco de los siete biomarcadores, ambos métodos asignaron rangos similares (diferencia ≤ 2). Las discrepancias mayores se observaron en Right Stance Time (rango Gini #1, rango permutación #6) y Left Swing Time (rango Gini #2, rango permutación #7).

La Figura 24 presenta la importancia de variables del clasificador Random Forest cuantificada por ambos métodos. El panel izquierdo muestra la importancia de permutación ordenada de mayor a menor, donde Left Step Time ocupa el primer rango (0.021) y Left Swing Time presenta un valor negativo (-0.002). El panel derecho muestra la importancia Gino, donde el orden es notablemente diferente: Right Stance Time ocupa el primer rango (0.235) pese a ocupar el sexto lugar en permutación y Left Swing Time ocupa el segundo lugar Gino pese a su valor de permutación negativa.

Figura 24*Importancia de biomarcadores para la clasificación*

6. Discusión

6.1 Biomarcadores significativos

El hallazgo más importante de este estudio son las diferencias significativas entre adultos jóvenes y adultos mayores, por ello, se encontró que entre adultos jóvenes y adultos mayores se concentraron exclusivamente en parámetros temporales del ciclo de marcha, sin ningún parámetro espacial alcanzara significancia estadística. Los siete biomarcadores significativos fueron Right Stride Time, Left Stride Time, Right Step Time, Left Step Time, Right Stance Time, Right Swing Time, Left Swing Time y Single Support Time, correspondientes a medidas de duración de fases del ciclo locomotor.

Este resultado es coherente con los hallazgos de Hollman et al. (2011), quienes en una muestra normativa de 294 adultos mayores encontraron que los parámetros del dominio *rhythm* (caracterizados por la cadencia y los tiempos de fase) diferían significativamente entre grupos de edad, mientras que los parámetros del dominio *pace* (velocidad y longitud de zancada) mostraban mayor variabilidad entre estudios. Asimismo, las revisiones sistemáticas sobre parámetros espaciotemporales a lo largo del ciclo de vida señalan que los adultos mayores exhiben una marcha más cuidadosa, con reducción de la velocidad preferida, la cadencia y las longitudes de paso y zancada, aunque el grado de estas diferencias varía notablemente según el estado funcional de los participantes.

La comparación entre los modelos de evaluación de importancia de variables (Figura 25) revela que la importancia de Gino y la importancia de permutación asignan órdenes significativamente distintos a varios biomarcadores del modelo. Esta divergencia no representa una inconsistencia en el análisis, sino que refleja una propiedad conocida de la importancia Gino:

si tendencia a sobre estimar la contribución de variables correlacionadas con otras presentes en el modelo (Strobel et al., 2008). En el caso de Right Stance Time (con 0.235 Gini, 0.004 Importancia Permutación) su información discriminante es recuperada por Right Stride Time y Right Swing Time cuando se elimina, dado que estos tres parámetros guardan una relación de complementariedad matemática directa. Un resultado aún más ilustrativo es el de Left Swing Time, cuya importancia de permutación negativo (-0.002) y elevada desviación estándar entre folds LOSO indican que su eliminación no deteriora el rendimiento de clasificador. Este hallazgo evidencia que la significancia estadística individual no garantiza la utilidad dentro de un modelo con múltiples variables: un biomarcador puede discriminar bien entre grupos de forma aislada y resultar redundante en presencia de variables correlacionadas. Por el contrario, Left Step Time combinó la mayor importancia de permutación (0.021 ± 0.016), alta estabilidad entre folds y efecto estadístico grande ($g = 0.898$), confirmándose como el discriminador más confiable del modelo.

6.1.1 Reducción del tiempo de apoyo unilateral

La diferencia observada en Single Support Time (jóvenes: 0.833 ± 0.056 s vs. mayores: 0.776 ± 0.065 s, $g = 0.927$) coincide con lo documentado por Perry y Burnfield (2010), quienes describen la reducción del apoyo unilateral como una de las adaptaciones locomotoras más consistentes del envejecimiento. Un menor tiempo de apoyo simple refleja una reducción de la capacidad de mantenimiento del equilibrio sobre un solo pie, fenómeno asociado al deterioro del control postural y la fuerza muscular del miembro inferior con la edad (Murray et al., 1969).

6.1.2 Reducción del tiempo de balanceo

Los menores tiempos de balanceo en adultos mayores (Right Swing Time: 0.552 ± 0.035 s vs. 0.590 ± 0.041 s en jóvenes; Left Swing Time: 0.549 ± 0.041 s vs. 0.609 ± 0.094 s) son consistentes con la literatura. Una fase de balanceo más corta en adultos mayores constituye una

estrategia adaptativa para minimizar el período en que el pie no tiene contacto con el suelo, reduciendo así el riesgo de tropiezos y caídas (Maki, 1997; Perry y Burnfield, 2010). Este patrón ha sido reportado sistemáticamente en estudios que comparan poblaciones jóvenes y mayores caminando a velocidad auto percibida (Murray et al., 1969; Boyer et al., 2017).

6.1.3 Reducción del tiempo de ciclo

La menor duración del ciclo completo en adultos mayores (Right Stride Time: 1.032 ± 0.085 s vs. 1.089 ± 0.082 s) implica mayor cadencia relativa, lo que es coherente con estudios que documentan que, al mantener velocidades similares con zancadas más cortas, los adultos mayores adoptan un ritmo de paso más frecuente (Herssens et al., 2018; Hollman et al., 2011). Estudios longitudinales con IMU en adultos mayores confirman que el tiempo de zancada se asocia con la edad y tiende a deteriorarse progresivamente, con diferencias apreciables entre hombres y mujeres (Weiss et al., 2022).

