



UNIVERSIDAD DE VALLADOLID

FACULTAD DE MEDICINA

ESCUELA DE INGENIERÍAS INDUSTRIALES

TRABAJO DE FIN DE GRADO

GRADO EN INGENIERÍA BIOMÉDICA

**Segmentación y análisis de señales de marcha
obtenidas con sensores inerciales mediante
métodos avanzados de aprendizaje profundo**

Autor:

D^a. Celia Mazariegos Iglesias

Tutor:

D. Mario Martínez Zarzuela

Cotutor:

D. Daniel Iordanov López

Valladolid, 25 de septiembre de 2025

TÍTULO:	Segmentación y análisis de señales de marcha obtenidas con sensores inerciales mediante métodos avanzados de aprendizaje profundo
AUTOR:	D^a. Celia Mazariegos Iglesias
TUTOR:	D. Mario Martínez Zarzuela
COTUTOR:	D. Daniel Iordanov López
DEPARTAMENTO:	Departamento de Teoría de la Señal y Comunicaciones e Ingeniería Telemática (TSCIT) de la Universidad de Valladolid

TRIBUNAL

PRESIDENTE:	D. Rodrigo de Luis García
SECRETARIO:	D. Mario Martínez Zarzuela
VOCAL:	D. Luis Fernando Hevia de los Mozos
SUPLENTE 1:	D.^a María García Gadañón
SUPLENTE 2:	D. Alberto Mansilla Gallo

FECHA: 25/09/2025

CALIFICACIÓN:

AGRADECIMIENTOS

Me gustaría agradecer en primer lugar a Mario y a Daniel por todo el tiempo que han dedicado para que este proyecto pudiera llevarse a cabo. Gracias por cada consejo y cada explicación, pero sobre todo gracias por transmitirme vuestra pasión y motivación por hacer las cosas bien y aportar valor a la sociedad. En siguiente lugar, me gustaría agradecer a Beatriz y al equipo de rehabilitación la labor que realizan día a día ayudando a niños con parálisis cerebral, además de agradecer la experiencia y los conocimientos clínicos transmitidos sin los cuales este trabajo no habría sido posible. Un agradecimiento a los niños y a sus padres que han hecho posible no solo este estudio, sino también futuras investigaciones. Por supuesto quiero agradecer a Carmen y Alba por tenderme su mano en los momentos en los que las cosas no salían como esperaba.

Gracias a mis padres, por haberme acompañado siempre con paciencia y cariño, enseñándome el valor del esfuerzo y del compromiso. A mis hermanas, por estar siempre a una llamada de distancia y regalarme millones de sonrisas. A mis abuelos, por lograr que nunca me sintiera lejos de casa. A mis tíos y primos, quienes me recuerdan lo orgullosos que están de mí y están presentes de una u otra manera.

Gracias a quienes durante cuatro años habéis sido mis compañeros de clase. Gracias por vuestro compañerismo y ayuda desinteresada. Gracias también a mis chicas del Colegio Mayor por no dejarme nunca sola y por convertirlos en parte esencial de esta etapa.

Finalmente, quiero agradecer en especial a Alejandro, por su apoyo incondicional, por recordarme siempre que soy capaz de todo, por su paciencia, por su comprensión, por su confianza en mí y por celebrar conmigo cada pequeño logro. Gracias por impulsarme a ser mejor.

Resumen

Este trabajo de fin de grado se centra en el análisis de la marcha de población infantil con parálisis cerebral y su comparación con patrones no patológicos. La parálisis cerebral es una enfermedad neurológica no progresiva que constituye la principal causa de discapacidad pediátrica. Sus manifestaciones incluyen espasticidad, debilidad y alteraciones en la marcha. La marcha es un proceso cíclico con fases de apoyo y oscilación que se analiza mediante parámetros espaciotemporales, curvas de cinemática y señales de electromiografía. El objetivo de este proyecto es aplicar tanto métodos estadísticos como técnicas de inteligencia artificial a estas curvas de cinemática para su comparación y segmentación en fases, además de generar informes clínicos automáticos que puedan ser útiles en la práctica de rehabilitación. Para su correcto desarrollo se ha recopilado una base de datos pediátrica en el Hospital Universitario Río Hortega (Valladolid) con 46 participantes (25 controles y 21 niños con parálisis cerebral).

La metodología se divide principalmente en dos bloques: en su inicio encontramos la generación automática de informes clínicos en Python, que facilitan el seguimiento del paciente y la comparación entre registros de distintas consultas. Seguidamente se comenta la segmentación de las fases de la marcha, aplicando dos enfoques: uno basado en la morfología de la señal y otro mediante un modelo BiLSTM + MultiHeadAttention, que incluye *data augmentation*, regularización y restricciones fisiológicas.

Los resultados muestran ejemplos de señales de cinemática y electromiografía sincronizadas, informes clínicos, comparaciones estadísticas y segmentaciones. En primer lugar, la comparación entre la sincronización propuesta y la referencia de Xsens mostró errores bajos. En el análisis global de 14 sujetos, los resultados se situaron en torno a 7,5° de RMSE y 6,7° de MAE, alcanzando correlaciones cercanas a 1, lo que confirma la similitud entre las formas de onda. La detección de eventos de la marcha obtuvo errores inferiores a 80 ms tanto en controles como en pacientes, lo que representa menos del 1% del ciclo de la marcha y se considera clínicamente despreciable. Statistical Parametric Mapping superó a las métricas discretas en interpretabilidad y proporcionó un enfoque más robusto y objetivo que la supervisión visual, evitando conclusiones erróneas debidas a la variabilidad entre pasos. En cuanto a la segmentación clásica basada en la velocidad angular, se obtuvo una división de las siete fases de la marcha fiable. Finalmente, la red neuronal alcanzó rendimientos comparables o superiores a estudios previos, incluso en población patológica. En pacientes el modelo obtuvo un *accuracy* del 92,37% al aplicar una tolerancia de ± 1 muestra. En controles, el rendimiento fue aún superior, alcanzando el 91,21% y hasta el 94,83% con una tolerancia de ± 1 muestra. El error medio en la detección de transiciones fue de aproximadamente 12 y 15 ms, dentro de los márgenes aceptados en la literatura. Las fases largas y estables, como el apoyo medio y la oscilación media, fueron las que mejor se reconocieron, mientras que las fases más breves (apoyo terminal y preoscilación) concentraron la mayor parte de los errores.

Palabras clave

Análisis de la marcha, aprendizaje profundo, BiLSTM, cinemática articular, fases de la marcha, informes automáticos, MultiHeadAttention, parálisis cerebral, rehabilitación pediátrica, segmentación de la marcha, sensores inerciales, Statistical Parametric Mapping.

Abstract

This bachelor's thesis focuses on the gait analysis of children with cerebral palsy and its comparison with non-pathological patterns. Cerebral palsy is a non-progressive neurological disorder and the main cause of pediatric disability. Its manifestations include spasticity, weakness and gait alterations. Gait is a cyclical process with stance and swing phases, analyzed through spatiotemporal parameters, kinematic curves and electromyographic signals. The aim of this project is to apply both statistical methods and artificial intelligence techniques to these kinematic curves for their comparison and segmentation into phases, in addition to generating automatic clinical reports that may be useful in rehabilitation practice. To this end, a pediatric database was compiled at the Hospital Universitario Río Hortega (Valladolid), including 46 participants (25 controls and 21 children with cerebral palsy).

The methodology is mainly divided into two blocks. First, the automatic generation of clinical reports in Python, which facilitates patient follow-up and the comparison of records from different consultations. Second, the segmentation of gait phases, addressed through two approaches: one based on signal morphology and another using a BiLSTM + MultiHeadAttention model, which incorporates data augmentation, regularization and physiological constraints.

The results show examples of synchronized kinematic and electromyographic signals, clinical reports, statistical comparisons and segmentations. The comparison between the proposed synchronization and the Xsens reference showed low errors. In the global analysis of 14 subjects, results were around 7.5° RMSE and 6.7° MAE, with correlations close to 1, confirming the similarity between waveforms. Gait event detection obtained errors below 80 ms in both controls and patients, representing less than 1% of the gait cycle and considered clinically negligible. Statistical Parametric Mapping outperformed discrete metrics in interpretability, providing a more robust and objective approach than visual inspection, thus avoiding misleading conclusions due to step variability. Regarding classical segmentation based on angular velocity, a reliable division of the seven gait phases was achieved, with stable durations between patients and controls. Finally, the neural network achieved performances comparable to or even exceeding those reported in previous studies, including in pathological populations. In patients, the model reached an accuracy of 92.37% when applying a tolerance of ± 1 sample. In controls, performance was even higher, achieving 91.21% and up to 94.83% with ± 1 sample tolerance. The mean error in transition detection was approximately 12–15 ms, within the margins accepted in the literature. Long and stable phases, such as mid-stance and mid-swing, were the most accurately recognized, whereas shorter phases (terminal stance and pre-swing) accounted for most misclassifications.

Keywords

Automatic reports, BiLSTM, cerebral palsy, Deep Learning, gait analysis, gait phases, gait segmentation, inertial sensors, joint kinematics, MultiHeadAttention, pediatric rehabilitation, Statistical Parametric Mapping.

Índice general

1. Introducción.....	1
1.1 Contexto del análisis de la marcha y motivaciones del trabajo.....	1
1.2 Estado del arte	2
1.2.1 Statistical Parametric Mapping en biomecánica	2
1.2.2 Segmentación de las fases de la marcha con métodos tradicionales de detección de eventos.....	3
1.2.3 Segmentación automática de las fases de la marcha con Deep Learning.....	4
1.3 Recursos utilizados.....	6
1.4 Hipótesis y objetivos	7
1.4.1 Hipótesis.....	7
1.4.2 Objetivos	7
1.5 Estructura del documento.....	8
2. Análisis de la marcha en parálisis cerebral.....	9
2.1 Etiología, manifestaciones clínicas y clasificación de la parálisis cerebral	9
2.2 Definición de la marcha y sus fases	12
2.3 Parámetros espaciotemporales de la marcha	13
2.4 Curvas de cinemática durante la marcha.....	14
2.5 Patrones de marcha patológica	17
2.6 Electromiografía en la marcha	18
3. Materiales.....	20
3.1 Equipamiento para el registro de señales de marcha.....	20
3.1.1 Principios de funcionamiento de las IMUs	20
3.1.2 Xsens MVN Awinda.....	21
3.1.3 Ventajas y limitaciones de las IMUs frente a otros métodos de obtención de señal de marcha	23
3.2 Creación y gestión de la base de datos	24
3.2.1 Selección de sujetos	24
3.2.2 Comité Ético.....	25
3.2.3 Protocolo de adquisición	26
3.2.4 Descripción de la base de datos.....	29
3.2.5 Generación de curvas normativas de nuestra base de datos	30
3.2.6 Sincronización de señales de cinemática y electromiografía	35
4. Metodología	38
4.1 Generación automática de informes	38
4.1.1 Estructura de los informes clínicos	38

4.1.2 Métodos estadísticos para análisis comparativo entre consultas de rehabilitación	40
4.2 Segmentación de las fases de la marcha.....	42
4.2.1 Segmentación basada en la morfología de la señal	42
4.2.2 Segmentación a través de Deep Learning	44
5. Resultados	48
5.1 Gráficas de electromiografía y cinemática sincronizadas	48
5.2 Ejemplo de informe clínico	51
5.3 Gráficas comparativas generadas con SPM	59
5.4 Gráficas de velocidad angular segmentadas.....	63
5.5 Resultados de la segmentación de las fases de la marcha con Deep Learning.....	66
6. Discusión y limitaciones	76
6.1 Aplicabilidad y calidad de la base de datos y los informes clínicos automáticos	76
6.2 Comparativa con trabajos previos de análisis SPM en la marcha	76
6.3 Comparativa con trabajos previos de segmentación de la marcha con métodos tradicionales	77
6.4 Comparativa con trabajos previos de segmentación de la marcha con Deep Learning	78
6.5 Limitaciones del estudio.....	80
7. Conclusiones y trabajos futuros.....	82
7.1 Síntesis de hallazgos principales	82
7.2 Implicaciones clínicas y para la investigación	82
7.3 Líneas futuras.....	84
8. Bibliografía	86
ANEXO	93

Índice de figuras

Fig. 1. Esquema seguido por (Salminen et al., 2024a) para la segmentación de la marcha.....	4
Fig. 2. Clasificación PC según el lugar de lesión (Hernández, 2015).....	10
Fig. 3. Clasificación PC según la limitación de la actividad (Graham et al., 2016).....	11
Fig. 4. Sistema de la Clasificación de la Función Motora Gruesa.	11
Fig. 5. Fases de la marcha en un ciclo completo.....	13
Fig. 6. Parámetros espaciotemporales de la marcha.....	14
Fig. 7. Movimientos de las articulaciones de la extremidad inferior en el eje sagital.....	14
Fig. 8. Movimientos de las articulaciones de la extremidad inferior en los ejes frontal y transversal.	15
Fig. 9. Planos con interés clínico.....	15
Fig. 10. Curvas de cinemática durante la marcha de las articulaciones del miembro inferior. ..	17
Fig. 11. Actividad muscular durante un ciclo completo de marcha.	19
Fig. 12. Músculos de interés en este trabajo (gastrocnemio y TA).	19
Fig. 13. Movimientos a través de los ejes principales x, y, z.	21
Fig. 14. Sensor inercial MTw junto con su sistema de referencia y Awinda Station.....	22
Fig. 15. Software MVN Analyze.....	22
Fig. 16. Software MVN Analyze durante un registro.....	22
Fig. 17. Colocación sensores inerciales y de EMG.....	26
Fig. 18. Sala del área de Rehabilitación Pediátrica del Hospital Universitario Río Hortega junto con esquema de la prueba pedida.	29
Fig. 19. Sensores de EMG e inerciales colocados.....	29
Fig. 20. Posiciones articulares de la extremidad inferior a lo largo de un ciclo completo en los tres ejes del espacio.....	33
Fig. 21. Posiciones articulares de la extremidad inferior durante un ciclo completo de marcha (patrón patológico vs. típico).	35
Fig. 22. Señal de velocidad angular original y resultado de la aplicación del filtro de varianza móvil.	36
Fig. 23. Resultado de la inversión de la primera mitad del registro.....	36
Fig. 24. Detección de eventos de la marcha sobre señal de velocidad angular.	37
Fig. 25. Segmentación de las fases de la marcha a través de la morfología de la señal (Behboodi et al., 2019a).....	43
Fig. 26. Esquema de arquitectura LSTM.	44
Fig. 27. Señales de velocidad angular obtenidas a través de sensores inerciales y de EMG sincronizadas.....	48
Fig. 28. Comparación entre señales segmentadas con nuestro algoritmo y referencia de Xsens (en rodilla).....	49
Fig. 29. Comparación entre señales segmentadas con nuestro algoritmo y referencia de Xsens (en tobillo).....	49
Fig. 30. Ejemplo de informe clínico.....	59
Fig. 31. Gráficas de las posiciones articulares de pacientes y sus respectivos análisis SPM.....	60
Fig. 32. Gráficas de posiciones articulares y sus respectivos análisis SPM (en otras articulaciones y planos).....	60
Fig. 33. Comparación entre medias, desviaciones y análisis SPM (ejemplo 1).....	61
Fig. 34. Comparación entre medias, desviaciones y análisis SPM (ejemplo 2).....	61
Fig. 35. Comparación entre medias, desviaciones y análisis SPM (ejemplo 3).....	61
Fig. 36. Posiciones articulares de la rodilla, análisis SPM y banda interpretativa.	62
Fig. 37. Análisis comparativo con SPM y bandas interpretativas.	63
Fig. 38. Resultado 1 de segmentación con algoritmo basado en la morfología de señal.	63

Fig. 39. Resultado 2 de segmentación con algoritmo basado en la morfología de señal.	64
Fig. 40. Resultado 1 de segmentación con algoritmo basado en la morfología de señal.	64
Fig. 41. Resultado 2 de segmentación con algoritmo basado en la morfología de señal.	64
Fig. 42. Resultado 3 de segmentación con algoritmo basado en la morfología de señal.	65
Fig. 43. Resultado 4 de segmentación con algoritmo basado en la morfología de señal.	65
Fig. 44. Resultado 5 de segmentación con algoritmo basado en la morfología de señal.	65
Fig. 45. Matriz de confusión obtenida de ANN entrenada con pacientes.	67
Fig. 46. Matriz de confusión obtenida de ANN entrenada con pacientes con tolerancia de 1 muestra.	68
Fig. 47. Ejemplo 1: Segmentación con ANN entrenada con pacientes.	69
Fig. 48. Ejemplo 2: Segmentación con ANN entrenada con pacientes.	70
Fig. 49. Ejemplo 3: Segmentación con ANN entrenada con pacientes.	70
Fig. 50. Ejemplo 4: Segmentación con ANN entrenada con pacientes.	70
Fig. 51. Ejemplo 5: Segmentación con ANN entrenada con pacientes.	71
Fig. 52. Matriz de confusión obtenida de ANN entrenada con controles.	72
Fig. 53. Matriz de confusión obtenida de ANN entrenada con controles con tolerancia de 1 muestra.	73
Fig. 54. Ejemplo 1: Segmentación con ANN entrenada con controles.	74
Fig. 55. Ejemplo 2: Segmentación con ANN entrenada con controles.	74
Fig. 56. Ejemplo 3: Segmentación con ANN entrenada con controles.	75
Fig. 57. Ejemplo 4: Segmentación con ANN entrenada con controles.	75
Fig. 58. Ejemplo 5: Segmentación con ANN entrenada con controles.	75
Fig. 59. Pasos mal segmentados por el algoritmo basado en la velocidad angular.	78
Fig. 60. Posiciones angulares de la rodilla del mismo paciente con 1 año y 4 meses de diferencia (derecha inicial, izquierda actual).	83
Fig. 61. Elección de carpetas y registros.	94