6.1.4 Ausencia de diferencia en parámetros espaciales

La literatura biomecánica documenta consistentemente la reducción de la longitud de zancada con el envejecimiento como uno de los marcadores espaciales más robustos (Murray et al., 1969; Whittle, 2007). Sin embargo, en el presente estudio ningún parámetro espacial resultó significativo: las longitudes de zancada derecha e izquierda presentaron tamaños del efecto Trivial ($g < 0.17$), y las longitudes de paso e izquierdo apenas alcanzaron efecto Pequeño ($g = 0.275$). Esta discrepancia puede atribuirse a tres factores:

- **Perfil funcional de la muestra.** Los adultos mayores de la base de datos GaitPrint fueron reclutados como individuos sanos, cognitivamente preservados (MMSE > 24) y funcionalmente independientes, capaces de completar el Timed Up and Go entre 5 y 15 segundos (Wiles et al., 2025). Este perfil representa el segmento más funcional del

envejecimiento saludable, en el que la preservación de la amplitud de zancada es esperable.

La reducción de la longitud de zancada es un marcador de envejecimiento avanzado o funcional, no necesariamente del envejecimiento saludable (Herssens et al., 2018).

- Condición de velocidad libre. El protocolo GaitPrint registró la marcha a velocidad autopercebida y cómoda sobre una pista de 200 metros. Cuando se permite a los sujetos seleccionar su propio ritmo, las diferencias en longitud de zancada entre grupos etarios tienden a reducirse respecto a lo observado en protocolos de velocidad controlada (Boyer et al., 2017). Los adultos mayores pueden seleccionar inconscientemente una velocidad que aún les permite mantener su longitud de zancada habitual.

6.1.5 Ausencia de diferencias en el tiempo de doble apoyo

El tiempo de doble apoyo es reportado clásicamente como el parámetro temporal más sensible al envejecimiento, con incrementos documentados del 20 % al 26 % o más del ciclo (Murray et al., 1969; Perry y Burnfield, 2010). Sin embargo, en este estudio el tiempo de doble apoyo no resultó significativo ($p = 0.150$, $g = 0.526$, efecto Mediano), y los valores entre grupos fueron similares (jóvenes: 0.258 ± 0.039 s; mayores: 0.237 ± 0.031 s).

Este resultado es llamativo pero consistente con los hallazgos de Wiles et al. (2025), quienes en la validación técnica de la propia base de datos GaitPrint reportaron solo evidencia moderada de diferencias en la fase de movimiento entre grupos etarios para varios parámetros de coordinación. El perfil de alta funcionalidad de los adultos mayores de GaitPrint podría explicar la preservación del doble apoyo en valores similares a los de adultos jóvenes: la necesidad de ampliar el doble apoyo surge como compensación ante déficits de control postural que este grupo aún no manifiesta de forma significativa.

6.1.6 Ausencia de diferencias en velocidad de marcha

La literatura reporta que la velocidad de marcha auto percibida disminuye progresivamente con la edad (Whittle, 2007; Herssens et al., 2018). Sin embargo, en el presente estudio los adultos mayores presentaron velocidades de zancada ligeramente superiores a los jóvenes (Left Stride Speed: 1.578 ± 0.137 m/s vs. 1.479 ± 0.303 m/s), aunque la diferencia no fue estadísticamente significativa ($g = -0.480$). Esta aparente inversión puede explicarse por la compensación entre parámetros: los adultos mayores de la muestra adoptaron ciclos más cortos (menor tiempo de zancada) que, combinados con una longitud de zancada similar, resultan en velocidades equivalentes o ligeramente superiores en términos numéricos. La alta variabilidad en la velocidad del grupo joven ($DE = 0.303$ m/s vs. 0.137 m/s en mayores) también contribuye a la falta de significancia.

La Tabla 20 sintetiza los principales hallazgos del estudio en relación con los valores normativos y tendencias reportados en la literatura de referencia.

Tabla 20

Comparación de los hallazgos del estudio con la literatura de referencia

Parámetro	Estudio	Literatura	Validación
Parámetros temporales (apoyo, balanceo, zancada)	Jóvenes > Mayores. En 6/7 casos, diferencias significativas.	Diferencias consistentes en todos los estudios (Murray et al., 1969; Boyer et al., 2017)	Dirección y magnitud coherentes con envejecimiento saludable.
Single Support Time	Jóvenes: 0.833 s vs Mayores: 0.776 s ($g = 0.927$).	Reducción documentada con envejecimiento (Perry y Burnfield, 2010; Hollman et al., 2011)	Reflejo de menor capacidad de apoyo unilateral en mayores.

Longitud de Zancada	Sin diferencia significativa ($g < 0.17$)	Reducción esperada con envejecimiento (Murray et al., 1969; White, 2007)	Existe una discrepancia explicada por perfil funcional sano y velocidad libre.
Tiempo de doble apoyo	Sin diferencia significativa ($p = 0.150$, $g = 0.256$)	Aumento clásicamente documentado (Murray et al., 1969; Perry y Burnfield, 2010)	Adultos mayores de alta funcionalidad preservan doble apoyo.
Velocidad de marcha	Sin diferencia significativa entre grupos.	Reducción esperada con envejecimiento (Herssens et al., 2018).	Compensación entre tiempo y longitud de zancada.

Los resultados del presente estudio son consistentes con la hipótesis de que el envejecimiento locomotor en adultos funcionalmente sanos se manifiesta primero en la dimensión temporal de la marcha (tiempos de fase, ritmo del ciclo, duración del apoyo unilateral) antes de afectar la dimensión espacial (longitudes de paso y zancada). Esta jerarquía temporal-espacial de la degradación locomotora ha sido sugerida por estudios longitudinales (Herssens et al., 2018) y es coherente con la idea de que los adultos mayores sanos adoptan estrategias compensatorias, es decir, ciclos más breves y frecuentes, que conserva la velocidad y la amplitud de zancada a expensas de una reorganización del ritmo temporal del ciclo.

Este patrón tiene relevancia clínica, en poblaciones de adultos mayores funcionalmente independientes, la monitorización de los parámetros temporales mediante sistemas de IMU portátiles podría detectar el inicio de la degradación de la funcionalidad locomotora antes de que las alteraciones espaciales se manifiesten. Left Step Time resultó ser el biomarcador individual más discriminantes en el modelo de clasificación (importancia de permutación = 0.0211), un

descubrimiento que refuerza la utilidad de los parámetros de timing del paso como indicadores de envejecimiento en marcha.

6.2 Discusión biomecánica del envejecimiento

Durante el ciclo de marcha existen dos fases con demandas de control completamente distintas. En la fase de doble apoyo, ambos pies están en contacto con el suelo: el sistema musculoesquelético dispone de dos puntos de restricción sobre los cuales distribuir la carga y las correcciones posturales. En la fase de apoyo simple, ese equilibrio depende exclusivamente del miembro de soporte. Es el intervalo más exigente del ciclo locomotor y, también, el que diferencia más claramente a los dos grupos en este estudio.

Los adultos mayores presentaron un tiempo de apoyo simple significativamente menor que los adultos jóvenes (0.776 ± 0.065 s vs 0.833 ± 0.056 s, $g = 0.927$). Desde el punto de vista biomecánico, esta reducción no representa una degradación del patrón locomotor, sino una adaptación intencional; al acortar el intervalo de apoyo unilateral, el sistema locomotor del adulto mayor disminuye su tiempo de exposición a la condición de mayor demanda. Si la capacidad de mantener el equilibrio sobre un solo pie se deteriora con la edad, la respuesta más eficiente es reducir el tiempo que se permanece en esa condición.

Perry y Burnfield (2010) describen la reducción del tiempo de apoyo simple como uno de los indicadores más consistentes del envejecimiento locomotor funcional. Maki (1997) la asocia directamente a estrategias compensatorias que adaptan los adultos mayores en respuesta a su falta de control postural unilateral, incluso en ausencia de patología. Este comportamiento se denomina en la literatura *marcha cautelosa* y es exactamente el patrón que los datos del presente estudio reflejan.

Los tiempos de balanceo bilaterales resultaron significativamente menores en los adultos mayores (Right Swing Time: 0.552 ± 0.035 s vs. 0.590 ± 0.041 s en jóvenes, $g = 0.954$; Left Swing Time: 0.549 ± 0.041 s vs. 0.609 ± 0.094 s, $g = 0.811$). El Right Swing Time fue el tercer biomarcador más importante para el clasificador (importancia de permutación = 0.0133), reflejando que la duración del balanceo derecho es especialmente informativa para distinguir entre grupos.

El presente estudio documenta exactamente ese patrón. Los adultos mayores no caminaron más despacio: las velocidades de zancada no difirieron significativamente entre grupos (Left Stride Speed: 1.578 ± 0.137 m/s en mayores vs. 1.479 ± 0.303 m/s en jóvenes). Tampoco recorrieron distancias menores por paso: ningún parámetro espacial resultó estadísticamente significativo. Lo que cambió fue la distribución temporal interna del ciclo: ciclos más breves y frecuentes, con menos tiempo en las fases de mayor demanda unilateral (apoyo simple y balanceo) y velocidad global preservada.

6.3 Análisis de modelos de aprendizaje automático

6.3.1 Mejor desempeño

Random Forest fue el clasificador con mejor desempeño global (AUC-ROC = 0.707), superando a SVM (RBF) (0.689) y Regresión Logística (0.676). Aunque SVM presentó mayor exactitud y F1-Score en un único umbral de decisión (0.767 y 0.774, respectivamente), Random Forest mostró mejor capacidad discriminativa a través de todos los umbrales posibles, lo cual lo hace el indicador más robusto.

La superioridad de Random Forest es consistente con dos características de los datos. Por un lado, los siete biomarcadores temporales están correlacionados entre sí (comparten información cinemática), y Random Forest maneja esta condición de forma natural al construir cada árbol sobre

subconjuntos aleatorios de variables, evitando la dependencia excesiva en variables redundantes (Breiman, 2001). Por otro lado, el análisis PCA (sección 4.5.2) mostró que los grupos no son linealmente separables en el espacio de biomarcadores; Regresión Logística, al limitarse a trazar fronteras de decisión lineales, no pudo capturar la estructura real de los datos, lo que explica su desempeño inferior frente a los modelos no lineales.

6.3.2 Aplicabilidad del modelo

El desempeño obtenido ($AUC = 0.707$, exactitud = 0.733) se ubica en un rango que la literatura clasifica como discriminación aceptable, pero no excelente (Hosmer et al., 2013): el modelo distingue grupos por encima del azar de forma consistente, pero está aún no puede constituir una herramienta de clasificación individual confiable. Esta limitación queda evidenciada en que 8 de los 30 sujetos (26.7%) fueron clasificados incorrectamente, una tasa de error que en un contexto clínico real resultaría inaceptable para la toma de decisiones diagnósticas sin supervisión humana adicional.

El rendimiento alcanzado debe interpretarse como exploratorio y no como aplicable clínicamente en su estado actual. El tamaño muestral ($n = 30$) es no es suficiente para garantizar la generalización del modelo a poblaciones más amplias y heterogéneas, condición reconocida como crítica en la literatura de aprendizaje automático aplicado a biomecánica (Halilaj et al., 2018). La validación LOSO, aunque metodológicamente apropiada para muestras pequeñas, no reemplaza la validación externa con una cohorte independiente. El modelo se entrenó exclusivamente con parámetros temporales, dejando fuera variables espaciales y cinemáticas que podrían aportar información complementaria y mejorar el desempeño.