Índice de tablas

Tabla 1. Parámetros espaciotemporales de la marcha en niños sanos.	14
Tabla 2. Patrones de marcha en PC.	18
Tabla 3. Resumen de características de los pacientes incluidos en la base de datos.	30
Tabla 4. Resumen de características de los voluntarios sanos incluidos en la base de datos.	30
Tabla 5. Características de la red.	46
Tabla 6. División de controles y pacientes en conjunto de train, validation y test.	47
Tabla 7. Número de ciclos por cada conjunto de train, validation y test.	47
Tabla 8. Errores entre los pasos segmentados con nuestro algoritmo y la referencia de Xsens (en rodilla).	49
Tabla 9. Errores entre los pasos segmentados con nuestro algoritmo y la referencia de Xsens (en tobillo).	50
Tabla 10. Errores entre los pasos segmentados con nuestro algoritmo y la referencia de Xsens (en 14 sujetos).	50
Tabla 11. Tabla comparativa en ms entre las duraciones de las fases en marcha sana y patológica.	65
Tabla 12. Tabla comparativa en % entre las duraciones de las fases en marcha sana y patológica.	66
Tabla 13. Métricas de rendimiento ANN entrenada con pacientes.	66
Tabla 14. Métricas de rendimiento desglosadas por fases de ANN entrenada con pacientes.	66
Tabla 15. Métricas de rendimiento de ANN entrenada con pacientes con tolerancia de 1 muestra.	68
Tabla 16. Métricas de rendimiento desglosadas por fases de ANN entrenada con pacientes con tolerancia de 1 muestra.	68
Tabla 17. Métricas de rendimiento de ANN entrenada con pacientes con tolerancia de 2 muestras.	68
Tabla 18. Métricas de rendimiento ANN entrenada con controles.	71
Tabla 19. Métricas de rendimiento desglosadas por fases de ANN entrenada con controles.	71
Tabla 20. Métricas de rendimiento de ANN entrenada con controles con tolerancia de 1 muestra.	72
Tabla 21. Métricas de rendimiento desglosadas por fases de ANN entrenada con controles con tolerancia de 1 muestra.	72
Tabla 22. Métricas de rendimiento de ANN entrenada con controles con tolerancia de 2 muestras.	73
Tabla 23. Resumen trabajos previos comparables al nuestro.	79

Acrónimos

ANN: Artificial Neural Network

BiLSTM: Bidirectional Long Short-Term Memory

CNN: Convolutional Neural Network

CNN-GRU: Convolutional Neural Network – Gated Recurrent Unit

CT: Contacto terminal

EC: End Contact

EKF: Extended Kalman Filter

EMG: Electromiografía

FC: Foot Contact

FES: Functional Electrical Stimulation

FO: Foot Off

HS: Heel Strike

IMU: Inertial Measurement Unit

IoU: Intersection over Union

ISw: Initial Swing

KRLS: Kernel Regularized Least Squares

LR: Loading Response

LSTM: Long Short-Term Memory

MEMS: Micro-Electro-Mechanical Systems

MLP: Multilayer Perceptron

MSt: Mid-Stance

MSw: Mid-Swing

PC: Parálisis Cerebral

PPV: Positive Predictive Value

PSw: Pre-Swing

RFT: Random Field Theory

ROM: Range of Motion

SAV: Shank Angular Velocity

SHAP: SHapley Additive exPlanations

SNC: Sistema Nervioso Central

SPM: Statistical Parametric Mapping

STFT: Short-Time Fourier Transform

TA: Tibial Anterior

TO: Toe-Off

TSt: Terminal Stance

TSw: Terminal Swing

1. Introducción

1.1 Contexto del análisis de la marcha y motivaciones del trabajo

El análisis de la marcha es una herramienta fundamental en el ámbito de la biomecánica y la rehabilitación, teniendo una especial relevancia en poblaciones con condiciones motoras complejas como la parálisis cerebral (PC). La PC afecta al control motor, provocando en algunos casos grandes alteraciones tanto en la postura como en el movimiento. Estas dificultades pueden influir negativamente en el desarrollo físico, social y psicológico, haciendo que disminuya la participación en actividades cotidianas y empeorando la calidad de vida de aquellos que las padecen (Shrader et al., n.d.). Existen diversos tratamientos destinados a mejorar la marcha, como la fisioterapia intensiva, la toxina botulínica, la radiofrecuencia y la cirugía, pero todos ellos requieren herramientas de evaluación objetivas y precisas que permitan cuantificar los cambios funcionales en los pacientes.

La tecnología ha abierto muchas puertas en este contexto. Hoy en día existen laboratorios equipados con sistemas de captura de movimiento basados en cámaras ópticas, cuyo objetivo es analizar la marcha humana con alta precisión, pero son bastante costosos y por lo tanto no accesibles para todos los hospitales. En contraposición a esto encontramos las unidades de medición inercial (IMUs), una alternativa portátil mucho más económica que nos permite registrar datos biomecánicos. Estos sensores hacen posible la recopilación de las posiciones articulares durante la marcha en tres dimensiones, ofreciendo así una visión completa del movimiento (Yin et al., 2025). Los datos de cinemática tienen una naturaleza continua y multidimensional, por eso hace unos años se los comenzó a analizar con Statistical Parametric Mapping (SPM). SPM proporciona un análisis completo y estadísticamente robusto al considerar el conjunto de datos como un continuo, en lugar de limitarse a puntos discretos. Esta característica lo hace ideal para analizar los patrones de movimiento dinámicos que existen en la marcha (Pataky, 2010).

Los informes médicos claros y estructurados son una herramienta esencial para los profesionales de la salud, ya que permiten un seguimiento preciso de los pacientes y facilitan la toma de decisiones terapéuticas. En este proyecto, se tiene como objetivo que dichos informes posibiliten la comparación y valoración de los resultados en distintos instantes temporales, favoreciendo así una visión longitudinal del estado del paciente. Además, se ha considerado la generación de versiones simplificadas para los propios usuarios con el fin de mejorar la comunicación de los resultados y recomendaciones tras la visita al área de rehabilitación.

Otro aspecto clave en el análisis de la marcha, que además tiene un gran interés clínico, es la segmentación del ciclo de la misma. Simplificando, la segmentación de la marcha es la división de las curvas articulares en diferentes fases. Esto es muy útil en la clínica ya que ayuda a detectar problemas concretos en cada parte del ciclo, pudiendo evaluar mejor cómo responde el paciente a las terapias. Esta información es especialmente relevante en la PC, donde las alteraciones motoras no se presentan de forma homogénea en todo el ciclo.

La motivación de este proyecto se centra en implementar SPM en Python para analizar la marcha de niños con PC. La información que nos proporcione SPM, será recopilada en informes generados de forma automática durante la consulta. Por otro lado, pero sin movernos del tema principal: el análisis de marcha, se segmentarán las curvas de cinemática con el fin de identificar alteraciones específicas en cada fase y evaluar la respuesta del paciente a las intervenciones.

1.2 Estado del arte

1.2.1 Statistical Parametric Mapping en biomecánica

Inicialmente SPM se creó para el análisis de neuroimágenes. Es un método estadístico que se aplica a datos continuos y permite determinar si entre ellos existen diferencias significativas manteniendo su forma. Anteriormente para realizar comparaciones se utilizaban puntos concretos, como el máximo, la media o la desviación estándar, lo que limitaba el análisis y en muchos casos daba resultados poco fieles a la realidad (Pataky et al., 2016). La falta de consideración de todas las características motivó la creación de SPM. Este enfoque evalúa los datos de manera continua y permite identificar regiones dónde hay diferencias significativas (no solo diferencia global), manteniendo en todo momento la estructura temporal. Existen numerosos trabajos que ya han aplicado SPM a sus señales de biomecánica. Resaltaremos tres de ellos que tienen gran similitud con el presente TFG:

- En el estudio de Aleksandrowicz y su equipo, tratan personas con artroplastia total de cadera. En él se usa SPM para detectar cambios en el patrón de marcha durante la rehabilitación, consiguiendo señalar tramos del ciclo donde mejora o empeora la cinemática (Aleksandrowicz et al., 2025).
- Otros investigadores utilizan SPM para comparar la marcha de pacientes con esclerosis múltiple y controles. Su objetivo es localizar las fases concretas del ciclo donde las desviaciones son significativas. Estos investigadores usan filtros *Butterworth* para eliminar el ruido de alta frecuencia y sincronizan los ciclos entre diferentes pruebas (Mestanza Mattos et al., 2023a).
- Un artículo publicado en el *Journal of Osteopathic Medicine* (Terrell et al., 2022) analiza los efectos de dos protocolos de tratamiento osteopático sobre la marcha de pacientes con enfermedad de Parkinson a través de SPM. Evalúa las diferencias cinemáticas en la marcha antes y después del tratamiento, destacando cambios en el rango de movimiento (ROM) de las articulaciones.

En otros trabajos, SPM se ha utilizado para comparar sistemas de adquisición de señales como ocurre en el artículo de Park & Yoon (Park & Yoon, 2021), en el que se validan IMUs frente a MoCap para análisis de marcha, confirmando que SPM es utilizado con muchos fines.

En resumen, SPM evita la pérdida de información contenida en los datos ya que considera su naturaleza continua. Además, al utilizar la teoría de campos aleatorios, controla la tasa de falsos positivos (determinar que existe un efecto cuando realmente no lo hay), haciendo que la posibilidad de que las diferencias identificadas sean por artefactos disminuya.

1.2.2 Segmentación de las fases de la marcha con métodos tradicionales de detección de eventos

La segmentación de la marcha es el proceso por el cual se divide un ciclo completo en diferentes fases con interés clínico. Son muchos los investigadores que han propuesto métodos con este fin. Para conseguirlo se puede partir de diferentes señales biomédicas, por lo que no todos los procedimientos son iguales. Las señales que permiten realizar esta tarea son:

- Señales de acelerometría y giroscopio obtenidas a través de IMUs (Lin et al., 2025; Vu et al., 2020).
- Señales cinemáticas obtenidas a través de IMUs. Por ejemplo, el mínimo de la flexoextensión captada por el sensor posicionado en la tibia es el contacto inicial (CI) (Fellin et al., 2010).
- Señales de electromiografía (EMG) (Yu et al., 2010).
- Señales obtenidas a través de plataformas de fuerza o plantillas de presión (Aqueveque et al., 2020).
- Señales espectrales: se utilizan en métodos como STFT (Transformada de Fourier de Tiempo Reducido) o wavelets. Detectan transiciones por cambios de energía en bandas. Por ejemplo, el impacto se representa a través de una alta frecuencia (Ji et al., 2019).
- Combinaciones de las señales anteriores (Wang et al., n.d.).

Dependiendo del tipo de señal, puede ser necesario un preprocesado a través de filtros para la eliminación de ruido o frecuencias no importantes. En algunos casos se requiere normalización, sincronización o suavizado. Después de revisar la literatura, podemos confirmar que predomina la segmentación de la marcha a través de la velocidad angular registrada por el sensor localizado en el pie y la tibia en el plano sagital (Taborri et al., 2016; Wu et al., 2020). Las razones de esto son:

- Periodicidad estable.
- Alta relación señal/ruido para impactos y transiciones.
- Posibilidad de algoritmos simples y robustos.

En caso de priorizar un único sensor, algunos artículos muestran que la velocidad angular de la tibia obtiene un error más bajo en la detección del CI y contacto terminal (CT) comparado con la velocidad vertical del pie, que muestra errores mucho mayores (Salminen et al., 2024a). Este posicionamiento, obtiene un registro alineado con la dirección de desplazamiento, lo cual facilita la segmentación automática de las fases de la marcha (Lin et al., 2025). Numerosos investigadores han identificado patrones característicos en esta señal estable y repetitiva entre ciclos, como picos, valles, cruces por cero y umbrales adaptativos, que se corresponden con los eventos clásicos (Lin et al., 2025). Por las razones anteriormente comentadas, nos centraremos en la señal de velocidad angular obtenida a través del sensor colocado en la tibia. A continuación, observamos en la figura 1 el esquema seguido por Salminen et al. (Salminen et al., 2024a) para segmentar la marcha a través de la velocidad angular de la tibia. En la parte superior de la imagen encontramos las posiciones de las piernas del sujeto analizado:




Fig. 1. Esquema seguido por (Salminen et al., 2024a) para la segmentación de la marcha.

Dual-Minima Algorithm del SAV (*shank angular velocity*) es un algoritmo que detecta dos mínimos locales característicos de la velocidad angular de la tibia por cada ciclo. Entre estos dos mínimos existe un máximo: el valle anterior al máximo se encuentra próximo al *toe-off* (TO) y el posterior al máximo, en torno al *heel strike* (HS). Existen otras variantes que usan el cruce por cero negativo (de valores positivos a negativos) para marcar el HS. Se han comparado estos métodos con los resultados de plataformas de fuerza obteniendo errores pequeños por lo que han sido adoptados en protocolos clínicos (Aftab & Ahmed, 2022a; Zahradka et al., 2020a).

En el trabajo de Lau H. y Tong K. (Lau & Tong, 2008) además de detectarse cruces por cero, se evalúan los cambios de pendiente (*rate-reversal*). Inicialmente detectan una gran cantidad de puntos, a los que posteriormente aplican umbrales, reduciendo así el número de ellos y eliminando aquellos que no dan demasiada información. Para la segmentación de la marcha patológica los umbrales de amplitud o pendiente son mucho más restrictivos, se añaden tiempos mínimos entre eventos y se fuerza una secuencia fisiológica. Dichos umbrales pueden adaptarse en función de la cadencia o de la variabilidad (Lau & Tong, 2008; Spaich et al., 2014). En la literatura, la mayoría de los estudios no detectan todas las fases que define el modelo clínico de Perry (J. Perry and J. M. Burnfield, 2010), si no que normalmente se detectan solo dos fases (apoyo y oscilación). Un número algo menor de estudios detecta tres o cuatro, normalmente añadiendo: *loading response* (LR) y *pre-swing* (PSw). Y muy pocos detectan las siete fases clásicas. Además, al revisar distintos trabajos, hemos observado que cada uno presenta descripciones diferentes.

1.2.3 Segmentación automática de las fases de la marcha con Deep Learning

Al igual que en el apartado anterior, comentaremos qué sensores existen para extraer los datos que posteriormente entrarán en la red:

1. Sensores inerciales

Destaca el uso de estos sensores en problemas similares al nuestro. Uno de los proyectos que trabaja con IMUs es el Sui y compañía (Sui et al., 2020), en el que emplean una sola unidad inercial fijada al dorso del pie. La información extraída se utiliza para dividir la marcha en *stance* y *swing* con una precisión de casi el 96%. Un trabajo más ambicioso es el PSO-CNN-LSTM (Zhang et al., 2025a) (siete IMUs) cuyo objetivo y características

son muy similares al nuestro, pero emplea adicionalmente EMG. Es capaz de segmentar siete fases alcanzando un 97% de *accuracy*.

Entre ambos trabajos existen numerosas configuraciones, por ejemplo:

- Cinco IMUs que dan información para agrupar dieciséis clases: distingue entre caminar y transiciones sentado-de pie y obtiene un 94% de exactitud (Y. Kim et al., 2025a).
- Otro sistema es DPF-LSTM-CNN para el que se posicionan seis IMUs (muslos, tibias y pies) obteniendo valores mayores al 97% de F1 en la fase de balanceo izquierdo (K. Liu et al., 2023a).

Las señales que estos sensores nos ofrecen pueden ser de diferentes tipos. La mayoría utiliza aceleraciones y velocidades tanto angulares como lineales.

2. Presión plantar

Las plantillas capacitivas *Pedar-X* eliminan errores a la hora de detectar dobles apoyos. Destaca en este punto el desarrollo de una CNN-BiLSTM que segmenta siete fases (Xia et al., 2023).

3. EMG y sinergias musculares

La EMG de superficie introduce información aproximadamente 120 ms antes que la cinemática, por eso existen modelos Bi-LSTM que, con este tipo de datos, consiguen distinguir *stance* de *swing* con un 92% de exactitud (Guerra et al., 2024).

4. Visión 2-D o 3-D

Otro grupo de investigadores (Halvorsen et al., 2025) fue capaz de programar una ResNet-50 con tres convoluciones y localizar el HS y TO con solo 0,55 cm de error medio, todo ello sin colocar sensores sobre el paciente.

5. Fusión multimodal

El modelo iP3T utiliza tres IMUs, dos plantillas de presión y hasta seis sensores de EMG además de un doble Transformer. Alcanza un 98,4% de F1 en seis pacientes post-ictus y 14 controles (Chen et al., 2024a).

Aunque ya han sido analizadas las posibles naturalezas de los datos, también es importante conocer si en trabajos previos se han estudiado pacientes y/o controles. En la mayoría de las bases de datos, encontramos sujetos sanos de entre 19 y 50 años. Una excepción es el paciente amputado transfemoral del trabajo del investigador Marcos Mazon (Marcos Mazon et al., 2022a) y los pacientes post-ictus del trabajo de iP3T (Chen et al., 2024a). Los tamaños de las bases de datos utilizadas oscilan entre 10 (K. Liu et al., 2023a) y 26 sujetos (Guerra et al., 2024). Cuando el número de sujetos es bajo se utilizan ventanas deslizantes que permiten generar millones de muestras y equilibrar las clases (K. Liu et al., 2023a). Todo lo anterior nos demuestra que no se suelen incluir pacientes y los trabajos que sí lo hacen es con un número muy reducido de ellos como en iP3T (Chen et al., 2024a) (6 pacientes post-ictus y 14 sanos). Otro aspecto a destacar es la división de los conjuntos de datos, predomina 70% *train*, 15% *validation* y 15% *test* (Guerra et al., 2024; K. Liu et al., 2023a).

A continuación, se mostrarán los rendimientos obtenidos por algunas redes neuronales existentes en la literatura: Un MLP (Multilayer Perceptron) de tres capas ocultas, alcanzó un 90,6% de *accuracy* en la segmentación binaria de apoyo y balanceo a partir del ángulo sagital de la rodilla (Di Nardo et al., 2020a). Otro trabajo con sensores angulares en la cadera y rodilla segmentó ocho fases y consiguió un 94,45% de tasa de acierto (D. X. Liu et al., 2016a). Arquitecturas más avanzadas como el clasificador KRLS (Kernel Regularized Least Squares) (Ma et al., 2019a) logró aproximadamente un 86% de precisión utilizando ángulos de cadera y rodilla. Por su parte, una combinación LSTM-CNN aplicada a seis articulaciones alcanzó un macro-F1 de 95,64%, mejorando hasta el 97,21% con el modelo DPF-LSTM-CNN (K. Liu et al., 2023a). Aunque son menos los trabajos que detectan eventos de la marcha en población pediátrica mediante redes neuronales encontramos algunos relevantes. Kim et al. entrenaron una Bi-LSTM (Long Short-Term Memory) con las trayectorias ópticas del talón y la puntera de 363 niños con PC, distinguiendo únicamente los eventos CI y TO con un error temporal de 10-13 ms (Y. K. Kim et al., 2022). De forma similar, Kidziński et al. aplicaron una LSTM unidireccional sobre datos de Vicon de 92 niños sanos y 86 con afecciones neurológicas (Kidziński et al., 2019a). Se aplicó en más de 9000 ciclos, de los cuales el 73% provenían de pacientes con PC, alcanzando un macro-F1 del 96,48% y errores temporales medios de 10-13 ms. En otro estudio incorporaron un acelerómetro en el tobillo de 48 niños de entre 8 y 14 años y diseñaron un clasificador CNN-GRU (Convolutional Neural Network – Gated Recurrent Unit) capaz de reconocer cuatro fases, alcanzando un 95% de *accuracy* (Yan et al., 2020). Estos estudios reflejan la tendencia que existe de modelos más simples (2-4 fases), aunque con precisiones altas.