6.3.3 Implicaciones clínicas

A pesar de estas limitaciones, los hallazgos tienen valor como prueba de concepto. El hecho de que un conjunto reducido de solo siete biomarcadores temporales, obtenidos mediante sensores inerciales portátiles logre una discriminación superior al azar entre grupos etarios respalda la viabilidad de los IMU como herramienta para el monitoreo del envejecimiento en contextos comunitarios o de atención primaria (Tran et al., 2021). La aplicabilidad real requeriría validación en muestras más amplias, la incorporación de variables adicionales y, fundamentalmente, una recalibración del umbral de decisión según el contexto clínico específico, priorizando sensibilidad sobre especificidad si el objetivo fuera la detección temprana de patrones de envejecimiento atípico.

6.4 Integración de lo cuantitativo y lo cualitativo

Los hallazgos de este estudio convergen en una misma dirección: el análisis estadístico inferencial, el modelo de clasificación automática y la evidencia biomecánica de la literatura. Esta sección integra perspectivas asociadas al diseño explicativo secuencial adoptado (Creswell, 2014), en el que los resultados cuantitativos orientan la interpretación cualitativa final.

El análisis inferencial (sección 5.4 Estadística inferencial) identificó siete biomarcadores significativamente diferentes entre grupos, todos correspondientes a parámetros temporales del ciclo de marcha. Esta misma jerarquía se reprodujo en el modelo de clasificación: los siete biomarcadores utilizados como variables de entrada (sección 5.5.1 Selección de variables (features) para el modelo) fueron exactamente los identificados como estadísticamente significativos, y el modelo ganador (Random Forest) logró una discriminación superior al azar ($AUC = 0.707$) utilizando únicamente esta información temporal: Esto identifica que el

envejecimiento se manifiesta principalmente en la dimensión temporal de la marcha, no en su componente espacial, al menos en la muestra y biomarcadores analizados.

Sin embargo, la integración también reveló una limitación relevante: a pesar de que los siete biomarcadores son individualmente discriminantes, su combinación en el espacio multivariado (PCA, sección 5.5.2 Visualización PCA) no mostró una separación clara entre grupos. Esto sugiere que las diferencias relacionadas con la edad, aunque son estadísticamente detectables variable por variable, se expresan como un desplazamiento gradual de distribuciones que se superponen parcialmente, más que como categorías claramente separables.

Esta interpretación es coherente con el patrón observado en los sujetos mal clasificados (sección 5.5.7 Reporte detallado del mejor clasificador): los adultos mayores confundidos con jóvenes podrían corresponder a individuos que conservan una marcha temporal más dinámica pese a su edad cronológica, mientras que los jóvenes confundidos con mayores podrían exhibir un patrón de marcha más conservador de lo esperado para su grupo etario, posiblemente influenciado por factores no capturados en este estudio, como nivel de actividad física o condición muscular individual.

6.5 Fortalezas

El presente estudio incorpora varias fortalezas metodológicas que respaldan la validez de los hallazgos obtenidos. Primera, el diseño con grupos perfectamente balanceados (15 jóvenes / 15 adultos mayores) eliminó la necesidad de técnicas de corrección por desbalance y permitió una interpretación directa de las métricas de clasificación. Segunda, la estrategia de validación Leave-One-Subject-Out resultó apropiada para el tamaño muestral disponible, al maximizar el conjunto de entrenamiento en cada iteración y garantizar independencia entre sujetos de entrenamiento y prueba (Arlot & Celisse, 2010). Tercera, el reporte conjunto de significancia estadística y tamaño

del efecto (Hedges g) permitió identificar casos metodológicamente relevantes, como la discrepancia observada entre *Left Stance Time* y *Left Stride Time* (sección 5.4.2 Tamaño del efecto), enriqueciendo la interpretación más allá de una lectura binaria de significancia. Finalmente, la integración secuencial de resultados cuantitativos con interpretación biomecánica cualitativa (sección 6.4 Integración de lo cuantitativo y lo cualitativo) aporta una explicación fisiológicamente fundamentada a los hallazgos estadísticos.

6.6 Limitaciones

Tamaño de muestra: La mayor limitación de este estudio obedece al tamaño de muestra, con $n = 15$ por grupo, el estudio se ubica en el límite inferior recomendado para tareas de clasificación supervisada, donde muestras reducidas tienden a producir estimaciones de desempeño más variables. Esta limitación es coherente con lo observado en la sección 5.4.2 Tamaño del efecto, donde biomarcadores con tamaños de efecto medianos a grandes (*Left Stance Time*, $g = 0.658$) no alcanzaron significancia estadística, sugiriendo que la potencia estadística disponible fue insuficiente para detectar diferencias reales de menor magnitud.

Una sola base de datos. Todos los datos provienen exclusivamente de NONAN GaitPrint (Wiles et al., 2023, 2025), capturados con un único protocolo, tipo de sensor y entorno de marcha (pista interior de 200 m). Es posible que el modelo entrenado capture, junto con el efecto del envejecimiento, características de esta base de datos específica.

Sensibilidad a la segmentación. Los biomarcadores espaciotemporales dependen directamente de la correcta detección de los eventos de contacto inicial y despegue del pie. La literatura reporta que los algoritmos de detección de eventos basados en IMU presentan mayor error y variabilidad intrasujeto que los métodos ópticos de referencia (Marin Garcia et al., 2025), por lo que pequeñas imprecisiones en la segmentación del ciclo de marcha pueden traducirse en

variaciones sistemáticas de los valores de cadencia, tiempo de apoyo o tiempo de balanceo reportados, afectando potencialmente tanto el análisis inferencial como la clasificación.

Generalización. El modelo fue entrenado exclusivamente con adultos sanos sin patología neurológica ni musculoesquelética, en un rango etario y una población geográfica específicos. Su capacidad de generalizar a poblaciones con comorbilidades, distintos orígenes étnicos, condiciones de calzado o superficies de marcha diferentes a las del protocolo original no puede asumirse.