Cuando se examinan los trabajos existentes, se observa que la elección de la arquitectura, el número de fases segmentadas y la señal de entrada condicionan el rendimiento. La arquitectura Bi-LSTM se ha posicionado como modelo de referencia, por otro lado, aquellos estudios que emplean atención multi-cabeza también se sitúan entre los mejores (Harris et al., 2022).

Finalmente, las métricas de evaluación en este campo se pueden agrupar en tres categorías (K. Liu et al., 2023a): métricas de clasificación nominal (*Accuracy* y Macro-F1), métricas de error temporal continuo (RMSE-*phase* y MAE en ms) y métricas operativas (porcentaje de transiciones válidas). Existe una fuerte heterogeneidad en la elección de métricas, lo que dificulta la comparabilidad entre estudios. Como señala Zhang, la ausencia de un estándar común compromete la extrapolación clínica de los resultados (Zhang et al., 2025a).

1.3 Recursos utilizados

Adquisición de datos y hardware

- IMUs: MTw Awinda Xsens.
- EMG: Trigno de Delsys.
- Vídeo: 3 iPads y 3 trípodes.
- Portátil de trabajo:
 - CPU: Intel® Core™ i7-1255U.
 - GPU: Intel® Iris® Xe Graphics.
 - Memoria RAM: 16 GB.

Almacenamiento: SSD Intel SSDPEKNU010TZH.

Sistema Operativo: Microsoft Windows 11 Home 64 bits.

Software de captura

- Xsens Motion Cloud.
- MVN Analyze Pro 2023.0: versión de pago del software MVN Analyze Record.
- Python (3.10). Entornos: PyCharm y Jupyter.
- Bibliotecas clave: numpy, pandas, scipy, matplotlib, spm1d (0.4.33), jinja2, wkhtmltopdf y tensorflow/keras (2.18.0).

1.4 Hipótesis y objetivos

1.4.1 Hipótesis

Para este trabajo se parte de la hipótesis de que incluir análisis SPM en los informes estandarizados de marcha de niños con PC obtenidos a través de IMUs permitirá ayudar a detectar cambios estadísticamente significativos entre el pre-tratamiento y el post-tratamiento. Adicionalmente, la aplicación de redes neuronales artificiales facilitará la segmentación de las curvas de cinemática en las distintas fases de la marcha, aportando información adicional para la valoración clínica del paciente.

1.4.2 Objetivos

Objetivo general

Desarrollar e implementar un algoritmo que permita generar de manera automática informes interpretables para niños con PC. En ellos se añadirá información sobre las diferencias estadísticamente significativas entre las posiciones articulares antes y después del tratamiento. Además, en este mismo lenguaje se programará una red neuronal para la segmentación de la marcha en siete fases que será entrenada con registros de nuestra propia base de datos, los cuales serán etiquetados a partir de un algoritmo basado en la velocidad angular.

Objetivos específicos

1. Construir y organizar una base de datos multimodal de marcha que incluya información cinemática, de EMG y de vídeo de sujetos con PC y controles, garantizando su privacidad y calidad para su uso en investigación.
2. Implementar un sistema automatizado de generación de informes clínicos que integre datos de consulta y resultados de análisis de marcha.
3. Desarrollar en Python un código que permita el análisis SPM de las posiciones angulares de cadera, rodilla y tobillo durante el ciclo de la marcha en niños con PC, incorporando comparaciones pre-intervención y post-intervención.
4. Diseñar y aplicar un algoritmo de segmentación de las siete fases de la marcha basado en la velocidad angular, utilizando los datos resultantes como entradas a una red neuronal que tendrá este mismo objetivo.

1.5 Estructura del documento

El trabajo se organiza en ocho capítulos:

Capítulo 1. Introducción. Se explica el contexto del análisis de la marcha y la motivación que ha dado lugar a este trabajo. Se incluye un estado del arte que abarca tres puntos: *(i)* Statistical Parametric Mapping en biomecánica, *(ii)* Segmentación de las fases de la marcha con métodos tradicionales de detección de eventos y *(iii)* Segmentación automática de las fases de la marcha con Deep Learning. Se detallan además los recursos utilizados y se expone la hipótesis y objetivos que guían este trabajo.

Capítulo 2. Análisis de la marcha en parálisis cerebral. Se resume la base clínica de la patología, necesaria para interpretar los patrones de marcha atípicos. Además, se define el ciclo normal de la marcha y sus fases junto con los parámetros espaciotemporales, curvas de cinemática articular, comparaciones normal vs patológico y EMG.

Capítulo 3. Materiales que han hecho posible la realización de este proyecto.

Capítulo 4. Metodología. Se explican los procedimientos llevados a cabo para la generación de informes automáticos y la segmentación de las fases de la marcha.

Capítulo 5. Resultados. En este capítulo se reúne todo lo obtenido: gráficas sincronizadas de EMG y cinemática, ejemplo de informe clínico, comparaciones de SPM y graficas de velocidad angular y cinemática segmentadas.

Capítulo 6. Discusión y limitaciones. Se comparan los resultados con trabajos existentes en la literatura y se exponen las limitaciones del presente TFG.

Capítulo 7. Conclusiones y trabajos futuros. Se comentan los hallazgos principales y se habla sobre las implicaciones tanto en el ámbito clínico como en el investigativo.

Capítulo 8. Bibliografía. Finalmente se muestran todas las referencias que han sido revisadas.

2. Análisis de la marcha en parálisis cerebral

2.1 Etiología, manifestaciones clínicas y clasificación de la parálisis cerebral

En este trabajo se utilizarán datos obtenidos de niños con PC y niños sin ninguna patología motora aparente. Por ello, es importante conocer la definición de esta enfermedad, su etiología, manifestaciones clínicas y clasificación. La PC se define como el trastorno del neurodesarrollo caracterizado por alteraciones del movimiento y la postura. Esta condición puede ser causada a través de una lesión o malformación no progresiva del cerebro en desarrollo. Sus manifestaciones clínicas y comorbilidades pueden cambiar con el tiempo (Sadowska et al., 2020). Se trata de la principal causa de discapacidad en la infancia (Papavasiliou et al., 2021), aunque su prevalencia varía mucho según el país que se analice, la estimación nacional es de entre 2 y 2.3 de cada 1.000 nacidos vivos (Nova-Díaz et al., 2025).

La PC surge debido a un desarrollo anormal o daño en el cerebro cuando el sujeto aún es un feto o lactante. El 80% de las veces se debe a causas prenatales, entre las más comunes encontramos malformaciones congénitas en el cerebro, infecciones uterinas, accidentes cerebrovasculares intrauterinos y anomalías cromosómicas. Si nos fijamos en las causas perinatales, es decir, durante el parto (10% / 15%), encontramos situaciones hipóxicas-isquémicas, infecciones del sistema nervioso central (SNC), accidentes cerebrovasculares e ictericias graves. Finalmente, los factores que pueden generar PC después del parto (5% /10%) son: traumatismos craneoencefálicos, infecciones del SNC, accidentes cerebrovasculares y anoxias cerebrales (falta de oxígeno) (Patel et al., 2020; Paul et al., 2022). La PC está directamente relacionada con la prematuridad, embarazo múltiple, restricción del crecimiento intrauterino, consumo materno de sustancias dañinas e hipoglucemia perinatal.

Las manifestaciones clínicas son variables dependiendo de la ubicación y gravedad de la lesión cerebral. Esta enfermedad se puede relacionar con comorbilidades como epilepsia, problemas musculoesqueléticos, discapacidad intelectual, dificultades en la alimentación, alteraciones visuales y trastornos de la comunicación (Graham et al., 2016). Los diagnósticos de esta enfermedad se basan en la historia del paciente y en la exploración física. Los clínicos evalúan antecedentes prenatales, perinatales y postnatales, además se les realiza una serie de pruebas que muestran si el paciente tiene un retraso en el desarrollo motor. En el estudio físico se evalúan diferentes puntos:

- Microcefalia o macrocefalia.
- Irritabilidad excesiva o escasa interacción social.
- Hipotonía o hipertonía (tono muscular bajo y tono muscular alto respectivamente).
- Espasticidad (rigidez muscular).
- Debilidad muscular.
- Persistencia de reflejos primitivos (reflejos de recién nacido).
- Hiperreflexia (reflejos osteotendinosos exagerados).

- Trastornos de la coordinación y el equilibrio.
- Fijación de las articulaciones en posiciones anómalas.
- Trastornos de la marcha.

Debido a que no todos los pacientes tienen la lesión ubicada en la misma zona ni con la misma extensión, la gravedad de los síntomas puede cambiar de unos a otros. Existen dos tipos de clasificaciones: en función de la alteración de la estructura cerebral y en función de la limitación de la actividad (Morris, 2007).

En función de la alteración de la estructura cerebral

- PC espástica: como ya se ha comentado antes, la espasticidad es la rigidez muscular y el principal síntoma de este tipo de PC. Su causa son las disfunciones en las células de la corteza cerebral motora, que afecta a la capacidad de controlar los músculos. Representa aproximadamente el 60-70% de los casos de PC.
- PC discinética o atetoide: aquellos que la padecen sufren movimientos involuntarios rápidos y descoordinados que se intensifican con la fatiga. Surge debido a alteraciones en la parte central del cerebro.
- PC atáxica: el daño del cerebelo compromete el equilibrio, generando inestabilidad en la marcha, incoordinación e hipotonía. La capacidad para caminar puede variar dependiendo del grado de afectación.
- PC mixta: ocurre cuando múltiples áreas del cerebro están lesionadas y por lo tanto se da una mezcla entre los tipos comentados anteriormente. Las manifestaciones pueden ser diversas.

En la figura 2 se muestra un esquema de las zonas afectadas en cada tipo de PC:



Fig. 2. Clasificación PC según el lugar de lesión..

En función de la limitación de la actividad

- Monoparesia: implica debilidad o falta de control muscular en una sola extremidad (brazo o pierna, no ambas). Si está afectada una pierna, la marcha será asimétrica.
- Hemiparesia: se caracteriza por debilidad o falta de control muscular en un lado del cuerpo (derecho o izquierdo de forma indiferente). En este caso están afectadas tanto las extremidades inferiores como las superiores. Al tener solo un lado afectado, su marcha es asimétrica.
- Diparesia: caracterizada por debilidad o falta de control muscular que afecta principalmente a las piernas. En algunos casos las extremidades superiores pueden no tener ningún síntoma. Al estar afectadas las piernas, estos pacientes tienen dificultad para andar y mantener el equilibrio.
- Triparésia: afectación motora de tres extremidades. Lo más frecuente son las piernas y un brazo.

- Tetraparesia: es la más grave pues afecta a las cuatro extremidades con mayor afectación en los brazos. Puede llegar a incluso al tronco generando problemas respiratorios o de deglución. Estos pacientes también tienen problemas para caminar.

En la figura 3 se pueden observar las zonas afectadas en cada tipo de PC según la limitación de la actividad:




Fig. 3. Clasificación PC según la limitación de la actividad (Graham et al., 2016).

Por último, el Sistema de la Clasificación de la Función Motora Gruesa (Gross Motor Function Classification System, GMFCS) es una escala global que estratifica la gravedad de la discapacidad en cinco niveles dependiendo de la capacidad funcional y la necesidad de dispositivos de movilidad (muletas, bastones, andadores o sillas de ruedas). En la figura 4 se muestran los siguientes niveles:

- Nivel I: camina sin limitaciones.
- Nivel II: camina con limitaciones.
- Nivel III: camina con ayuda de un dispositivo de sujeción manual.
- Nivel IV: movilidad autónoma muy limitada, puede requerir sistemas de propulsión motor.
- Nivel V: movilidad dependiente, requiere traslado en silla de ruedas manual.




Fig. 4. Sistema de la Clasificación de la Función Motora Gruesa.

2.2 Definición de la marcha y sus fases

La marcha es el proceso de locomoción bípeda propio del ser humano, donde los miembros inferiores, apoyados en el suelo, realizan un movimiento alternante para mantener la estabilidad y permitir el avance del cuerpo hacia delante. Existen dos periodos clave en la marcha: apoyo (pie en contacto con el suelo) y oscilación (pie no tiene contacto con el suelo). Dada la relevancia de la marcha en la vida diaria, los profesionales de rehabilitación necesitan herramientas para valorar su calidad. Por ello se han creado diversas escalas clínicas de evaluación de la marcha validadas en distintas poblaciones patológicas, entre las que se incluye la PC. Dentro de las escalas de evaluación visual, cuya principal ventaja es la accesibilidad al no requerir instrumental, destacan la *Visual Gait Assessment Scale* (empleada sobre todo en niños con PC) y la *Salford Gait Tool* (que describe la posición de cadera, rodilla, tobillo y tronco en niños con PC). Por otro lado, existen escalas que consideran parámetros biomecánicos, espaciotemporales y cinéticos, proporcionando resultados más objetivos, como la *Observational Gait Scale*, que puntúa la simetría en niños con PC. La elección de una u otra depende de la condición del paciente, de los aspectos de la marcha que se busquen analizar y de los recursos disponibles en cada centro sanitario.

A continuación, se explicará la marcha pediátrica no patológica: Un ciclo completo se define como el intervalo entre dos contactos consecutivos del talón del mismo pie con el suelo. Dentro de este ciclo se han establecido una serie de eventos sucesivos, lo que permite un análisis detallado tanto en individuos sanos como en aquellos con alteraciones motoras. Las dos fases principales anteriormente citadas son el apoyo que ocupa el aproximadamente 60% del ciclo y la oscilación que ocupa el 40%. Dentro de estas dos fases principales existen numerosas subfases:

1. Apoyo:

1. Contacto inicial / CI (0-2%): tiene lugar cuando el pie toca el suelo con el talón, marcando el inicio del ciclo.
2. Respuesta a la carga / LR (2-10%): el peso del cuerpo se desplaza hacia la extremidad que ha contactado con el suelo.
3. Apoyo medio / MSt (10-30%): El peso corporal se encuentra alineado sobre el pie de apoyo (máxima estabilidad).
4. Apoyo final / TSt (30-50%): hay una transferencia del peso hacia la parte delantera del pie, preparando así el cuerpo para el despegue. Esta finalizará cuando el pie contrario entre en contacto con el suelo.
5. Preoscilación / PSw (50-60%): se puede explicar como la fase de transición entre el apoyo y la oscilación. Se inicia con el contacto inicial del pie contralateral y termina cuando el pie ipsilateral se despegue completamente, es decir en esta fase ambos pies están en contacto con el suelo (doble apoyo), situación que no ocurre en la carrera. El final de esta fase se denomina *toe-off*.

2. Oscilación (la extremidad se mueve hacia adelante):

6. Oscilación inicial / ISw (60-73%): comienza con el despegue del pie y su aceleración va hacia adelante, haciendo que el cuerpo avance.
7. Oscilación media / MSw (73-87%): La tibia que se encuentra en el aire se posiciona perpendicular al suelo y por lo tanto ya no hay un avance efectivo.
8. Oscilación final / TSw (87-100%): Esta fase finaliza cuando el pie contacta nuevamente con el suelo, desacelerando con el fin de prepararse para el siguiente ciclo.

La figura 5 resume esquemáticamente las fases anteriormente explicadas (Cicirelli et al., 2022a):




Fig. 5. Fases de la marcha en un ciclo completo.

2.3 Parámetros espaciotemporales de la marcha

Dentro del análisis de marcha se incluyen numerosos parámetros espaciotemporales que son esenciales para valorar la eficiencia de los tratamientos y detectar situaciones que se alejan de lo cotidiano. Los más relevantes e incluidos en este estudio son:

- Cadencia: número de pasos por minuto.
- Longitud de paso: distancia entre el punto de CI del pie ipsilateral y el punto de CI del pie contralateral.
- Longitud de zancada: distancia entre el punto de CI de un pie hasta el siguiente CI del mismo pie.
- Tiempo de paso: tiempo entre el CI del pie ipsilateral y el CI del pie contralateral. Influye en la regularidad de la marcha.
- Tiempo de zancada: tiempo entre el CI de un pie hasta el siguiente CI del mismo pie.
- Anchura de paso: distancia entre los talones de ambos pies en apoyo. Cuanto más grande sea la anchura, más estabilidad tendrá el paciente evitando de esta manera el riesgo de caídas.

- Velocidad de marcha: distancia recorrida por unidad de tiempo. Disminuye con la edad y patologías neuromusculares.

En la figura 6 se muestran los parámetros espaciales más relevantes de la marcha, seguidamente, en la tabla 1 observamos los rangos típicos de niños de entre 6 y 12 años de los parámetros anteriormente explicados. Los datos han sido extraídos de múltiples estudios (Holm et al., 2009; Ito et al., 2022; Smith et al., 2016). Es necesario tener en cuenta que los valores varían con la edad, estatura y calzado.




Fig. 6. Parámetros espaciotemporales de la marcha.

Parámetro	Rango típico
Cadencia	122-130 pasos/min
Velocidad de marcha	1.09-1.35m/s
Longitud de paso	0.5-0.6m
Longitud de zancada	1.01-1.20m
Tiempo de paso	0.46-0.49s
Anchura de paso	8-9.5 cm

Tabla 1. Parámetros espaciotemporales de la marcha en niños sanos.

2.4 Curvas de cinemática durante la marcha

Para poder comprender este apartado necesitaremos tener ciertas nociones sobre los movimientos que realizan las articulaciones de la extremidad inferior:

- Flexión: es el proceso por el cual se acercan los segmentos, es decir, disminuye el ángulo de la articulación. La flexión del tobillo también se denomina dorsiflexión o flexión dorsal.
- Extensión: proceso por el cual aumenta el ángulo o el segmento vuelve desde la flexión hasta la posición neutra. La extensión del tobillo también se denomina flexión plantar.

Ambos movimientos están ilustrados sobre la figura 7:




Fig. 7. Movimientos de las articulaciones de la extremidad inferior en el eje sagital.

- Rotación interna: giro hacia la línea media alrededor del eje longitudinal (la rodilla y el pie apuntan hacia dentro). Cuando el pie realiza este movimiento se produce la eversión, haciendo que suba el borde lateral de esta parte del cuerpo y baje el medial.
- Rotación externa: giro en sentido opuesto a la línea media (la rodilla y el pie apuntan hacia fuera). Cuando el pie realiza este movimiento se produce la inversión, sube el borde medial y baja el lateral.
- Aducción: mover el segmento hacia la línea media en el plano frontal.
- Abducción: mover el segmento lejos de la línea media.

Estos movimientos aparecen representados en la figura 8:




Fig. 8. Movimientos de las articulaciones de la extremidad inferior en los ejes frontal y transversal.

Los tres planos con interés clínico aparecen en la siguiente imagen:

- Plano sagital: corta el cuerpo en izquierda-derecha (flexión/extensión).
- Plano frontal o coronal: corta el cuerpo en anterior-posterior (abducción/aducción).
- Plano transversal: corta el cuerpo en superior-inferior (rotación interna/externa).





Fig. 9. Planos con interés clínico.

El análisis cinemático estudia los movimientos de las diferentes articulaciones del cuerpo sin considerar las fuerzas que los generan. Una vez comentados los movimientos que realizan las articulaciones del miembro inferior, la definición de la marcha, las fases que la forman y los parámetros espaciotemporales que sirven para analizarla, es conveniente explicar el patrón cinemático de la pelvis, cadera, rodilla, tobillo y pie.

Durante la marcha, cada segmento de la pierna sigue una trayectoria específica en cada fase del ciclo permitiendo una locomoción eficiente y estable. El plano sagital es el más estudiado y en él predominan los movimientos de flexión y extensión. Sin embargo, también es relevante evaluar los desplazamientos en los planos frontal y transversal. Registrar las curvas de cinemática nos va a permitir visualizar las amplitudes articulares y su función en la marcha, lo que ayuda a identificar desviaciones o alteraciones en individuos con patologías. (J. Perry and J. M. Burnfield, 2010) ha sido la referencia principal para la descripción cinemática de la marcha:

- Pelvis: presenta oscilaciones de baja amplitud en los tres planos, esenciales para mantener el equilibrio dinámico y facilitar el avance del centro de masas.
- Cadera: su mayor movimiento se da en el plano sagital, con flexión en contacto inicial y oscilación y extensión en apoyo.
- Rodilla: sigue un patrón de doble flexión. Una primera tras el apoyo de talón para absorber impacto, una extensión parcial en apoyo medio para estabilizar y una segunda flexión en oscilación para acortar la extremidad.
- Tobillo: alterna entre dorsiflexión (progresión tibial) y flexión plantar (justo antes del despegue para la propulsión). También presenta movimientos en los otros planos que ayudan a la estabilidad en apoyo de un único pie.
- Pie: Cambia de dorsiflexión en el contacto inicial a flexión plantar en el impulso. Los movimientos en planos frontal y transversal permiten adaptación al terreno. Este elemento corporal pase de ser una estructura flexible para la absorción del impacto a una estructura rígida que permite la propulsión.

En la imagen inferior se muestran las curvas articulares extraídas de un artículo publicado en PeerJ (Fukuchi et al., 2018). En el eje horizontal se representa el vector de tiempo normalizado (un ciclo). Por otro lado, el eje vertical cuantifica los grados:






Fig. 10. Curvas de cinemática durante la marcha de las articulaciones del miembro inferior.

En próximos capítulos se hará un análisis más detallado de las curvas cinemáticas de los niños incluidos en nuestra base de datos, tanto de controles como ejemplos de pacientes.

2.5 Patrones de marcha patológica

La clasificación de los patrones de marcha en la PC se ha estudiado en múltiples trabajos, algunos de ellos parten de datos musculares y otros de datos cinemáticos. Papageorgiou (Papageorgiou et al., 2019) realizó una revisión sistemática acerca de las distintas clasificaciones que valoraba ambos tipos de datos. Se puede ver en la siguiente tabla:

Patrón	Características cinemáticas	Características electromiográficas
Genu recurvatum	Hiperextensión (extensión mayor a 180°) de la rodilla en la fase de apoyo	Extensores de rodilla: debilitados Flexores de rodilla: hipertónicos o espásticos
Equino Verdadero	Flexión plantar (extensión) excesiva (marcha de puntillas) e incapacidad de realizar dorsiflexión (flexión) completa. Puede llegar a haber hiperextensión de rodilla.	Gastrocnemio y sóleo: acortados y contraídos
Equino Aparente	Tobillo en posición de flexión plantar excesiva, aunque la articulación del tobillo no es patológica. Puede llegar a haber hiperextensión de rodilla.	TA y extensor común de los dedos del pie: debilitados
Pie Caído	Se arrastra el pie al caminar debido a la incapacidad de realizar dorsiflexión. El CI se da con la punta del pie. Para compensar esto los pacientes suelen levantar el muslo mientras flexionan la rodilla.	TA: debilitado

Marcha de salto	Salto durante las dos fases principales de la marcha. Flexión excesiva de rodilla y cadera en la fase inicial de apoyo, seguida de la extensión de las mismas en la fase final	Extensores de cadera, rodilla, tobillo y pie: debilitados
Marcha agachada	Hiperflexión de rodillas y caderas continua. Flexión dorsal excesiva durante la fase de apoyo	Extensores de cadera y rodilla: debilitados

Tabla 2. Patrones de marcha en PC.

Los patrones pueden solaparse, además existe cierta subjetividad en la detección debido a las leves diferencias, por lo que es útil el análisis instrumentado.

2.6 Electromiografía en la marcha

La EMG es el procedimiento por el cual se registra la actividad eléctrica que generan los músculos esqueléticos durante la contracción. Para los diagnósticos de PC es necesario su detección, análisis y procesado. Existen varios tipos de sensores que registran este tipo de señal, en nuestro caso se han utilizado sensores no invasivos (de superficie) que se colocan sobre la piel y miden la diferencia de potencial generada por la activación de las unidades motoras. La señal de EMG se registra cuando el impulso nervioso llega a la unión neuromuscular que provoca una liberación de acetilcolina y la posterior despolarización de la membrana de la fibra, de esta manera se propaga el potencial de acción que activa las miofibrillas. La forma y amplitud del impulso dependen de la unión neuromuscular, el diámetro y la profundidad de fibras, la fatiga que tenga el sujeto y la distancia al electrodo. Su contenido principal se encuentra en la banda de 20-500 Hz (Boyer et al., 2023), existiendo más energía entre 50-150 Hz.

Al trabajar con este tipo de señales debemos valorar los artefactos más comunes: interferencia de la red (50/60 Hz), movimiento de los electrodos, actividad cardiaca (cuánto más cerca del corazón mayor ruido) y *crosstalk* (señal de músculos adyacentes captada por el electrodo de interés) (Boyer et al., 2023). Otros aspectos que hacen variar la señal son la velocidad de la marcha, el terreno, la fatiga y por supuesto, diversas patologías.

Los músculos que intervienen en el proceso de la marcha son los siguientes:

- Cuádriceps / Recto femoral: respuesta a la carga.
- Isquiotibiales: final de oscilación e inicio de apoyo.
- Glúteo mayor: contacto inicial y respuesta a la carga.
- Glúteo medio: apoyo temprano-medio.
- Tibial anterior (TA): contacto inicial, respuesta a la carga y oscilación temprana y media.
- Tríceps sural (sóleo + gastrocnemio): apoyo medio-tardío y pre-oscilación.

En este trabajo no se profundizará en la señal de EMG pues no se requieren más nociones para la comprensión de los posteriores apartados. Aun así, en las siguientes figuras (11 y 12) se muestran los instantes de actuación de cada músculo durante la marcha y la localización del gastrocnemio y TA (músculos registrados en este trabajo):




Fig. 11. Actividad muscular durante un ciclo completo de marcha.




Fig. 12. Músculos de interés en este trabajo (gastrocnemio y TA).

3. Materiales

3.1 Equipamiento para el registro de señales de marcha

3.1.1 Principios de funcionamiento de las IMUs

Las IMUs (Unidades de Medición Inercial) son sistemas compuestos por acelerómetros, giroscopios y magnetómetros. Internamente combinan todas estas señales de tal manera que son capaces de estimar la posición, velocidad y orientación de un objeto en el espacio. Sus principios de funcionamiento son:

1. Acelerómetro MEMS triaxial

El acelerómetro MEMS (micro-electro-mecánico) triaxial cuenta con una masa que se suspende en micro-resortes. Cuando el dispositivo sufre una aceleración lineal en cualquiera de sus ejes, la masa se desplaza una distancia respecto a la referencia (Albarbar et al., 2008). El desplazamiento produce un cambio en la capacitancia que se puede medir gracias a los dos electrodos fijos que se localizan alrededor de la masa obteniendo así la aceleración instantánea.

En reposo, el vector gravedad se detecta en el eje vertical, permitiendo inferir inclinación estática (Albarbar et al., 2008). Es decir, cuando no hay aceleraciones dinámicas, la única aceleración que se mide es la gravedad que apunta siempre hacia el centro de la Tierra. Midiendo cómo se distribuye esa gravedad entre los tres ejes del acelerómetro, podemos calcular los ángulos de inclinación (*pitch* y *roll*) del sensor respecto al eje vertical.

2. Giroscopio MEMS triaxial

Mide la velocidad angular sobre una masa interna que vibra a una frecuencia determinada mediante el efecto Coriolis. Al girar el sensor con una velocidad angular, aparece una fuerza de Coriolis que desvía la vibración, cambiando la amplitud o fase. Esto se detecta de manera capacitiva o piezoeléctricamente y posteriormente se transforma a velocidad angular. Cuanto más rápido se gira el sensor, mayor será el desvío (Gill et al., 2022).

3. Magnetómetro triaxial

El magnetómetro mide el campo magnético terrestre en tres ejes, funcionando como una brújula. Pueden contener sensores de efecto Hall o magnetorresistivos. Los primeros detectan el campo magnético midiendo la tensión transversal (tensión Hall) generada por el desvío de cargas en un conductor, mientras que los segundos varían su resistencia en presencia del campo magnético. Permite estimar el *yaw* absoluto (eje vertical) además de corregir la deriva del giroscopio. Estos dispositivos sufren perturbaciones en entornos ferromagnéticos, por ello encontramos problemas al registrar pacientes con andadores metálicos (Ahmad et al., 2013).

Toda esta información debe fusionarse para realizar una buena estimación de la orientación 3D, para ello se utilizan principalmente dos algoritmos (Kok et al., 2017). El primero de ellos es el filtro de Kalman Extendido (EKF) el cual integra la velocidad angular para propagar la orientación y compara la gravedad y el vector magnético con las direcciones esperadas, realizando ajustes para minimizar errores (Sabatini, 2011). Por otro lado, el filtro complementario realiza una suma ponderada de la integración del

giroscopio y la estimación de inclinación obtenida del acelerómetro, siendo más simple computacionalmente hablando. Los movimientos *roll*, *pitch* y *yaw* se describen en la siguiente figura:




Fig. 13. Movimientos a través de los ejes principales x, y, z.

3.1.2 Xsens MVN Awinda

En este proyecto se han utilizado los sensores inerciales MTw (Motion Tracker Wireless) del sistema Xsens MVN Awinda, desarrollado por la compañía Xsens Technologies B.V. (actualmente Movella). Toda la información expuesta se ha extraído directamente del manual de Xsens (MVN User Manual, 2005).

MVN Awinda es un sistema de captura inercial diseñado con el fin de medir el movimiento corporal mediante 17 sensores denominados MTw. Internamente contienen acelerómetros, giroscopios y magnetómetros y están equipados con baterías recargables. Estos sensores se colocan sobre los pacientes por ello son pequeños y ligeros (47 x 30 x 13 mm y 16 gramos), lo que facilita su colocación y evita modificar el movimiento natural del paciente. Tienen una comunicación inalámbrica que llega hasta 50 metros en exteriores y 20 metros en interiores y permiten una sincronización temporal precisa (10 microsegundos).

Otro recurso que se incluye en el hardware es Awinda Station, un dispositivo clave para la recepción sincronizada de los datos provenientes de los MTw. Este dispositivo conecta los sensores y el portátil que ejecuta el software MVN Analyze. La estación Awinda puede manejar pérdidas temporales de datos gracias a un *buffer* interno que permite la retransmisión inmediata de paquetes perdidos. Incluso si se experimenta una desconexión momentánea, los sensores MTw siguen registrando internamente el movimiento tridimensional. MVN Analyze nos permitirá elegir qué sensores registrarán en cada grabación. Además, durante la adquisición, el software ofrece visualizaciones tridimensionales del avatar para monitorear la calidad de los movimientos registrados.

La frecuencia de muestreo del MVN Awinda es configurable, cuando se registra todo el cuerpo es de 60 Hz, mientras que, si solo se registra el tren inferior, la frecuencia es de 100 Hz (la utilizada en este estudio). El sistema emplea EKF, para combinar la información inercial. En cuanto a la precisión, se detalla que el máximo error es de 0.2° para los movimientos de *roll* y *pitch*, y de 0.5° para *yaw*.

El sistema entrega un amplio conjunto de variables biomecánicas que incluye: aceleración y velocidad lineal y angular, orientación en cuaterniones y ángulos de Euler, centros de masa, parámetros espacio-temporales... Además es compatible con múltiples plataformas

de software como MVN Animate, Unity, MATLAB y OpenSim. En las siguientes figuras se muestra el sensor inercial junto con su sistema de referencia, Awinda Station y varias ventanas del Software de MVN Analyze:




Fig. 14. Sensor inercial MTw junto con su sistema de referencia y Awinda Station.




Fig. 15. Software MVN Analyze.




Fig. 16. Software MVN Analyze durante un registro.

3.1.3 Ventajas y limitaciones de las IMUs frente a otros métodos de obtención de señal de marcha

El principal competidor de las IMUs son los sistemas ópticos basados en cámaras y marcadores. Algunas de las ventajas que ofrecen las IMUs son:

- Portabilidad y facilidad de uso: permiten realizar mediciones fuera del laboratorio, en entornos naturales o clínicos (Prisco et al., 2025). Los sensores inerciales son compactos, ligeros, fáciles y rápidos de colocar, esto es especialmente útil en pediatría, donde las condiciones del entorno pueden influir significativamente en su comportamiento. A diferencia de los sistemas ópticos, las IMUs permiten la evaluación de la marcha en entornos cotidianos, proporcionando datos más representativos del comportamiento natural del sujeto.
- Resistencia a la pérdida de datos: mientras que los sistemas ópticos requieren una línea de visión constante entre las cámaras y los marcadores (lo que puede interrumpirse fácilmente con movimientos rápidos, ropa o interferencias), los sensores inerciales no dependen de este tipo de visibilidad, pues permiten registrar movimiento de manera continua y sin interrupciones.
- Sistemas más económicos: facilita su implementación en diversas instituciones y estudios con presupuestos limitados (He et al., 2024).

Aunque no es una ventaja frente a los sistemas ópticos porque estos también lo incluyen, es preciso comentar que los datos obtenidos a través de las IMUs incluyen marcas de tiempo absolutas, lo que permite sincronizarlos con precisión con otros dispositivos biomédicos.

Además de IMUs y sistemas ópticos 3D, se pueden realizar exámenes de marcha con plataformas de fuerza (miden fuerzas de reacción del suelo, momentos y centros de presiones). Las ventajas que encontramos de las IMUs vs estos dispositivos son:

- Portátiles: las plataformas de fuerza suelen estar instaladas en salas y no se suelen poder transportar. Tanto es así que muchas veces estas plataformas se encuentran mimetizadas con el entorno para evitar que el sujeto varíe su patrón de marcha al verlas.
- Muchos pasos seguidos: las IMUs permiten grabar toda la caminata al contrario que las plataformas que solo graban un par de pasos (suelen ser muy cortas). Es conveniente destacar que al grabar toda la caminata capturamos la variabilidad.
- Los datos que devuelven son distintos, las IMUs capturan ángulos y las plataformas, vectores de fuerzas.
- Costosos: como ya se ha comentado las plataformas se suelen integrar en el propio suelo de la sala del laboratorio por ello su montaje no es inmediato ni tampoco barato.
- Para obtener mediciones válidas, el pie debe impactar exactamente sobre la plataforma. La superficie instrumentada ocupa solo una parte del trayecto por lo que es necesario planificar la salida para asegurar el apoyo (puede introducir sesgos).

Pese a sus ventajas, los sistemas inerciales también presentan limitaciones:

- Acumulación de errores por integración, especialmente al estimar posición o desplazamiento en el espacio. Debido a su naturaleza, los acelerómetros y giroscopios pueden generar pequeñas desviaciones que, al integrarse a lo largo del tiempo, producen errores significativos (Neto et al., n.d.). Este fenómeno, conocido como *drift*, puede limitar el uso de los sensores inerciales.
- Artefactos por movimiento de tejidos blandos: si los sensores no están correctamente fijados o si se colocan sobre zonas musculares o con grasa subcutánea pueden devolver valores poco precisos. Aunque esta limitación puede mitigarse con una colocación adecuada (colocando sobre hueso), sigue siendo un factor a considerar (Radhakrishnan et al., 2025). La precisión de los datos obtenidos depende en gran medida de la correcta colocación y fijación de los sensores.
- Algunos parámetros pueden requerir métodos adicionales o combinaciones con otros sistemas para una estimación precisa (He et al., 2024).
- Perturbaciones magnéticas que generan una gran necesidad de recalibraciones frecuentes.
- No ofrecen una representación tridimensional visual directa.

Aun así, estudios recientes han demostrado que los IMUs ofrecen una excelente fiabilidad en la medición de parámetros como la velocidad de marcha, la cadencia y las fases de apoyo y oscilación (He et al., 2024).

3.2 Creación y gestión de la base de datos

Al inicio de la memoria se planteó como objetivo la recopilación de un conjunto de datos de población pediátrica para el estudio de la marcha. Este *dataset* contiene numerosos tipos de datos: medidas anatómicas, registros con extensión *.mvn*, información cinemática (posiciones articulares, velocidad angular, centros de masas...), señales de EMG y videos de los pacientes caminando. Los registros se realizaron en la Unidad de Rehabilitación del Hospital Universitario Río Hortega (Valladolid, España). Participaron tanto niños sin patología motriz aparente como niños con PC cuyas edades estaban comprendidas entre los 4 y los 16 años. Los pacientes debían hasta una marca, girar y volver al lugar de inicio. Este conjunto de datos ha servido para entrenar y testear la red implementada en el proyecto, realizar la sincronización entre los datos de EMG y cinemática y comprobar el código de Python que genera automáticamente los informes.

3.2.1 Selección de sujetos

Los participantes fueron reclutados en el área de Rehabilitación Pediátrica del Hospital Universitario Río Hortega. El estudio se centró en niños con trastornos de la marcha debidos a PC que tenían programada una intervención terapéutica.

Los criterios de inclusión fueron los siguientes:

- Niños de entre 4 y 16 años.
- Niños con diagnóstico de PC (conjunto de pacientes). Estos debían ser capaces de caminar y tener suficiente capacidad cognitiva para participar y seguir nuestras indicaciones.

-
- Niños con marcha aparentemente normal (conjunto de controles).
 - Todos los tutores legales de los niños debían autorizar la participación en el estudio.