Posible sesgo por selección. La submuestra de 30 sujetos (15 por grupo) fue extraída aleatoriamente de un conjunto mayor de 76 disponibles en GaitPrint (35 jóvenes, 41 mayores), lo que, pese al procedimiento estratificado, no garantiza que la submuestra sea perfectamente representativa de la población original en variables no controladas explícitamente, como nivel de actividad física, índice de masa corporal o lateralidad. Adicionalmente, el criterio de inclusión limitado a sujetos completamente sanos excluye por diseño a las poblaciones clínicas (por ejemplo, adultos mayores con fragilidad o riesgo de caída) donde la aplicación práctica de este tipo de modelo tendría mayor relevancia.

7. Conclusiones

Se clasificaron los patrones de marcha entre adultos jóvenes y adultos mayores mediante el análisis de biomarcadores espaciotemporales obtenidos de sensores inerciales y la implementación de modelos de aprendizaje automático, evidenciando que el envejecimiento locomotor en adultos funcionalmente sanos se manifiesta principalmente en los parámetros temporales del ciclo de marcha.

Se identificaron y caracterizaron 24 biomarcadores espaciotemporales extraídos de la base de datos NONAN GaitPrint, permitiendo evaluar de manera objetiva el comportamiento biomecánico de adultos jóvenes y adultos mayores. Únicamente los parámetros temporales evidenciaron diferencias consistentes entre grupos, lo que confirma que variables como el tiempo de zancada, el tiempo de paso, el tiempo de apoyo, el tiempo de balanceo y el apoyo simple constituyen biomarcadores sensibles para describir las adaptaciones biomecánicas propias del envejecimiento.

Se analizó que la aplicación análisis estadístico, con prueba metodológica y tamaño del efecto mediante Hedges g reveló que siete parámetros poseen diferencias estadísticamente significativas entre adultos jóvenes y adultos mayores: Right Stance Time, Right Swing Time, Single Support Time, Right Stride Time, Left Step Time, Left Swing Time y Left Stride Time. Esta selectividad temporal indica que, en adultos mayores sanos, el envejecimiento locomotor se manifiesta primero en la reorganización del ritmo del ciclo antes de afectar las distancias recorridas por paso.

Se adaptó un modelo de aprendizaje automático, el cual demostró la viabilidad de utilizar biomarcadores temporales de la marcha para diferenciar adultos jóvenes y adultos mayores. Entre

los tres modelos de clasificación evaluados (Regresión Logística, SVM con kernel RBF y Random Forest), superaron el desempeño de un clasificador aleatorio ($AUC > 0.5$), Random Forest presentó la mejor capacidad discriminativa global ($AUC-ROC = 0.707$, $Accuracy = 0.733$, $F1 = 0.733$), siendo seleccionado como modelo final. Su superioridad confirmó que los modelos no lineales representan una alternativa más adecuada para abordar la complejidad biomecánica de la marcha. Sin embargo, el desempeño alcanzado refleja una capacidad de clasificación moderada, lo que evidencia que los biomarcadores temporales son limitados por sí solos para lograr una separación completa entre grupos etarios. Esto sugiere que futuros modelos podrían beneficiarse de la incorporación de variables cinemáticas adicionales, muestras de mayor tamaño y procesos de validación externa que incrementen su capacidad de generalización.

Referencias Bibliográficas

- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4, 40–79. <https://doi.org/10.1214/09-SS054>.
- Bermejo Garcia, J., Rodriguez Jorge, D., Jayakumar, A., Romero Sanchez, F., & Alonso Sanchez, F. J. (2021). *Análisis dinámico de los momentos articulares en la marcha humana en adultos y adultos mayores usando el análisis de componentes principales (PCA)* [Ponencia]. Departamento de Ingeniería Mecánica, Energética y de los Materiales, Universidad de Extremadura.
- Boyer, K. A., Hafer, J. F., Sigward, S. M., Meijer, K., Grabowski, A. M., & Franz, J. R. (2023). Age-related changes in gait biomechanics and their impact on the metabolic cost of walking: Report from a National Institute on Aging workshop. *Journal of Biomechanics*, 148, 111474. <https://doi.org/10.1016/j.jbiomech.2023.111474>
- Boyer, K. A., Johnson, R. T., Banks, J. J., Jewell, C., & Hafer, J. F. (2017). Systematic review and meta-analysis of gait mechanics in young and older adults. *Experimental Gerontology*, 95, 63–70. <https://doi.org/10.1016/j.exger.2017.05.005>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Brydges, C. R. (2019). Effect size guidelines, sample size calculations, and statistical power in gerontology. *Innovation in Aging*, 3(4), igz036. <https://doi.org/10.1093/geroni/igz036>
- Bulgarelli, F., et al. (2026). Participant-aware model validation for repeated-measures data. *JMIR AI*, e87728. <https://doi.org/10.2196/87728>

- Camargo, C., et al. (2021). A comprehensive study of age-related differences in spatiotemporal gait parameters: Cross-sectional data and systematic review. *Gait & Posture*, 86, 96–109. <https://doi.org/10.1016/j.gaitpost.2021.02.024>
- Cappozzo, A., Catani, F., Della Croce, U., & Leardini, A. (1995). Position and orientation in space of bones during movement: Anatomical frame definition and determination. *Clinical Biomechanics*, 10(4), 171–178. [https://doi.org/10.1016/0268-0033\(95\)91394-T](https://doi.org/10.1016/0268-0033(95)91394-T)
- Cardenas, A., Gomez, B., Ealo, L., y Perez, J. (2023). Uso de algoritmos de aprendizaje automatico para la clasificacion de la marcha de enfermedades neurodegenerativas. *Ingenierias USBMed*, 14, 8-14. <https://revistas.usb.edu.co/index.php/IngUSBmed/article/view/6084>
- Cerda A., L. (2010). Evaluacion del paciente con trastorno de la marcha. *Revista Hospital Clinico Universidad de Chile*, 21(4), 326-336. <https://doi.org/10.5354/2735-7996.2010.75367>
- Cifuentes, C., Martinez, F., & Romero, E. (2010). Analisis teorico y computacional de la marcha normal y patologica: Una revision. *Revista Med*, 18(2), 182-196. <https://www.redalyc.org/articulo.oa?id=91020446005>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum Associates.
- Creswell, J. W. (2014). *Research design: Qualitative, quantitative, and mixed methods approaches* (4th ed.). SAGE Publications.
- Davis, R. B., Ounpuu, S., Tyburski, D., & Gage, J. R. (1991). A gait analysis data collection and reduction technique. *Human Movement Science*, 10(5), 575–587. [https://doi.org/10.1016/0167-9457\(91\)90046-Z](https://doi.org/10.1016/0167-9457(91)90046-Z)

- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.
<https://doi.org/10.1016/j.patrec.2005.10.010>
- Fondo de Poblacion de las Naciones Unidas [UNFPA]. (2023). *Analisis de situacion de poblacion 2023* (ISBN 978-958-5437-27-2). UNFPA Colombia. https://colombia.unfpa.org/sites/default/files/pub-pdf/asp_completo_baja_compressed.pdf
- Fundacion Saldarriaga Concha & Departamento Administrativo Nacional de Estadistica [DANE]. (2021). Personas mayores en Colombia: Hacia la inclusion y la participacion. DANE.
<https://www.dane.gov.co/files/investigaciones/notas-estadisticas/oct-2022-nota-estadistica-personas-mayores-en-colombia.pdf>
- Garcia, J. A., Rueda, J. D., & Blanco, L. F. (2018). *Analisis de la marcha en el adulto mayor: Simulador de estado funcional* [Trabajo de grado, Universidad Pontificia Bolivariana]. Repositorio Institucional UPB.
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow* (3rd ed.). O'Reilly Media.
- Giakas, G., & Baltzopoulos, V. (1997). Time and frequency domain analysis of ground reaction forces during walking. *Journal of Biomechanics*, 30(9), 959–963. [https://doi.org/10.1016/S0021-9290\(97\)00047-X](https://doi.org/10.1016/S0021-9290(97)00047-X)
- Halilaj, E., et al. (2018). Machine learning in human movement biomechanics: Best practices, common pitfalls, and new opportunities. *Journal of Biomechanics*, 81, 1–11.
<https://doi.org/10.1016/j.jbiomech.2018.09.009>
- Harris, C. R., et al. (2020). Array programming with NumPy. *Nature*, 585(7825), 357–362.
<https://doi.org/10.1038/s41586-020-2649-2>

- Harvard Catalyst. (s.f.). Mixed methods research. Harvard University.
<https://catalyst.harvard.edu/community-engagement/mmr/>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Hedges, L. V. (1981). Distribution theory for Glass's estimator of effect size and related estimators. *Journal of Educational Statistics*, 6(2), 107–128. <https://doi.org/10.2307/1164588>
- Hedges, L. V., & Olkin, I. (1985). *Statistical methods for meta-analysis*. Academic Press.
- Herssens, N., Verbecque, E., Hallemans, A., Vereeck, L., Van Rompaey, V., & Saeys, W. (2018). Do spatiotemporal parameters and gait variability differ across the lifespan of healthy adults? A systematic review. *Gait & Posture*, 64, 181–190. <https://doi.org/10.1016/j.gaitpost.2018.06.012>
- Hollman, J. H., McDade, E. M., & Petersen, R. C. (2011). Normative spatiotemporal gait parameters in older adults. *Gait & Posture*, 34(1), 111–118. <https://doi.org/10.1016/j.gaitpost.2011.03.024>
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression* (3rd ed.). Wiley.
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
- Hwang, S., et al. (2025). Age-related gait adaptations: Analysis of temporal gait parameters and variability, and muscle activation across flat vs. uneven surfaces in young, middle-aged, and older adults. *Frontiers in Aging*. <https://doi.org/10.3389/fragi.2025.1573778>
- Instituto de Biomecánica de Valencia [IBV]. (2021). *BIOMECA4IA: Analisis de las tecnicas de IA aplicadas a la modelizacion biomecanica* (Entregable E4.1). IBV. https://www.ibv.org/wp-content/uploads/2021/12/BIOMECA4IA_E4.pdf

- Jarchi, D., Pope, J., Lee, T. K. M., Tamjidi, L., Mirzaei, A., & Sanei, S. (2018). A review on accelerometry-based gait analysis and emerging clinical applications. *IEEE Reviews in Biomedical Engineering*, 11, 177-194. <https://doi.org/10.1109/RBME.2018.2807182>
- Judge, J. O., Davis, R. B., & Öunpuu, S. (1996). Step length reductions in advanced age: The role of ankle and hip kinetics. *The Journals of Gerontology Series A*, 51A(6), M303–M312.
- Kataoka, N., Hirai, H., Hamilton, T., Yoshikawa, F., Kuroiwa, A., Nagakawa, Y., & Krebs, H. I. (2017). *Effects of partial body-weight support and functional electrical stimulation on gait characteristics during treadmill locomotion. En Proceedings of the 2017 International Conference on Rehabilitation Robotics (ICORR) (pp. 1-6). IEEE.* <https://doi.org/10.1109/ICORR.2017.8009277>
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Proceedings of IJCAI*, 1137–1145.
- Kohavi, R., & John, G. H. (1997). Wrappers for feature subset selection. *Artificial Intelligence*, 97(1–2), 273–324. [https://doi.org/10.1016/S0004-3702\(97\)00043-X](https://doi.org/10.1016/S0004-3702(97)00043-X)
- Lesmes, J. D. (2007). Evaluacion clinico-funcional del movimiento corporal humano. Editorial Medica Panamericana.
- Levene, H. (1960). *Robust tests for equality of variances. En I. Olkin (Ed.), Contributions to probability and statistics (pp. 278–292). Stanford University Press.*
- Lim, A. C. Y., Natarajan, P., Fonseka, R. D., Maharaj, M., & Mobbs, R. J. (2022). The application of artificial intelligence and custom algorithms with inertial wearable devices for gait analysis. *Digital Health*, 8, 1-20. <https://doi.org/10.1177/20552076221074128>
- Lugade, V., Lin, V., & Chou, L. S. (2011). Center of mass and base of support interaction during human walking. *Gait & Posture*, 33(3), 406–411. <https://doi.org/10.1016/j.gaitpost.2010.12.013>