El protocolo buscaba realizar tres sesiones por cada intervención de cada paciente, esto no quiere decir que por paciente haya un máximo de tres registros, ya que desde 2024 (inicio de la recopilación de datos), la mayor parte de los pacientes han sufrido varias intervenciones, además en cada consulta se realizan al menos dos registros. La explicación del protocolo realizado con los pacientes es la siguiente:

1. Los pacientes incluidos en la base de datos fueron seleccionados por la Dra. Beatriz de la Calle García durante las evaluaciones de rehabilitación rutinarias.
2. Se explicó el proyecto de forma clara y detallada a los tutores legales de los pacientes, los cuales tuvieron que rellenar un formulario de consentimiento informado después de leer una hoja con la información relevante.
3. Se realizó una valoración clínica inicial que incluyó, entre otros aspectos, la exploración de las articulaciones, la musculatura, el control motor y la espasticidad, además de un análisis visual de la marcha.
4. En la primera sesión se realizó una evaluación inicial de la marcha con los sensores inerciales y de EMG (T0). Esta sesión se realiza antes del tratamiento, lo más próximo posible.
5. La intervención prescrita (inyección de toxina botulínica, bloqueo nervioso, yeso, neuromodulación...) se administró de acuerdo con los protocolos clínicos.
6. Se realizó un segundo registro de la marcha (T1) entre dos y tres semanas después de la intervención.
7. Finalmente, se llevó a cabo otro registro de seguimiento (T2) después de tres meses o más de la intervención para evaluar si los efectos de tratamiento seguían siendo visibles a lo largo del tiempo.

Por otro lado, el protocolo de reclutamiento de sujetos de control difiere ligeramente del anterior ya que solo se hace una evaluación, pues no se someten a ningún tratamiento:

1. Los niños voluntarios fueron reclutados mediante carteles informativos y formularios de inscripción.
2. Al igual que en el caso anterior, se explicó el estudio a los tutores y se obtuvo el consentimiento informado.
3. Los participantes se sometieron a una única sesión de registro de la marcha (C0), siguiendo las mismas instrucciones que las utilizadas con el primer grupo.

3.2.2 Comité Ético

Dado que este proyecto involucra pacientes, se obtuvo la aprobación del Comité Ético antes de iniciar la recogida de datos. El estudio se llevó a cabo en el Hospital Universitario Río Hortega (Valladolid, España) bajo el protocolo de referencia 22-PI125, que recibió la aprobación del Comité de Ética en Investigación Clínica con Medicamentos (CEIM), Área Sanitaria de Valladolid Oeste, en marzo de 2023. Además, antes de participar, todas las familias recibieron información tanto oral como escrita sobre los objetivos,

procedimiento y pruebas a realizar en el estudio y sus dudas al respecto fueron aclaradas por los profesionales. Se recogieron por escrito todos los consentimientos informados de los tutores legales de los niños participantes.

El estudio implicó el procesamiento de señales biomédicas consideradas datos de categoría especial en virtud del Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo (Reglamento General de Protección de Datos, RGPD). Todos los procedimientos de tratamiento y procesado de las mediciones cumplieron con los requisitos establecidos por la Ley de Investigación Biomédica y la Ley Orgánica 3/2018, garantizando así el pleno cumplimiento de la legislación nacional y europea en materia de protección de datos.

3.2.3 Protocolo de adquisición

A la hora de realizar las adquisiciones, se utilizaron dos ordenadores portátiles de forma paralela: uno trabajaba con Trigno Discover 1.6.5 (Delsys) conectado a los sensores de EMG y otro que tenía descargado MVN Analyze controlaba los sensores inerciales.

Fueron cuatro sensores inalámbricos (Trigno Avanti) los que recogieron las señales de electromiografía y ocho sensores inalámbricos (Xsens Awinda) los que recogieron la información inercial (cinemática). Además, en la habitación se colocaron tres iPads en puntos estratégicos que tenían como finalidad grabar al paciente caminando desde distintos ángulos: uno grababa la vista sagital y los otros dos registraban al paciente de espaldas en la primera mitad del registro y de frente en la segunda mitad. Aunque estas grabaciones de vídeo forman parte del protocolo de adquisición y se han incluido en la base de datos comentada, no se utilizaron en el actual estudio.

Para garantizar mediciones precisas y reproducibles, los sensores se localizaron en puntos específicos del cuerpo siguiendo directrices anatómicas estandarizadas y las pruebas funcionales siempre eran las mismas (States et al., 2021). Estas posiciones se ilustran sobre la figura 17:




Fig. 17. Colocación sensores inerciales y de EMG.

Las unidades de medición inercial fueron colocadas según las recomendaciones del equipo de Xsens (Movella, s.f.):

1. Sensor del esternón: Colocado en el bolsillo frontal del chaleco (incluido en el kit) que asegura una fijación firme, evitando que se desplace.
2. Sensor en la pelvis: Colocado en la parte posterior de la pelvis (vértebras lumbares L3-L5), a la altura de la espina ilíaca anterosuperior, orientado verticalmente.
3. Sensores en los muslos: en la zona lateral del muslo, entre el tercio superior y tercio del medio del muslo. Esta localización puede ser crítica ya que tiene más tejido adiposo que otras, haciendo que los sensores no estén tan fijos. Puede aparecer lo que se denomina artefacto de tejido blando (Radhakrishnan et al., 2025).
4. Sensores en las tibias: Se colocan sobre la zona anterior superior plana de la tibia. Mitternacht y compañía (Mitternacht et al., 2022) destacan que el borde óseo de la tibia es la ubicación preferida para colocar sensores inerciales, ya que la tibia se encuentra justo debajo de la superficie de la piel, con pocos músculos u otras estructuras de tejido blando.
5. Sensores en los pies: sobre el dorso de cada pie.

Los electrodos de EMG por su parte, se colocaron en los músculos TA (número 6 en la siguiente figura) y gastrocnemio medial (número 7 en la siguiente figura), seleccionados por su relevancia en la marcha y su fácil acceso a ellos. La colocación de los sensores siguió las directrices definidas por el proyecto SENIAM (Hermens, 2000). El sensor del TA se coloca a un tercio del camino entre la punta del peroné y el hueso del tobillo interno, y el del gemelo medial en la protuberancia que más sobresalga de la pantorrilla.

Tanto los sensores inerciales como los de EMG se adhieren firmemente al cuerpo ya sea a través de las cintas elásticas ajustables que proporciona Xsens como a través de esparadrapo en los de EMG. De esta manera evitamos desplazamientos que puedan introducir ruido, artefactos o pérdida de señal. Un estudio publicado en el *Journal of Biomechanics* recalca que para obtener datos cinemáticos de alta precisión es crucial que los sensores estén ajustados firmemente al segmento corporal (Leardini et al., 2005).

El procedimiento de adquisición de datos se cuidó con detalle con el fin de garantizar la coherencia entre las sesiones y la comparabilidad entre distintos sujetos. Como se ha señalado anteriormente, las señales EMG, cinemáticas y de vídeo se registraron simultáneamente. Resumidamente los pasos que se siguieron para la toma de datos fueron:

1. Los pacientes preferiblemente acudían con ropa cómoda (pantalón corto de chándal) para evitar que interfiriera con la colocación de los sensores.
2. Antes de la llegada del sujeto, realizabamos una comprobación del funcionamiento de los sensores y los iPads. La sala debía prepararse para la correcta realización de las pruebas: despejar el camino, colocar marcas, colocar iPads en trípodes marcados y abrir las herramientas necesarias (Xsens MVN 2023.2, Trigno Discover y Excel).

3. El siguiente paso consistía en dar una explicación sobre el estudio y las pruebas a realizar, así como firmar el consentimiento informado en aquellos casos en los que no se hubiera hecho con anterioridad. Es importante destacar que, tanto en pacientes como en controles, se asignó un código de identificación para proteger su privacidad y no tener que trabajar con sus nombres y apellidos.

4. En el Excel se añadió además del anterior código identificativo, la fecha de nacimiento, sexo, peso, lado dominante y medidas corporales necesarias para la calibración de Xsens (altura total, altura de hombros, altura de cadera, altura de rodilla, altura de tobillo, envergadura, distancia entre muñecas, distancia entre codos, anchura de hombros, anchura de cadera y longitud de pie). En el caso de los participantes con PC, también se recopiló información clínica adicional como la fecha de la intervención o el tipo de patología.

5. En primer lugar se colocaban los electrodos de EMG en los músculos TA y gastrocnemio medial en ambos miembros con ayuda de ultrasonidos si no estaba clara la localización. Posteriormente, se ubicaban los sensores cinemáticos.

6. En el caso de los sensores de EMG, se evaluaba la calidad de la señal en cada paciente para garantizar que el ruido se mantuviera por debajo de 10-15 mV, en el caso de que esto no fuera así, se ajustaba la colocación de los electrodos.

7. Para el correcto funcionamiento de los IMUs es necesario realizar una calibración siguiendo el método recomendado por XSens denominado "Npose + walk": el participante se colocaba en posición neutra, es decir, erguido con los pies separados y paralelos a la anchura de los hombros y con los brazos pegados al cuerpo. Luego, el sujeto debía caminar de forma natural durante 10 segundos y finalmente, regresar al punto inicial manteniendo nuevamente la posición neutra hasta concluir la calibración. El *segment calibration* permite al software alinear correctamente la orientación del sensor con cada segmento corporal específico, aumentando la reproducibilidad de las mediciones cinemáticas obtenidas. Después, se pedía caminar al sujeto para asegurarnos que el esqueleto del *software* realizaba los mismos movimientos que el paciente.

8. Después de esto, ya se podían realizar las pruebas. Se contaba hasta cinco: al inicio de la cuenta comenzaban a registrar los sensores de EMG, cuando se llegaba a tres, los inerciales y el niño comenzaba a caminar al terminar la cuenta. En el caso de los videos, se empezaba a grabar cuando se veía por pantalla al sujeto. El recorrido consistía en caminar hasta un objeto visible, previamente indicado y posteriormente regresar al punto de partida. La persona debía caminar a un ritmo normal, intentando no arrastrar los pies, sin correr, ni ir muy despacio ya que si no el posterior procesamiento daría error. Como se ha comentado, siempre se realizaban al menos dos adquisiciones y en el caso de que en alguna diera problemas, se repetía.

9. Una vez finalizada la prueba, se retiraban todos los sensores y el paciente podía irse.

A continuación, se añade en la figura 18 una foto y un esquema de la sala de registro y en la figura 19 se observa la colocación de ambos sensores sobre un paciente real:




Fig. 18. Sala del área de Rehabilitación Pediátrica del Hospital Universitario Río Hortega junto con esquema de la prueba pedida.



Fig. 19. Sensores de EMG e inerciales colocados.

3.2.4 Descripción de la base de datos

La base de datos adquirida contiene a un total de 46 participantes pediátricos, siendo 25 sujetos de control sin anomalías en la marcha y 21 diagnosticados con PC. Dentro del grupo con PC, no todos los sujetos tienen la misma situación patológica. Se incluyeron 4 presentaciones clínicas: 6 pacientes con hemiparesia derecha, 5 con hemiparesia izquierda, 9 con diparesia y 1 con monoparesia izquierda. Las siguientes tablas resumen las características clínicas de los participantes:

Paciente	Sexo	Diagnóstico	Lado dominante
P01	H	Hemiparesia derecha	I
P03	H	Hemiparesia izquierda	D
P04	H	Hemiparesia derecha	I
P07	H	Hemiparesia izquierda	D
P08	H	Hemiparesia izquierda	D
P09	H	Monoparesia izquierda	D
P10	H	Hemiparesia derecha	I
P11	H	Hemiparesia derecha	I

P15	H	Diparesia	D
P17	M	Hemiparesia derecha	I
P31	H	Hemiparesia derecha	I
P32	H	Hemiparesia izquierda	D
P33	H	Diparesia	D
P34	H	Diparesia	D
P36	M	Diparesia	D
P37	M	Diparesia	I
P38	H	Diparesia	D
P39	M	Diparesia	D
P40	H	Diparesia	D
P41	H	Diparesia	I
P42	M	Diparesia	D

Tabla 3. Resumen de características de los pacientes incluidos en la base de datos.

Sujeto	Sexo	Lado dominante
S01	H	D
S02	H	D
S03	H	I
S04	M	I
S05	H	D
S06	M	D
S07	M	D
S08	M	D
S09	H	I
S10	H	D
S11	H	D
S12	H	D
S13	M	I
S14	H	D
S15	M	I
S16	H	I
S17	H	D
S18	M	D
S19	H	D
S20	M	D
S21	H	D
S22	H	I
S23	M	D
S24	M	D
S25	M	I

Tabla 4. Resumen de características de los voluntarios sanos incluidos en la base de datos.

3.2.5 Generación de curvas normativas de nuestra base de datos

En el segundo capítulo de este TFG se presentó una introducción general a las curvas cinemáticas del miembro inferior durante la marcha. En el presente apartado se llevará a cabo una descripción más detallada que incorpora además los ROM obtenidos en los sujetos control incluidos en nuestra base de datos:

1. Cinemática de la pelvis durante la marcha:

- Plano sagital (flexo-extensión): se extiende la primera mitad del ciclo y se flexiona la otra mitad.
- Plano frontal (aducción/abducción): poca variación. Rango entre 5° y -5° .
- Plano transversal (rotación externa/rotación interna): Varía mucho dependiendo del sujeto.

2. Cinemática de la cadera durante la marcha

- Plano sagital (flexo-extensión): En el contacto inicial, la cadera se encuentra en una posición de flexión de aproximadamente 30° . A medida que el cuerpo avanza en la fase de apoyo, la cadera comienza a extenderse, alcanzando su máxima extensión (10° o si tenemos en cuenta el signo, -10°) en el apoyo final. Posteriormente, durante la fase de oscilación, la cadera inicia un movimiento de flexión progresiva, alcanzando nuevamente los 30° de flexión en la oscilación final donde se estabiliza durante poco tiempo.
- Plano frontal (abducción-aducción): el rango máximo en este plano es de 8° a -8° . Parte de una situación de abducción, pero rápidamente cae. Podríamos decir que en la fase de apoyo la cadera se encuentra la mayor parte del tiempo en aducción y en el periodo de oscilación en abducción.
- Plano transversal (rotación interna/externa): es el plano en el que menos diferencia se ve. El rango varía entre 5° y -10° .

3. Cinemática de la rodilla durante la marcha: clave en la absorción del impacto y en la adaptación al terreno.

- Plano sagital (flexo-extensión): En el contacto inicial, la rodilla presenta una ligera flexión pocos grados (aproximadamente 5°). A medida que avanza la fase de apoyo, la flexión aumenta hasta 20° , facilitando la absorción del impacto. En el apoyo medio y final, la rodilla se extiende gradualmente llegando en algunos casos hasta la posición neutra. En la fase de oscilación inicial, la rodilla se flexiona hasta su máximo de $60^{\circ}/65^{\circ}$, permitiendo el avance del pie sin que este arrastre por el suelo, evitando así los tropiezos. En la oscilación final, la rodilla vuelve a extenderse para preparar el siguiente contacto con el suelo.
- Plano frontal (valgo (abducción)/varo (aducción)): Durante la marcha, la rodilla presenta ligeros movimientos en este plano, con una amplitud máxima de 6.5° y mínima de -7.5° . Primeramente se genera un ligero varo, seguidamente progresa hasta un valgo de 6.5° grados de amplitud. En la fase final se genera una aducción de 7.5° que vuelve al estado inicial.
- Plano transversal (rotación interna/externa): En la fase de apoyo, la rodilla experimenta una rotación interna. Posteriormente, a medida que el pie se despega del suelo, la rodilla gira externamente para estabilizar la pierna en la oscilación final.

4. Cinemática del tobillo durante la marcha: El tobillo juega un papel esencial en propulsión.


- Plano sagital (flexión dorsal/flexión plantar (extensión)): En el contacto inicial, el tobillo se encuentra en posición neutra. Dentro de la primera subfase de apoyo, el pie realiza una dorsiflexión, facilitando la adaptación al suelo. Justo antes del despegue el tobillo se extiende (flexión plantar) y en la fase de oscilación el tobillo

se flexiona permitiendo que el pie no choque con el suelo. Finalmente vuelve al estado neutro.

- Plano frontal (aducción/abducción): varía poco, normalmente se encuentra en un estado neutro, habiendo un paso de abducción a aducción antes de la fase de oscilación.
- Plano transversal (rotación externa/rotación interna): El ángulo comienza disminuyendo, aunque rápidamente sube generando un pico en el cambio entre apoyo y oscilación y luego se estabiliza.

5. Cinemática del pie durante la marcha: solo se registra los datos del plano frontal. El pie suele ir bastante paralelo al eje, excepto en la transición entre las dos fases principales, que como vemos hay sujetos que lo desvían hacia fuera y otros hacia dentro.

Toda la información anterior se ve reflejada en las gráficas de la figura 20. Estas recogen la media y la desviación estándar de los parámetros biomecánicos correspondientes a los niños sanos incluidos en nuestra base de datos. Como podemos observar su variabilidad resulta considerable incluso siendo sujetos sin patología. Es importante señalar que las edades de estos participantes oscilan entre los 4 y los 16 años, aspecto a tener en cuenta por ser la marcha un proceso que cambia con la edad.






Fig. 20. Posiciones articulares de la extremidad inferior a lo largo de un ciclo completo en los tres ejes del espacio.

El eje más analizado por los médicos es el sagital y las articulaciones que más información ofrecen son la cadera, rodilla y tobillo.

Las gráficas articulares de un paciente con PC (azul) junto con la desviación de los datos obtenidos de controles (nube gris) se muestran en la figura 21. Estas gráficas sirven para ejemplificar a continuación el tipo de interpretaciones que puede realizar el personal clínico:

Comparaciones curvas de cinemática de la pelvis: la mayor diferencia se ve en el eje sagital, existe una mayor basculación posterior en la mitad final del ciclo (curva azul más negativa que la banda gris), esto se corresponde con el patrón de tilt aumentado (inclinación de la pelvis en el plano sagital). En el eje frontal no hay grandes diferencias, la curva azul se encuentra dentro de la banda gris, mientras que en el eje transversal se muestra una permanente rotación interna.


Comparaciones curvas de cinemática de la cadera: en este caso la mayor diferencia se observa en el eje transversal en el cual se puede ver que el paciente seleccionado se encuentra en rotación interna durante todo el ciclo. Por otro lado, en el eje frontal vemos más abducción en la parte media-final del ciclo (azul por encima de la banda).

Comparaciones curvas de cinemática de la rodilla: en el eje sagital vemos una escasa flexión de carga tras el contacto, además este sujeto tiene tendencia a la extensión o hiperextensión (Genu recurvatum) en el apoyo medio. La flexión en la oscilación existe, pero en menor medida y retardada. Respecto a los otros ejes podemos afirmar que existe una rotación interna aumentada hacia el 60-80% del ciclo y que no genera grandes abducciones ni aducciones.

Comparaciones curvas de cinemática del tobillo: déficit de flexión en el apoyo visto en el eje sagital y una extensión excesiva retardada. Este tipo de pacientes no realizan una dorsiflexión completa al inicio del ciclo y además efectúan una flexión plantar muy pronunciada en torno al 80% (azul por debajo de la banda gris, pie caído y equino).

verdadero). El pie se encuentra constantemente en rotación interna y realiza más aducción de lo que debería.

Comparaciones curvas de cinemática del pie: En frontal aparece aducción brusca.






Fig. 21. Posiciones articulares de la extremidad inferior durante un ciclo completo de marcha (patrón patológico vs. típico).

3.2.6 Sincronización de señales de cinemática y electromiografía

Una aportación adicional de este TFG, con claras proyecciones futuras, es el planteamiento de un procedimiento de sincronización entre las señales de EMG y los registros cinemáticos. Esta contribución se enmarca en una línea futura orientada a incorporar a la red neuronal información de la actividad muscular, dado que la literatura explica mejoras con ella. Para hacerlo viable, resulta imprescindible garantizar la sincronización precisa entre las señales de EMG y las cinemáticas. Por otro lado, tener esta información puede ser de gran interés para médicos, que podrán comparar las curvas de cinemática y de EMG de un paso concreto. Esta sincronización es un apartado que se ha incluido en la base de datos anteriormente comentada porque creemos que puede ser de gran provecho para otras investigaciones. Remarcamos que existen herramientas comerciales que llevan a cabo este proceso, pero para utilizarlas se requieren licencias caras.

A continuación, hablaremos sobre el algoritmo creado con este fin: este procedimiento se basó en las señales de velocidad angular registradas por los sensores de EMG situados en el TA y las IMU situadas sobre la tibia. Asumimos que los datos registrados son comparables ya que existe una gran proximidad anatómica entre ambos puntos y por lo tanto la dinámica angular es similar. Al graficar las señales cinemáticas, se identificó un problema relacionado con el sistema de referencia utilizado por las IMU de Xsens: a diferencia de los sensores de EMG, que registran datos en su sistema de coordenadas local, las IMUs proporcionan mediciones en un sistema de coordenadas global. Esta diferencia de sistemas de referencia provocó que la primera mitad de la señal apareciera invertida. La explicación de esta inversión se debe al giro que realizan los pacientes para volver al punto de inicio. Para corregirlo se multiplicó por -1 el segmento anterior al giro haciendo que coincidieran ambas señales. La detección de este punto fue posible gracias a la aplicación de un filtro de varianza móvil. En la figura 22 se muestra la señal original de velocidad angular registrada a través del sensor inercial colocado en la tibia y el resultado de aplicarle el filtro de varianza móvil, posteriormente en la figura 23 se observa el resultado de la inversión de la primera mitad del registro:




Fig. 22. Señal de velocidad angular original y resultado de la aplicación del filtro de varianza móvil.




Fig. 23. Resultado de la inversión de la primera mitad del registro.

Debido a la diferencia entre las frecuencias de muestreo de ambos sensores, fue necesario remuestrear la señal EMG originalmente tomada a 148,14 Hz, a una frecuencia de 100 Hz, la misma que la que registran las IMUs. De esta manera conseguimos que las señales sean comparables.

El siguiente reto fue la detección automática del giro. Utilizamos otra vez un filtro de varianza móvil aplicado a ambas señales de velocidad angular. La función generada requería la selección del tamaño de la ventana que barría la señal. Comenzamos con un tamaño de 100 muestras y progresivamente fuimos disminuyendo hasta identificar el valor óptimo de 20 muestras. Después de marcar los giros de las señales, se identificaron todos los máximos locales en las curvas de velocidad angular. En el laboratorio se intenta que ambos tipos de sensores comiencen a registrar a la vez, pero los sensores de EMG tienen cierto retardo que no se puede controlar, debido a esto, las señales nunca tienen la misma duración y si el protocolo no se ha seguido de forma correcta, el primer paso registrado por los sensores de EMG podría no corresponderse con el primer paso registrado por los sensores de Xsens. Para asegurarnos de la correspondencia de pasos, se decidió trabajar con los máximos antes y después del giro como referencias, garantizando así una alineación precisa. Se probó un único punto de referencia que no dio buenos resultados ya que introducía un mayor error temporal. Finalmente, se optimizó la posición de los puntos de referencia minimizando el RMSE, lo que garantizó la mejor alineación temporal posible entre las dos señales.

Después de todo este proceso, se detectaron los puntos estratégicos que marcan los eventos de HS y TO: los mínimos adyacentes a todos los máximos locales, siendo el mínimo anterior al máximo el despegue del dedo del pie, y el mínimo siguiente, el impacto del talón. Un ejemplo de detección de los eventos de HS y TO sobre la señal de velocidad angular se muestra en la siguiente figura:




Fig. 24. Detección de eventos de la marcha sobre señal de velocidad angular.

4. Metodología

4.1 Generación automática de informes

4.1.1 Estructura de los informes clínicos

Según el estudio publicado en el *Journal of Medical Internet Research* (Wright et al., 2015), los pacientes con acceso a las anotaciones médicas presentaron una tasa de adherencia al tratamiento del 79,7%, en comparación con aquellos sin acceso. Varios estudios destacan que entregar un resumen tras la consulta facilita la comprensión de lo visto en la visita, reduce el olvido, impulsa el seguimiento adecuado de la medicación o próximas pruebas y mejora la comunicación, especialmente en familias de pacientes pediátricos o crónicos como ocurre en el caso de niños con PC. Una de las iniciativas que promueve esto es OpenNotes (Schust et al., 2022).

En este contexto y dada la gran relevancia de los informes médicos como herramienta para la práctica clínica, el presente proyecto plantea la automatización de su generación en tiempo real. Esta automatización permitirá a los profesionales de la salud disponer de información estructurada de manera inmediata, agilizando tareas administrativas como la búsqueda del código del paciente, la fecha de intervención, la fecha de nacimiento o la edad, sin necesidad de intervención manual. Además, los informes incluyen gráficas que muestran la evolución pre y post-tratamiento, lo que facilita el seguimiento clínico y contribuye a una evaluación objetiva de la eficacia de la terapia y a la toma de decisiones fundamentadas. Como valor añadido, estos documentos también ayudan a pacientes y familias a comprender mejor el proceso terapéutico y favorece la comunicación con otros profesionales implicados en su cuidado.

Otra de las justificaciones sobre la importancia de estos informes es el gran volumen de datos heterogéneos que se generan (curvas cinemáticas, curvas de EMG, parámetros espaciotemporales, recomendaciones del médico...), por lo que elaborar informes de forma manual es lento, variable entre profesionales y propenso a errores de transcripción. Gracias al código desarrollado, el proceso se realiza rápido, sin errores y según una plantilla estandarizada.

Contenido de los informes:

- Datos del paciente: nombre, código identificativo, número de estudio (campo a rellenar por el clínico), fecha del estudio, fecha de nacimiento, género y edad.
- Datos sobre el registro clínico del paciente: motivo de consulta, antecedentes personales e historia clínica.
- Tabla de exploración clínica editable: tabla estandariza en la que el médico puede incluir los rangos de movimiento, valores numéricos según diferentes escalas clínicas, comentarios...
- Análisis visual de la marcha: se muestra una tabla para el miembro inferior izquierdo y otra para el miembro inferior derecho, que sirve de guía para el clínico y puede ser completada por este.

-
- Parámetros espaciotemporales obtenidos a través del análisis instrumentado de la marcha: velocidad, cadencia, longitud de paso... Son métricas fáciles de comprender y fáciles de comparar entre visitas.
 - Curvas de cinemática: gráficas para la visualización de la función articular de la pelvis, cadera, rodilla, tobillo y pie. La primera articulación anteriormente mencionada se registra de forma unitaria, no como las demás, en las que existe un registro de la pierna izquierda y un registro de la pierna derecha. Además, en cada adquisición podemos observar tres gráficas que corresponden a los diferentes ejes: frontal (x), transversal (y) y sagital (z) (excepto en los pies que solo se incluye el primero de estos).

Explicación de las gráficas de cinemática: en el eje horizontal se representa el vector de tiempo normalizado, desde el 0% hasta el 100% del ciclo de la marcha, de modo que cada gráfica corresponde a un paso completo. Por otro lado, el eje vertical varía dependiendo del eje que estemos analizando:

- Aducción (-) / Abducción (+) para el eje frontal (x)
- Rotación externa (-) / Rotación interna (+) para el eje transversal (y)
- Extensión (-) / Flexión (+) para el eje sagital (z)

Todas estas medidas se expresan en grados, y la interpretación del signo de la señal en cada instante permite determinar el tipo de movimiento realizado (por ejemplo, extensión o flexión). En este estudio los registros se agruparon en tres fases: T0 (antes del tratamiento), T1 (dos o tres semanas después del tratamiento) y T2 (tres meses o más después del tratamiento). El código está creado con el objetivo de que se pueda elegir un máximo de tres registros a analizar, pudiéndose seleccionar también dos o uno. Principalmente está diseñado para que se grafiquen de forma simultánea un registro T0, otro T1 y otro T2, que representan la evolución del paciente a lo largo del tratamiento. El código incluye el requisito de que el registro más antiguo se grafique en color rojo, el intermedio en color azul y el más nuevo en color verde, con el propósito de que el médico interiorice esta correspondencia y no tenga que mirar continuamente la leyenda. En el caso de que solo se seleccionen dos registros los colores serán rojo y verde y si solo se elige uno, rojo. Otro aspecto relevante son las nubes grises que se dibujan en todas las gráficas. Estas son las desviaciones estándar de los controles, lo que asumimos como la normalidad. En consecuencia, cuanto más próximos se encuentren los registros de los pacientes a estas nubes, mayor será la similitud de su marcha con un patrón no patológico.

- Información SPM: debajo de las gráficas del eje sagital de la cadera, rodilla y tobillo, podemos observar recuadros a veces vacíos y otras veces con bandas de colores. Estos recuadros nos muestran cuándo hay diferencias significativas entre los diferentes registros, es decir, si el tratamiento ha generado un cambio significativo en las posiciones articulares del paciente durante la marcha (T0 vs. T1, recuadro superior) o si la marcha cambia a largo plazo después del tratamiento (T1 vs. T2, recuadro inferior). En el caso de que solo se seleccionasen dos registros, solo se produciría una comparación y si solo se elige un registro,

ninguna. Podemos fijarnos a la izquierda de los recuadros que aparecen las fechas de los registros comparados junto con el estado, para que el clínico no tenga ninguna duda sobre qué se está comparando.

- Curvas de EMG: visualizan la función muscular de forma inmediata, permitiendo detectar patrones patológicos. La gráfica facilita la interpretación clínica y la explicación al paciente al tener la nube que representa la normalidad. En la parte superior vemos cuatro gráficas en las que se muestra la actividad eléctrica muscular en todo el registro, no solo un paso. En el eje horizontal se representa el tiempo (en segundos) y en el eje vertical la amplitud de la señal en milivoltios (mV). Los picos de la señal corresponden a periodos de mayor activación muscular, mediante el análisis de su morfología, es posible identificar o descartar la presencia de patrones de activación asimétricos.

En la parte inferior se plasman otras cuatro gráficas complementarias que representan la activación muscular a lo largo de un ciclo completo de marcha (0% - 100%), con valores expresados en mV obtenidos mediante sensores colocados en los músculos tibiales anteriores y gastrocnemios de ambas extremidades. Aparecen de forma simultánea los registros a comparar.

- Conclusiones, recomendaciones y firma del médico.

Es conveniente mencionar que esta plantilla ha sido diseñada con ayuda de los propios clínicos.

4.1.2 Métodos estadísticos para análisis comparativo entre consultas de rehabilitación

SPM ofrece diferentes funciones que se adaptan a múltiples tipos de problemas, tanto en función del dato como de la comparación a realizar. Una de sus principales ventajas radica en que proporciona interpretaciones visuales directas, en las que las regiones significativas aparecen resaltadas en colores. En biomecánica, SPM unidimensional (Pataky, 2018) permite analizar fuerzas, momentos y cinemática articular. Este método parte del vector de datos completo con el que calcula en cada punto una métrica de diferencia (*score*: t , F , T^2 ...). Seguidamente, genera otra curva con los valores de *score* dando lugar a $SPM\{t\}$ o $SPM\{F\}$. Valores elevados en el anterior vector indicarán la existencia de grandes diferencias. El umbral de significancia z^* ($zstar$) se calcula a través de Random Field Theory (RFT). Cuando el *score* sobrepasa $|z^*|$ (tanto por arriba como por debajo) se considera que existe una diferencia estadísticamente significativa en ese punto. Esta zona será marcada como clúster y se le asignará un p-valor (Pataky, 2018). Es importante evaluar el estadístico tanto en $+z^*$ como en $-z^*$ para buscar cambios en ambos sentidos. En el caso de obtener una curva sin clústeres puede afirmarse que los registros analizados son estadísticamente indistinguibles. Como se ha comentado, la función seleccionada en cada análisis depende de los datos y de la naturaleza de las comparaciones de interés. Las empleadas en este estudio son:

- Paired t test: compara un mismo sujeto en dos condiciones, por ejemplo: pre-tratamiento y post-tratamiento. Se aplica $SPM\{t\}$ pareado que devuelve intervalos del ciclo donde la diferencia media es significativa. También existe una

prueba `t_test` para muestras independientes, que permite comparar dos grupos distintos, como controles frente a pacientes.

- Repeated-measures ANOVA 1D: esta versión es similar a la anterior, pero se deben incluir tres o más registros del mismo sujeto.

Más concretamente en este estudio se empleó SPM para la comparación de las posiciones articulares (en grados) a partir de los datos extraídos de archivos `.x/sx` provenientes de *Xsens Motion Cloud*. Este software procesa las señales seleccionando los pasos más representativos, aplicando filtros para eliminar artefactos y re-escalando los ciclos a 101 puntos (0–100% del ciclo, que evita realizar alineaciones temporales). El principal nivel de significación empleado fue 0.05, aunque también 0.02 y 0.01 en pruebas puntuales. Las funciones específicas de `spm1d` (SPM unidimensional) utilizadas han sido:

- `spm1d.stats.ttest_paired`: permitió comparar T0 vs T1 y T1 vs T2.
- `spm1d.stats.ttest2`: utilizada para contrastar pacientes frente a controles (comparación entre grupos distintos).
- `spm1d.stats.anova1`: similar a la prueba anterior, pero aplicable a tres o más grupos independientes (en `spm1d.stats.ttest2` solo se trabaja con dos grupos).
- `spm1d.stats.anova1rm`: empleada para comparaciones con tres o más registros de un mismo sujeto en diferentes condiciones, lo que se denomina medidas repetidas (T0 vs T1 vs T2)
- `spm1d.stats.eqvartest`: utilizada para determinar si existían diferencias en la varianza entre dos registros a lo largo del tiempo.

Para garantizar el correcto funcionamiento o ejecución de estas funciones, es necesario cumplir con una serie de requisitos:

- En las comparaciones intra-sujeto, los registros deben tener el mismo número de ciclos para poder emparejarse. Si el número de pasos difiere entre sesiones, se determina cuál tiene menos y se eliminan los sobrantes.
- Es necesario que todos los ciclos tengan el mismo número de muestras (101).
- Se requiere que cada registro tenga al menos dos ciclos completos, ya que SPM examina la desviación estándar. Además, la varianza entre las sesiones no puede ser nula.
- Los datos se transforman a matrices de dimensiones $N \times 101$, siendo N el número de ciclos completos que realiza el sujeto y 101 las muestras temporales.
- Dado que la comparación no se realiza frente a un único control, para cada voluntario sano se calcula su curva media, es decir, se promedian los ciclos de todos ellos.

Por otro lado, se intentó resumir la información generada a través de SPM de forma que resultara intuitiva y fácilmente interpretable, representándola a través de una banda con diferentes colores en las zonas significativas. Se realizaron diferentes experimentos:

1. En primer lugar, se definió la severidad puntual como el valor absoluto del estadístico dividido entre su valor máximo ($sev(t) = |z(t)| / \max|z|$).
2. En segundo lugar, se propuso calcular la intensidad puntual, denominada Q , como el cuadrado del estadístico. De esta manera la curva de test se convierte en una

medida siempre positiva. A continuación, los valores de los puntos significativos se dividen por percentiles (25, 50 y 75%), estableciendo cuatro niveles de cambio: débil, medio, fuerte y muy fuerte. Este método garantiza el mismo número de puntos en cada nivel, aunque la clasificación se aplica sobre puntos individuales y no sobre un clúster.

3. En tercer lugar, se planteó el uso de umbrales fijos, clasificando los puntos significativos en función de si superan o no determinados valores de referencia, sin necesidad de emplear percentiles.
4. En cuarto lugar, se propuso calcular la severidad de cada clúster mediante diferentes métricas, como el área bajo la curva o el producto entre el valor máximo y la duración. A partir de los grupos de mayor y menor severidad se establecen cuatro categorías: débil, medio, fuerte y muy fuerte. Este método permite etiquetar grupos completos, aunque no garantiza un número equilibrado en cada categoría.
5. Por último, se planteó definir la severidad de un clúster como una combinación entre la magnitud de la desviación y el tiempo durante el cual se mantiene dicha desviación. En este caso, cada grupo se representa con un color uniforme que refleja su severidad global.

Finalmente, se optó por definir la severidad puntual como el valor (absoluto y con signo) del estadístico debido a que se consideró la estrategia más intuitiva y la que ofrecía una interpretación más clara, evitando complejidades innecesarias en la representación.

4.2 Segmentación de las fases de la marcha

4.2.1 Segmentación basada en la morfología de la señal

En este trabajo replicaremos el algoritmo propuesto por Behboodi y su equipo (Behboodi et al., 2019a). Estos autores segmentan la marcha utilizando únicamente la velocidad angular de la tibia en el eje sagital, medida con un giroscopio colocado en la cara lateral interna de cada pierna, misma localización que la nuestra. El algoritmo se usó en siete niños con desarrollo típico y cinco niños con PC espástica diparésica (GMFCS niveles II y III). Se pudieron identificar patrones claros en la señal: dos picos positivos durante la fase de apoyo y un pico negativo de mayor amplitud y más sostenido en el tiempo en la fase de oscilación. La señal expuesta en el apartado: 3.2.6 Sincronización de señales de cinemática y electromiografía de este TFG, se encuentra invertida en comparación a la referencia que muestran en este estudio. Por ello, el primer paso realizado para llevar a cabo la segmentación consistió en invertir la señal haciendo que las formas de onda coincidieran. En este estudio se definieron cuatro eventos ipsilaterales:

- Inicio de *loading response* (LR/HS/IC) tiene lugar en el cruce por cero de valores negativos a positivos.
- Inicio de *initial swing* (ISw/TO/EC (end contact)) corresponde con el último pico positivo.
- Inicio de *mid-swing* (MSw) caracterizado por un cruce por cero de positivo a negativo
- Inicio de *terminal swing* (TSw) corresponde con el mínimo.