- Maceira Suarez, E. (2003). Analisis cinematico y cinetico de la marcha humana. *Revista del Pie y Tobillo*, 17(1), 29-37. <https://fondoscience.com/pieytobillo/vol17-num1/fs031008-analisis-cinematico-cinetico-marcha-humana>
- Maki, B. E. (1997). *Gait changes in older adults: Predictors of falls or indicators of fear?* *Journal of the American Geriatrics Society*, 45(3), 313–320. <https://doi.org/10.1111/j.1532-5415.1997.tb00946.x>
- Mann, H. B., & Whitney, D. R. (1947). On a test of whether one of two random variables is stochastically larger than the other. *The Annals of Mathematical Statistics*, 18(1), 50–60. <https://doi.org/10.1214/aoms/1177730491>
- Marin Garcia, J., et al. (2025). Accuracy and inter-subject variability of gait event detection methods based on optical and inertial motion capture. *Sensors*, 25(24), 7652. <https://doi.org/10.3390/s25247652>
- Martínez, D. C. [carmare13]. (2024). *Gait-Reorganization* [Código fuente en software]. GitHub. <https://github.com/carmare13/Gait-Reorganization>
- McKinney, W. (2010). Data structures for statistical computing in Python. *Proceedings of the 9th Python in Science Conference*, 56–61. <https://doi.org/10.25080/Majora-92bf1922-00a>
- Moe-Nilssen, R. (1998). A new method for evaluating motor control in gait under real-life environmental conditions. *Clinical Biomechanics*, 13(4–5), 328–335. [https://doi.org/10.1016/S0268-0033\(98\)00090-4](https://doi.org/10.1016/S0268-0033(98)00090-4)
- Molla, P. (2022). *Inteligencia artificial aplicada a biomecanica* [Trabajo de fin de grado, Universidad de Zaragoza]. Repositorio Zeguan. <https://zeguan.unizar.es/record/125153/files/TAZ-TFG-2022-2999.pdf>

- Muro-De-La-Herran, A., Garcia-Zapirain, B., & Mendez-Zorrilla, A. (2014). Gait analysis methods: An overview of wearable and non-wearable systems, highlighting clinical applications. *Sensors*, 14(2), 3362-3394. <https://doi.org/10.3390/s140203362>
- Murray, M. P., Kory, R. C., & Clarkson, B. H. (1969). Walking patterns in healthy old men. *Journal of Gerontology*, 24(2), 169–178. <https://doi.org/10.1093/geronj/24.2.169>
- Neumann, D. A. (2010). *Kinesiology of the musculoskeletal system: Foundations of physical rehabilitation* (2nd ed.). Mosby.
- O'Connor, C. M., Thorpe, S. K., O'Malley, M. J., & Vaughan, C. L. (2007). Automatic detection of gait events using kinematic data. *Gait & Posture*, 25(3), 469–474. <https://doi.org/10.1016/j.gaitpost.2006.05.016>
- Organización Mundial de la Salud. (2000). Obesity: Preventing and managing the global epidemic. WHO Technical Report Series 894.
- Pedregosa, F., et al. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Perry, J., & Burnfield, J. M. (2010). *Gait analysis: Normal and pathological function* (2nd ed.). Slack Incorporated.
- Pirker, W., & Katzenschlager, R. (2017). Gait disorders in adults and the elderly: A clinical guide. *Wiener Klinische Wochenschrift*, 129(3–4), 81–95. <https://doi.org/10.1007/s00508-016-1096-4>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC. *Journal of Machine Learning Technologies*, 2(1), 37–63.

- Prakash, C., Kumar, R., & Mittal, N. (2016). Recent developments in human gait research: Parameters, approaches, applications, machine learning techniques, datasets and challenges. *Artificial Intelligence Review*, 49(1), 1-40. <https://doi.org/10.1007/s10462-016-9514-6>
- Proakis, J. G., & Manolakis, D. G. (2007). *Digital signal processing* (4th ed.). Pearson.
- Rampp, A., Barth, J., Schüle, S., Gaßmann, K. G., Klucken, J., & Eskofier, B. M. (2015). Inertial sensor-based stride parameter calculation from gait sequences in geriatric patients. *IEEE Transactions on Biomedical Engineering*, 62(4), 1089–1097. <https://doi.org/10.1109/TBME.2014.2368211>
- Razali, N. M., & Wah, Y. B. (2011). Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *Journal of Statistical Modeling and Analytics*, 2(1), 21–33.
- Robertson, D. G. E., Caldwell, G. E., Hamill, J., Kamen, G., & Whittlesey, S. N. (2014). *Research methods in biomechanics* (2nd ed.). Human Kinetics.
- Sarker, I. H. (2021). Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions. *SN Computer Science*, 2, 420. <https://doi.org/10.1007/s42979-021-00815-1>
- Sarker, I. H. (2022). AI-based modeling: Techniques, applications and research issues towards automation, intelligent and smart systems. *SN Computer Science*, 3(2). <https://doi.org/10.1007/s42979-022-01043-x>
- Shapiro, S. S., & Wilk, M. B. (1965). An analysis of variance test for normality. *Biometrika*, 52(3–4), 591–611. <https://doi.org/10.1093/biomet/52.3-4.591>
- Strobl, C., Boulesteix, A. L., Kneib, T., Augustin, T., & Zeileis, A. (2008). Conditional variable importance for random forests. *BMC Bioinformatics*, 9, 307. <https://doi.org/10.1186/1471-2105-9-307>
- Sutherland, D. H., Kaufman, K. R., & Moitza, J. R. (1994). *Kinematics of normal human walking*. En J. Rose & J. G. Gamble (Eds.), *Human locomotion* (pp. 23–44).