Los eventos encontrados en la señal de la pierna contralateral fueron:

- Inicio de *mid-stance* (MSt) es el primer máximo de la pierna contraria.
- Inicio de *terminal stance* (TSt) corresponde al mínimo contralateral.
- Inicio de *pre-swing* (PSw) se define como el contacto inicial contralateral, es decir el paso por cero de negativo a positivo de la pierna contraria a la analizada.

Todos estos eventos están marcados en la figura que aparece a continuación:




Fig. 25. Segmentación de las fases de la marcha a través de la morfología de la señal (Behboodi et al., 2019a).

En el artículo se comenta que los registros tomados de niños con PC no tenían un pico claro y evidente en TO, por ello se modificó el algoritmo empleando la suma de las tres componentes de la velocidad angular e introduciendo bloqueos temporales mínimos entre eventos. Además, se generó un sistema de autoajuste de umbrales que se calculaba a partir de las amplitudes medias de picos y valles en ciclos previos. Esto permitió que la precisión se mantuviera al 99% respecto al sistema de referencia basado en captura de movimiento (GPD-MoCap) y que los errores calculados se encontrasen por debajo de 100ms. En el presente TFG también se han introducido bloqueos temporales en ambos algoritmos, pero no se han sumado las tres componentes de la velocidad angular en el algoritmo de los pacientes pues en general no resultaba necesario. Volviendo al capítulo 3.2.6 (sincronización de señales), en el que determinamos el CI como un máximo (debido a la inversión para este algoritmo sería un mínimo) vemos cierta incoherencia con el anterior trabajo citado, en el que sitúan el CI en el paso por cero. Revisando diversas publicaciones hemos observado que en cada una se presentan descripciones diferentes. Algunos estudios muestran el CI como el paso por cero (lo realizado en este TFG y en el estudio de referencia (Behboodi et al., 2019a)) y otros lo sitúan en un máximo (Catalfamo et al., 2010a).

Estudios comparativos confirman que este tipo de algoritmos son los más consistentes y fiables entre sujetos y velocidades después de los realizados con aprendizaje profundo (Trigo et al., 2025a). La gran ventaja que tienen son su interpretabilidad, pues existe una explicación física. Sin embargo, no todos los aspectos son positivos, estos métodos son muy sensibles a la colocación del sensor y al basarse en derivadas, tienden a amplificar el ruido de la señal. En consecuencia, resulta imprescindible incorporar un proceso de suavizado o filtrado para mejorar la relación señal-ruido (Rueterbories et al., 2010).

La lógica de detección de eventos implementada en este TFG es la siguiente:

Partimos de las señales ipsilaterales (pierna analizada) y contralaterales (la opuesta), muestreadas a 100 Hz. En primer lugar, se aplica un filtro paso-banda (0.5-10 Hz) *Butterworth* IIR de 4º orden en fase cero.

- TSw: valles con una prominencia mayor o igual a 5 (prom_TSw) y una amplitud menor a -3 (amp_TSw).
- ISw: para cada TSw, se busca el máximo entre el TSw previo (o inicio) y el TSw actual, tomando el pico más alto.
- MSw: cambio de signo positivo a negativo entre ISw y TSw.
- LR / HS: primer cruce de valores negativos a positivos después de cada TSw. El golpe de talón es estimado por el cambio de signo.
- PSw: cruce negativo-positivo, válido solo si el último valle previo está por debajo de -5 (amp_PSw) y respeta un intervalo mínimo de 5 muestras o 50 ms (interv).
- TSt: valles con prominencia mayor o igual a 5 (prom_TSt).
- MSt: para cada TSt, se toma el último máximo entre el TSt previo y el TSt actual, con prominencia mayor o igual 3 (prom_MSt).

Finalmente se devuelve un vector de etiquetas por índice.

4.2.2 Segmentación a través de Deep Learning

Las redes LSTM (Long Short-Term Memory) son un tipo de redes neuronales recurrentes diseñadas para trabajar con secuencias largas evitando el problema del desvanecimiento del gradiente. Son capaces de mantener información a lo largo del tiempo y aprender dependencias temporales a largo plazo. Su funcionamiento se basa en un estado de memoria (*cell state*) y tres puertas principales: la puerta de olvido, que elimina información irrelevante, la puerta de entrada, que decide qué información nueva incorporar y la puerta de salida, que determina la información que se transmite hacia adelante (Ghojogh & Ghodsi, 2023a). Estas propiedades hacen que las LSTM sean especialmente útiles en el análisis de señales biomédicas secuenciales, como electrocardiogramas o la segmentación de fases de la marcha. El entrenamiento se realiza mediante retropropagación a través del tiempo, lo que permite ajustar los pesos de acuerdo con el error cometido en las predicciones pasadas. El esquema simplificado de la arquitectura LSTM se presenta en la figura 26:




Fig. 26. Esquema de arquitectura LSTM.

En el entrenamiento de ANN (Artificial Neural Network) se ejecutan diversas técnicas de regularización que previenen el sobreajuste y mejoran la generalización. Entre ellas, el *dropout* consiste en desactivar aleatoriamente un porcentaje de neuronas en cada iteración, reduciendo la dependencia del modelo a combinaciones específicas y mejorando su robustez. El *early stopping* detiene el entrenamiento cuando la pérdida de validación deja de mejorar tras varias épocas consecutivas, evitando el sobreentrenamiento. Finalmente, *ReduceLROnPlateau* ajusta automáticamente la tasa de aprendizaje reduciéndola cuando una métrica evaluada deja de mejorar, lo que permite realizar un ajuste más fino y escapar de mínimos locales (Dialameh et al., 2024a; Liman et al., 2024a).

El modelo desarrollado en este trabajo integra estas estrategias y se inspira en recomendaciones de estudios previos en segmentación de marcha. Se trata de un modelo híbrido que combina la capacidad de las BiLSTM (Bidirectional Long Short-Term Memory) para capturar dependencias temporales con mecanismos de MultiHeadAttention que permiten extraer relaciones a diferentes escalas, incorporando además restricciones fisiológicas específicas de la marcha.

En la fase de preprocesado, cada ciclo se interpoló a 101 puntos con el fin de normalizar la duración de los registros y garantizar la comparabilidad de los datos antes de su entrada en la red (Kidziński et al., 2019a). Las curvas articulares (cadera, rodilla y tobillo en los tres ejes de cada pierna) se normalizaron con un *StandardScaler*, de forma que cada señal presentara media cero y desviación unitaria, evitando que diferencias de rango entre articulaciones o velocidades afectaran al entrenamiento (Su et al., 2020a). La entrada final del modelo consistió en 11 características: nueve señales de cinemática, la posición normalizada dentro del ciclo (similar a un contador de 0 a 100) (Kidziński et al., 2019a) y un vector de fase esperada que actúa como referencia fisiológica de la secuencia (Chen et al., 2024a). Gracias a ello, situamos todos los pasos a la misma escala sin perder información y le damos contexto para obtener mejores resultados.

Con el fin de aumentar la generalización, se aplicaron técnicas de *data augmentation* adaptadas a la biomecánica de la marcha, como desplazamientos temporales, deformaciones suaves de tiempo (*time warping*), adición de ruido gaussiano, escalado de amplitud, filtrado en frecuencia, ruido localizado en transiciones y deformaciones elásticas. Estas transformaciones fueron diseñadas bajo la inspiración de trabajos previos que advierten de la pérdida de información y alteración de eventos clave cuando las deformaciones superan ciertos umbrales (Y. Kim et al., 2025a). Previo al diseño de la arquitectura final, se evaluaron diversos modelos con un de aumento de datos más limitado, los cuales no alcanzaron un rendimiento comparable al obtenido por lo que se considera un paso esencial.

El Deep Learning aplicado a la segmentación de la marcha ha demostrado superar a los métodos clásicos en precisión y capacidad de generalización, especialmente en datos complejos (Taborri et al., 2016). La arquitectura propuesta se organiza en dos bloques: dos capas BiLSTM (80 y 64 neuronas), encargadas de modelar las dependencias temporales pasadas y futuras y reducir la confusión en fases con transiciones rápidas (datos de cinemática) y dos capas densas (32 y 16 neuronas) que procesan la información de posición en el ciclo y el vector de fase esperada (contextual). Ambas se concatenan con MultiHeadAttention (6 y 4 cabezas (Chen et al., 2024a)), capaz de considerar

dependencias a corto y largo plazo entre diferentes fases del ciclo. La salida corresponde a una capa *softmax* distribuida en siete clases, que indica la probabilidad estimada de cada fase en cada instante.

La función de pérdida utilizada combina *Categorical Cross-Entropy* con *Focal Loss* y ponderación por clase para compensar el desbalance existente entre fases largas y cortas y centrarse en ejemplos difíciles. A esto se añadieron penalizaciones por transiciones inválidas, inspiradas en la *transition-penalty matrix* del modelo DPF-LSTM-CNN (K. Liu et al., 2023a). De esta manera, se castigan retrocesos, saltos no consecutivos y cambios excesivamente erráticos. Asimismo, tras la salida softmax se aplica un postprocesado basado en una matriz de transición que restringe al modelo a avanzar como máximo una fase por frame, garantizando la coherencia fisiológica del ciclo.

El entrenamiento se realizó con el optimizador Adam y con un *learning rate* inicial de 1×10^{-3} , durante un máximo de 80 épocas. Se fijó un tamaño de *batch* de 6, adaptado a los pasos pediátricos más cortos, en línea con lo observado en IMU-Net (Kidziński et al., 2019a). Para regularizar el proceso se incorporaron *early stopping* (15 épocas), *ReduceLROnPlateau* (factor 0.5) y *dropout* (0.3-0.25 para mantener la generalización, tal como recomienda el PSO-CNN-LSTM (Zhang et al., 2025a). Toda la información anteriormente comentada se resume en la siguiente tabla:

Características	Valor/método
Interpolación por ciclo	101 puntos
Normalización	StandardScaler (media = 0, desviación = 1)
Entradas al modelo	11 características (9 señales cinemáticas, posición normalizada en el ciclo, vector de fase esperada)
<i>Data augmentation</i>	Desplazamientos temporales, <i>time warping</i> , ruido gaussiano, escalado de amplitud, filtrado en frecuencia, ruido localizado en transiciones, deformaciones elásticas
BiLSTM	80 y 64 neuronas
Capas densas	32 y 16 neuronas
MultiHeadAttention	6 y 4 cabezas
Dropout	0.3 – 0.25
Capa de salida	Softmax (7 clases)
Función de pérdida	Categorical Cross-Entropy + Focal Loss + ponderación por clase + penalización por transiciones inválidas
Postprocesado	Matriz de transición (máximo avance de 1 fase por frame)
Optimizador	Adam
Learning rate inicial	1×10^{-3}
Épocas máximas	80
Batch size	6
Regularización	Early stopping (15 epochs), ReduceLROnPlateau (factor 0.5)

Tabla 5. Características de la red.

Finalmente, el modelo fue entrenado, validado y evaluado en conjuntos separados de pacientes con PC y controles sanos, con métricas tanto *frame a frame* como métricas secuenciales más estrictas. La división de los conjuntos en el grupo control se realizó con 17 sujetos destinados a entrenamiento, 3 a validación y 5 a prueba (68%/ 12%/20%). Por su parte, para los pacientes la división fue 14 para train, 3 para validación y 4 para test

(aproximadamente 67%/14%/19%). Estas divisiones se evidencian en las siguientes dos tablas:

Train Controles	Validation Controles	Test Controles
S01, S04, S05, S06, S08, S09, S10, S11, S12, S15, S17, S18, S20, S22, S23, S24, S25	S03, S13, S16	S02, S07, S14, S19, S21

Train PC	Validation Controles	Test Controles
P01, P03, P04, P07, P10, P11, P15, P31, P32, P34, P36, P39, P41, P42	P33, P37, P40	P08, P09, P17, P38

Tabla 6. División de controles y pacientes en conjunto de train, validation y test.

El número de registros disponibles por paciente no es uniforme, dado que algunos llevan más tiempo en seguimiento que otros. Además, el número de ciclos válidos presentes en cada registro puede variar. Por este motivo, la forma más adecuada de presentar la información es indicar directamente el número total de ciclos válidos incluidos en cada conjunto de datos. En total hay 1380 en controles y 2063 en PC, en la tabla 7 aparece detallada la división de ciclos por grupo:

	Ciclos Train	Ciclos Validation	Ciclos Test
Controles	720	294	366
Sujetos	1400	91	572

Tabla 7. Número de ciclos por cada conjunto de train, validation y test.

5. Resultados

5.1 Gráficas de electromiografía y cinemática sincronizadas

Después de remuestrear las señales de EMG de 148,14 Hz a 100 Hz, detectar el punto de giro mediante varianza, corregir la inversión direccional en la velocidad angular de las IMUs y alinear temporalmente ambas señales usando los máximos inmediatamente antes y después del giro, obtenemos los siguientes resultados. Sobre la figura 27, en azul observamos la señal de velocidad angular registrada por EMG y en naranja la registrada por los sensores inerciales:




Fig. 27. Señales de velocidad angular obtenidas a través de sensores inerciales y de EMG sincronizadas.

Con intención de calcular el error, compararemos las curvas de cinemática que nos ofrece el software de Xsens vs las curvas de cinemática segmentadas con nuestro algoritmo de velocidad angular. En la imagen inferior se observa la cinemática articular de la rodilla izquierda. Cabe señalar que Xsens Motion Cloud también normaliza los ciclos a 101 muestras y que, en nuestro caso, el algoritmo descarta aquellos pasos que se desvían más de un 25% de la desviación estándar, lo que permite minimizar la variabilidad intra-sujeto y en consecuencia, mejorar la comparación. En la tabla se muestran los RMSE (error cuadrático medio punto a punto a lo largo del ciclo) de cada paso, siendo la media de este ejemplo aproximadamente 6.68° .




Fig. 28. Comparación entre señales segmentadas con nuestro algoritmo y referencia de Xsens (en rodilla).

Paso	RMSE (°)
1	9.234
2	7.487
3	4.439
4	8.391
5	11.153
6	7.052
7	3.085
8	8.500
9	6.639
10	6.444

Tabla 8. Errores entre los pasos segmentados con nuestro algoritmo y la referencia de Xsens (en rodilla).

Este procedimiento se ha realizado también en la articulación del tobillo, donde se ha obtenido un RMSE medio de 5.37°, es decir de media la diferencia punto a punto entre nuestra curva y la de referencia es 5.37 grados (figura 29 y tabla 9):




Fig. 29. Comparación entre señales segmentadas con nuestro algoritmo y referencia de Xsens (en tobillo).

Paso	RMSE (°)
1	6.950
2	4.782
3	3.998
4	6.286
5	8.086
6	6.355
7	5.056
8	6.514
9	5.983
10	3.640

Tabla 9. Errores entre los pasos segmentados con nuestro algoritmo y la referencia de Xsens (en tobillo).

En la posterior tabla encontramos los valores de error de 14 sujetos. Estas medidas se encuentran entre 3.38° y 13.88° . También se optó por utilizar MAE (error absoluto medio) que toma valores entre 2.71° y 12.2° . La correlación de Pearson es de aproximadamente 0.9999 en todos los sujetos lo que nos indica que la forma de onda es prácticamente idéntica. La correlación de Pearson se empleó dado que las variables analizadas son continuas y se asume distribución aproximadamente normal, condición necesaria para aplicar este coeficiente.

Sujeto	RMSE	MAE	Correlación		
1	5.606	4.857	0.999976		
2	3.620	3.421	0.999987		
3	5.158	4.783	0.999971		
4	4.671	4.091	0.999982		
5	7.424	6.882	0.999941		
6	3.378	2.706	0.999994		
7	8.721	7.944	0.999903		
8	10.796	9.438	0.999919		
9	5.414	4.579	0.999966		
10	12.428	11.250	0.999880		
11	8.101	7.048	0.999979	Métrica	Media $\pm$ SD
12	9.271	8.955	0.999993	RMSE	7.50 ± 3.23
13	13.883	12.200	0.999888	MAE	6.67 ± 2.94
14	6.481	5.286	0.999889	Correlación	1.00 ± 0.00

Tabla 10. Errores entre los pasos segmentados con nuestro algoritmo y la referencia de Xsens (en 14 sujetos).

Finalmente, respecto a la detección de eventos hemos obtenido los siguientes resultados:

- Controles: error medio de HS = $0.043 \pm 0.021s$ y de TO = $0.049 \pm 0.024s$ con correlaciones de aproximadamente 1.
- PC: error medio de HS = $0.073 \pm 0.044s$ y de TO = $0.080 \pm 0.039s$.

Con la frecuencia de muestreo a 100 Hz los errores fueron menores a 80 ms representando menos del 1% del ciclo de marcha, por lo que se consideran despreciables para el marcado de eventos.

5.2 Ejemplo de informe clínico

A continuación, se mostrará en la figura 30 un ejemplo de informe clínico generado de manera automática. Se ha eliminado la información personal del paciente para garantizar su privacidad:



Informe del Análisis de la Marcha

Nombre:	Nombre paciente
Código:	P100
Número de estudio:	
Fecha de estudio:	21-11-2023
Fecha de nacimiento:	Día-mes-año
Género:	H
Edad:	7

MOTIVO DE CONSULTA

ANTECEDENTES PERSONALES

HISTORIA CLÍNICA

EXPLORACIÓN CLÍNICA

Nota: L: libre / NEG: negativo / POS: positivo.

Control motor selectivo: grado 2 completo / grado 1 parcial / grado 0 ausente / NV no valorable.

Comentarios: dolor.