- Taborri, J., Palermo, E., Rossi, S., & Cappa, P. (2016). Gait partitioning methods: A systematic review. *Sensors*, 16(1), 66. <https://doi.org/10.3390/s16010066>
- Teran Pineda, D. F. (2024). *Aprendizaje automatico para la deteccion de inicio/fin de la marcha mediante dos sensores inerciales y modelado de datos usando aprendizaje profundo* [Tesis doctoral, Universidad de Malaga]. Repositorio Institucional UMA.
- Tesio, L., Roi, G. S., & Möller, F. (1998). Displacement of the pelvis during human walking. *European Journal of Applied Physiology*, 77(5), 453–461. <https://doi.org/10.1007/s004210050358>
- Tran, T. T., et al. (2021). Machine learning in gait analysis: A review. *Sensors*, 21(5), 1633. <https://doi.org/10.3390/s21051633>
- Trojaniello, D., Cereatti, A., Pelosin, E., Avanzino, L., Mirelman, A., Hausdorff, J. M., & Della Croce, U. (2014). Estimation of step-by-step spatio-temporal parameters of normal and impaired gait using shank-mounted magneto-inertial sensors. *Journal of NeuroEngineering and Rehabilitation*, 11, 152. <https://doi.org/10.1186/1743-0003-11-152>
- Trojaniello, D., Cereatti, A., & Della Croce, U. (2014). Accuracy, sensitivity and robustness of five different methods for the estimation of gait temporal parameters using a single inertial sensor mounted on the lower trunk. *Gait & Posture*. <https://doi.org/10.1016/j.gaitpost.2014.09.004>
- Vabalas, A., Gowen, E., Poliakoff, E., & Casson, A. J. (2019). Machine learning algorithm validation with a limited sample size. *PLOS ONE*, 14(11), e0224365. <https://doi.org/10.1371/journal.pone.0224365>
- van Rossum, G., & Drake, F. L. (2009). Python 3 reference manual. CreateSpace.
- Virtanen, P., et al. (2020). SciPy 1.0: Fundamental algorithms for scientific computing in Python. *Nature Methods*, 17(3), 261–272. <https://doi.org/10.1038/s41592-019-0686-2>

- Wager, J. C., & Challis, J. H. (2024). The effects of plantarflexor weakness and reduced tendon stiffness with aging on gait stability. *Journal of Biomechanics*.
<https://doi.org/10.1016/j.jbiomech.2024.111982>
- Webster, J. B., & Darter, B. J. (2019). *Principles of normal and pathologic gait*. En D. A. Muccini (Ed.), *Atlas of orthoses and assistive devices* (5.a ed., pp. 49-62). Elsevier. <https://doi.org/10.1016/B978-0-323-48323-0.00004-4>
- Weiss, A., Mirelman, A., Giladi, N., Barnes, L. L., Bennett, D. A., Buchman, A. S., & Hausdorff, J. M. (2022). Walking parameters of older adults from a lower back inertial measurement unit. *Gait & Posture*, 93, 217–222. <https://doi.org/10.1016/j.gaitpost.2022.02.008>
- Whittle, M. W. (2007). *Gait analysis: An introduction* (4th ed.). Butterworth-Heinemann.
- Wiles, T. M., Kim, S. K., Mangalam, M., Sommerfeld, J. H., Brink, K. J., Grunkemeyer, A., Kalaitzi Manifrenti, M., Charles, A. E., Shakerian, N., Haghighatnejad, M., Mastorakis, S., Stergiou, N., & Likens, A. D. (2025). NONAN GaitPrint: An IMU gait database of healthy older adults. *Scientific Data*, 12, 143. <https://doi.org/10.1038/s41597-024-04359-w>
- Wiles, T. M., Mangalam, M., Sommerfeld, J. H., Kim, S. K., Brink, K. J., Charles, A. E., Grunkemeyer, A., Kalaitzi Manifrenti, M., Mastorakis, S., Stergiou, N., & Likens, A. D. (2023). NONAN GaitPrint: An IMU gait database of healthy young adults. *Scientific Data*, 10, 867. <https://doi.org/10.1038/s41597-023-02704-z>
- Winter, D. A. (2009). *Biomechanics and motor control of human movement* (4th ed.). John Wiley & Sons.
- Winter, D. A., Patla, A. E., Frank, J. S., & Walt, S. E. (1990). Biomechanical walking pattern changes in the fit and healthy elderly. *Physical Therapy*, 70(6), 340–347. <https://doi.org/10.1093/ptj/70.6.340>

- Xu, G., & Huang, J. Z. (2012). Asymptotic optimality and efficient computation of the leave-subject-out cross-validation. *The Annals of Statistics*, 40(6), 3003–3030. <https://doi.org/10.1214/12-AOS1063>
- Zeni, J. A., Richards, J. G., & Higginson, J. S. (2008). Two simple methods for determining gait events during treadmill and overground walking using kinematic data. *Gait & Posture*, 27(4), 710–714.
- Zheng, X., Wilhelm, E., Otten, E., Reneman, M. F., & Lamoth, C. J. C. (2024). Age-related gait patterns classification using deep learning based on time-series data from one accelerometer. *Sensors*, 24. University of Groningen.