BALANCE ARTICULAR	DER	IZQ	ESPASTICIDAD ESCALA ASHWORTH MODIFICADA	DER	IZQ	FUERZA / CONTROL MOTOR	DER	IZQ
CADERA			CADERA			CADERA		
FLEXIÓN			EXTENSORES			EXTENSIÓN		
Test de Thomas			FLEXORES			FLEXIÓN		
Test de Phelps			Comentarios			Comentarios		
ADDUCCIÓN			ABDUCTORES			ADDUCCIÓN		
ABDUCCIÓN			Comentarios			Comentarios		
Cad 90° - Rod 90°			ADDUCTORES			ABDUCCIÓN		
Cad 0° - Rod 90°			Cad 90° - Rod 90°			Comentarios		
Cad 0° - Rod 0°			Cad 0° - Rod 90°			ROTAC INTERNA		
ROT INTERNA			Cad 0° - Rod 0°			ROT EXTERNA		
Prono / Supino			Comentarios			Comentarios		
ROT EXTERNA			RODILLA			RODILLA		
Prono / Supino			RECTO FEMORAL			EXTENSIÓN		
RODILLA			ISQUIOTIBIALES			EXTENSOR LAG		
EXTENSIÓN			Uni/Bilat			FLEXIÓN		
FLEXIÓN			Comentarios			Comentarios		
ÁNGULO POPLÍTEO			TOBILLO			ELEV PIERNA EXT		
Unilateral			FLEXORES PLANTARES			Comentarios		
TEST DUNCAN-ELY			Rodilla 90°			TOBILLO		
FLEX RODILLA PRONO			Rodilla 0°			DORSIFLEXIÓN		
TOBILLO			INVERSORES			Comentarios		
FLEXIÓN DORSAL			Comentarios			FLEXIÓN PLANTAR		
Rodilla 90°			VARIOS			Comentarios		
Rodilla 0°			ANTEVERS FEMORAL			INVERSIÓN		

BALANCE ARTICULAR	DER	IZQ	ESPASTICIDAD ESCALA ASHWORTH MODIFICADA	DER	IZQ	FUERZA / CONTROL MOTOR	DER	IZQ
FLEXIÓN PLANTAR			LAXITUD ARTIC RODILLA			Comentarios		
INVERSIÓN			LONGITUD MMII (cm)			EVERSIÓN		
EVERSIÓN			ÁNGULO MUSLO-PIE			Comentarios		
Comentarios			DEFORMIDAD PIE			TRONCO		
RÓTULAS ALTAS			Apoyo plantígrado			ABDOMINALES		
			Ángulo retro-antepié			ERECT. TRONCO		
			Varo retropié carga			Comentarios		
			Midfoot break			EQUILIBRIO		
			Hallux valgus					

ANÁLISIS OBSERVACIONAL DE LA MARCHA

MIEMBRO INFERIOR DERECHO												
FASE DE APOYO							FASE DE OSCILACIÓN					
Cont. Inicial	Resp. Carga		Apoyo Medio			Ap. Termin.	Pre Osc.	Osc. Inic.	Osc. Med.	Osc. Term.		
talón	mov. flexor rodilla		ext. rod.	hiperext.	flex. rod.	ext. rodilla	push off activo	clearance		extens. rod.		
med. ant. ded.	no mov.	extens.	pie compl.	2	5	flex. rod.	no activo	clearance no/alter.		flex. rod		
	cad. neutra		no pie compl.	3	4	extens. cad.	flex rápida rod.+cad.			cadera neutra		
	>endo./add.	exo.	ascens. talón	sí	no	flex. cad.	otros			>endo./add.	exo.	
			calcáneo neutro									
tipo de marcha			varo		valgo							
1	2	3	4	5								
Observaciones:												

MIEMBRO INFERIOR IZQUIERDO												
FASE DE APOYO							FASE DE OSCILACIÓN					
Cont. Inicial	Resp. Carga		Apoyo Medio			Ap. Termin.	Pre Osc.	Osc. Inic.		Osc. Med.	Osc. Term.	
talón	mov. flexor rodilla		ext. rod.	hiperext.	flex. rod.	ext. rodilla	push off activo	clearance			extens. rod.	
med. ant. ded.	no mov.	extens.	pie compl.	2	5	flex. rod.	no activo	clearance no/alter.			flex. rod.	
	cad. neutra		no pie compl.	3	4	extens. cad.	flex. rápida rod.+cad.				cadera neutra	
	>endo./add.	exo.	ascens. talón	si	no	flex. cad.	otros			>endo./add.	exo.	
			calcáneo neutro									
tipo de marcha			varo		valgo							
1	2	3	4	5								
Observaciones:												

ANÁLISIS INSTRUMENTADO DE MARCHA

Se realiza estudio de marcha según protocolo. Se ha realizado estudio de cinemática y de EMG dinámica de superficie en los músculos gemelo medial y tibial anterior bilateral, siguiendo las recomendaciones de la SENIAM.


Fases:

CI 0-2% • Respuesta a la carga 2-12% • Apoyo medio 12-31% • Apoyo terminal 31-50% • Pre-oscilación 50-62% • Oscilación inicial 62-75% • Oscilación media 75-87% • Oscilación terminal 87-100%.


PARÁMETROS ESPACIO-TEMPORALES

	27/06/2023	03/08/2023	21/11/2023
Velocidad (m/s)	0.87	0.51	1.02
Cadencia (steps/min)	119.73	106.97	134.22
Long. paso der (cm)	50.03	47.63	51.16
Long. paso izq (cm)	41.48	16.23	43.35
Dif. long paso (cm)	45.75	31.93	47.26
Ancho paso der (cm)	8.03	8.76	14.26
Ancho paso izq (cm)	7.52	8.60	14.05
Dif. ancho paso (cm)	7.77	8.68	14.16
Zancada paso der (cm)	91.74	63.40	94.97
Zancada paso izq (cm)	91.56	63.87	94.59
Dif. zancada (cm)	0.18	0.48	0.38


CURVAS DE CINEMÁTICA







EMG DINÁMICO DE SUPERFICIE



CONCLUSIONES

RECOMENDACIONES

FIRMA

Fig. 30. Ejemplo de informe clínico.

5.3 Gráficas comparativas generadas con SPM

En este apartado se presentarán los resultados del análisis estadístico comparativo generado con SPM. Se muestran a continuación las curvas utilizadas para contrastar diferencias pre-post tratamiento en el patrón de marcha. En estas primeras gráficas (figura 31) observamos las posiciones articulares de la rodilla izquierda (recuadro A) y rodilla derecha (recuadro B), en el eje sagital. Como ya se ha comentado antes, es el plano más utilizado por representar mayor ROM y por lo tanto más diferencias. Dentro de cada rectángulo, a la izquierda encontramos las curvas T0 y T1, en las que se muestra la media junto con una nube que indica la desviación estándar de cada señal. A la derecha observamos la curva SPM{t} generada con la función `spm1d` pareada. En ella se pueden analizar tres o cuatro clústeres, respectivamente (zonas grises). En estos casos el p-valor es menor al 0.001 y ambas utilizan como umbral tanto $+z^*$ como $-z^*$.




Fig. 31. Gráficas de las posiciones articulares de pacientes y sus respectivos análisis SPM.

A continuación, se añaden ilustraciones de diferentes planos y articulaciones:




Fig. 32. Gráficas de posiciones articulares y sus respectivos análisis SPM (en otras articulaciones y planos).

SPM considera la variabilidad entre pasos y la dependencia entre muestras, por ello, zonas donde la media difiere visualmente pueden tener alta variabilidad y no alcanzar el nivel de significación por lo que no se etiquetan como clústeres. Si intentásemos analizar visualmente la figura 33A, probablemente concluiríamos que existen más diferencias significativas de las que SPM detecta (figura 33B). No obstante, la figura 33C confirma una diferencia en torno al 80% del ciclo (hueco blanco), sin embargo, el pequeño intervalo próximo al 20% que podría interpretarse como una diferencia entre las señales, no alcanza significación según este método estadístico. En el segundo conjunto de gráficos (figura 34) ocurre algo similar: hasta el 40% del ciclo las señales parecen claramente distintas, pero SPM solo identifica un clúster reducido antes del 20%. En ese mismo ejemplo, si comparásemos únicamente las medias, clasificaríamos como diferente el pico de flexión, por el contrario, SPM no lo considera significativo. En último, el tercer ejemplo (figura 35), la aparente gran diferencia durante la fase de apoyo medio se traduce, desde el punto

de vista estadístico, en un efecto de pequeña magnitud, generando un clúster muy pequeño.




Fig. 33. Comparación entre medias, desviaciones y análisis SPM (ejemplo 1).




Fig. 34. Comparación entre medias, desviaciones y análisis SPM (ejemplo 2).




Fig. 35. Comparación entre medias, desviaciones y análisis SPM (ejemplo 3).

Como ya se comentó otro gran reto fue el resumen de esta técnica estadística en algo fácilmente interpretable. Se decidió utilizar la magnitud del estadístico t sobre el ciclo completo de la marcha para indicar las zonas más significativas. En las gráficas inferiores (figura 36) observamos las señales cinemáticas, las curvas de SPM y una banda que refleja a través de un mapa de calor la magnitud del estadístico t. En la figura 36A los colores de esta banda son continuos durante todo el ciclo, no se muestra los clústeres, mientras en la figura 36B la banda solo se colorea en las zonas significativas. En este último caso, valores de t mayores se representan con colores más vivos y oscuros, además la dirección también está representada al incluir el color rojo o el color azul. El tercer caso (figura 36C) no incluye si el efecto del tratamiento va hacia arriba o hacia abajo, solo se pintan

las zonas del ciclo estadísticamente significativas. Valores absolutos altos de t colorearán el clúster de morado y valores absolutos bajos de naranja claro:




Fig. 36. Posiciones articulares de la rodilla, análisis SPM y banda interpretativa.

Aunque finalmente se decidió añadir en las gráficas de los informes el estilo de la banda SPM de la figura 36C, se propuso otro estilo que se muestra en la figura 37. El caso 37A realiza una sola comparación, por ello solo se grafica una banda. Sobre ella podemos visualizar tres zonas pintadas, tres clústeres. El primero de ellos es verde porque la curva T1 (verde) sobrepasa a la azul, lo contrario que ocurre en el segundo clúster. Si nos fijamos en el primer clúster, podemos darnos cuenta de que su última parte está coloreada de verde más oscuro, lo que indica mayores diferencias. El ejemplo 37B muestra dos comparaciones, por eso se incluyen dos bandas. En la primera de ellas se compara T0 vs T1, como T0 está siempre por encima de T1, todos los clústeres aparecen en rojo. En el clúster central se ve claramente el degradado de colores, en el centro el rojo es menos intenso (menores diferencias) que en los laterales (mayores diferencias). Finalmente, en el tercer caso (figura 37C), la curva azul siempre está por encima de las otras dos, esto genera que todos los clústeres estén pintados de azul. Este método de representación permite detectar fácilmente la dirección que ha tenido el tratamiento:




Fig. 37. Análisis comparativo con SPM y bandas interpretativas.

5.4 Gráficas de velocidad angular segmentadas

A continuación, se presentan las gráficas de velocidad angular segmentadas mediante un algoritmo de desarrollo propio con características similares al propuesto por Behboodi y su grupo (Behboodi et al., 2019a).

En primer lugar, en la figura 38A se presenta la señal ipsilateral (filtrada y recortada), junto con los eventos detectados sobre ella. La imagen 38B muestra la señal contralateral (filtrada y recortada) junto con los eventos que esta determina y la señal ipsilateral con estos mismos puntos marcados sobre ella. En la gráfica de la figura 38C se representan todos los instantes comentados proyectados sobre la señal ipsilateral.




Fig. 38. Resultado 1 de segmentación con algoritmo basado en la morfología de señal.

Otro ejemplo de señal segmentada se expone en la siguiente imagen:




Fig. 39. Resultado 2 de segmentación con algoritmo basado en la morfología de señal.

Dado que esta segmentación constituye la entrada a la red, se implementó un código generalizable capaz de segmentar automáticamente todos los archivos contenidos en una carpeta. A continuación, se muestran algunos de los resultados en las figuras 40-44. Los tres primeros registros no dieron ningún error a diferencia de los dos últimos. Los dos primeros pertenecen a pacientes y el tercero a control. Si nos fijamos en la figura 43, podemos ver como en ese caso no se determinó bien el giro y por lo tanto la señal no se invirtió en el momento adecuado, haciendo que, en una parte, los eventos no se pudieran determinar correctamente. La última gráfica corresponde a un registro mal realizado (sensor mal orientado o suelto). Este último caso se trata de un voluntario sano, por lo que su marcha no debería ser anormal, además la pierna contraria se midió correctamente:




Fig. 40. Resultado 1 de segmentación con algoritmo basado en la morfología de señal.




Fig. 41. Resultado 2 de segmentación con algoritmo basado en la morfología de señal.




Fig. 42. Resultado 3 de segmentación con algoritmo basado en la morfología de señal.




Fig. 43. Resultado 4 de segmentación con algoritmo basado en la morfología de señal.




Fig. 44. Resultado 5 de segmentación con algoritmo basado en la morfología de señal.

Fase	Pacientes (Señales originales) (ms)	Controles (Señales originales) (ms)	Pacientes (Señales remuestreadas) (ms)	Controles (Señales remuestreadas) (ms)
LR	89.56	88.45	96.99	96.79
MSt	272.94	275.71	301.42	306.39
TSt	89.94	88.28	99.43	97.86
PSw	87.21	82.97	94.62	89.96
ISw	92.36	93.40	101.99	104.10
MSw	185.01	188.46	204.30	209.15
TSw	92.49	87.46	101.24	95.75

Tabla 11. Tabla comparativa en ms entre las duraciones de las fases en marcha sana y patológica.

Fase	Pacientes (Señales originales) %	Controles (Señales originales) %	Pacientes (Señales remuestreadas) %	Controles (Señales remuestreadas) %
LR	9.85	9.78	9.70	9.68
MSt	30.01	30.47	30.14	30.64
TSt	9.89	9.76	9.94	9.79
PSw	9.59	9.17	9.46	9.00
ISw	10.15	10.32	10.20	10.41
MSw	20.34	20.83	20.43	20.91
TSw	10.17	9.67	10.12	9.57

Tabla 12. Tabla comparativa en % entre las duraciones de las fases en marcha sana y patológica.

5.5 Resultados de la segmentación de las fases de la marcha con Deep Learning

Los resultados en PC se muestran en las tablas inferiores (tanto de forma global como por fases):

Métrica	Valor (global)
Accuracy	0.8964
Precision	0.8910
Recall	0.8778
F1-score	0.8827
IoU (Intersection over Union)	0.7929
Dice	0.8827

Tabla 13. Métricas de rendimiento ANN entrenada con pacientes.

Fase	Precision	Recall	F1-score	IoU	Dice
LR	0.948	0.821	0.880	0.785	0.880
MSt	0.927	0.928	0.927	0.865	0.927
TSt	0.786	0.828	0.806	0.676	0.806
PSw	0.829	0.890	0.858	0.752	0.858
ISw	0.907	0.792	0.846	0.733	0.846
MSw	0.887	0.964	0.924	0.859	0.924
TSw	0.953	0.921	0.937	0.881	0.937

Tabla 14. Métricas de rendimiento desglosadas por fases de ANN entrenada con pacientes.

Haber conseguido un *accuracy* de 89.64% significa que el modelo clasifica correctamente aproximadamente 9 de cada 10 muestras de la secuencia de test. Son resultados muy favorables teniendo en cuenta la complejidad de diferenciar siete fases de la marcha. La precisión indica que, cuando el modelo predice una fase determinada, en el 89,1% de los casos esa predicción es correcta (comete pocos falsos positivos). F1-score es una medida que muestra equilibrio entre precisión y recall, valores elevados indican un buen equilibrio. La medida de IoU sin embargo no se encuentra tan cercana a 1 ya que es más estricta que las métricas anteriores. Esta indica que, en promedio, el 79% de las muestras predichas y reales coinciden en la misma fase.

Si realizamos la interpretación desglosando cada fase podemos confirmar que MSt ($F1=0.927$, $IoU=0.865$), es la fase mejor reconocida, la posible explicación se debe a su larga duración. Mientras que TSt ($F1=0.806$, $IoU=0.676$), es que peor se detecta. Sus valores en $F1$ e IoU sugieren confusión con fases adyacentes (MSt o PSw), posiblemente tenga fronteras más difusas debido a su corta duración. El modelo tiende a clasificar bien PSw, pero con algunos falsos positivos. El recall de ISw nos muestra que no siempre detecta todas las muestras de esta fase, pero cuando lo hace suele ser correcto.

En siguiente lugar presentaremos en la ilustración 45 la matriz de confusión que devuelve este modelo tras analizar los datos del conjunto de test. En este esquema se ve claramente la diagonal, lo que indica una buena capacidad global de clasificación. Las confusiones se concentran únicamente en fases adyacentes, ya que los límites entre fases sucesivas son más difusos.




Fig. 45. Matriz de confusión obtenida de ANN entrenada con pacientes.

Durante la realización del proyecto se pensó que no se debía penalizar de la misma manera las muestras mal etiquetadas en las fronteras, por lo que se decidió tener cierta tolerancia en los límites. El *boundary tolerance* es una técnica bastante habitual en segmentación temporal. Vancanneyt et al. detectaron el *Foot Strike* y el *Foot Off* dentro de un rango de ± 3 frames (equivalente a ± 30 ms a 100 Hz), un nivel de precisión incluso mejor que la variabilidad entre expertos humanos (Vancanneyt et al., 2025a). En diferentes artículos (Fellin et al., 2010; Zahradka et al., 2020a) se permite un rango de tolerancia de aproximadamente 10-20 ms basándose en resultados empíricos. Además, en métodos de captura óptica, los errores absolutos en la predicción de eventos de marcha se han reportado entre 4 y 30 ms y han sido considerados aceptables (Fellin et al., 2010; Zeni et al., 2008a). Se eligió una ventana de tolerancia de 1 muestra (10 ms), es decir si el modelo predice el cambio en la muestra $t+1$ y el real está en t , se considera correcto, al igual que si el modelo predice el cambio en la muestra t y el real está en $t-1$. Como se ve los resultados (tabla 15 y 16 y figura 46) mejoran significativamente llegando a un 92.36% de accuracy que alcanzaría un 94.8% si la tolerancia fuera de dos muestras:

Métrica	Valor (tolerancia de ± 1 muestra)
Accuracy	0.9236
Precision	0.9225
Recall	0.9108
F1-score	0.9150
IoU	0.8454
Dice	0.9150

Tabla 15. Métricas de rendimiento de ANN entrenada con pacientes con tolerancia de 1 muestra.

Fase	Precision	Recall	F1-score	IoU	Dice
LR	0.976	0.834	0.899	0.817	0.899
MSt	0.939	0.941	0.940	0.887	0.940
TSt	0.827	0.872	0.849	0.737	0.849
PSw	0.881	0.941	0.910	0.835	0.910
ISw	0.950	0.845	0.895	0.809	0.895
MSw	0.915	0.981	0.947	0.899	0.947
TSw	0.971	0.962	0.966	0.935	0.966

Tabla 16. Métricas de rendimiento desglosadas por fases de ANN entrenada con pacientes con tolerancia de 1 muestra.




Fig. 46. Matriz de confusión obtenida de ANN entrenada con pacientes con tolerancia de 1 muestra.

Métrica	Valor (tolerancia de ± 2 muestra)
Accuracy	0.9480
Precision	0.9501
Recall	0.9399
F1-score	0.9437
IoU	0.8947
Dice	0.9437
Métrica	Valor

Tabla 17. Métricas de rendimiento de ANN entrenada con pacientes con tolerancia de 2 muestras.

Se han buscado otras métricas que permitan la evaluación del modelo de una forma distinta a *frame a frame*. En primer lugar, la distancia Levenshtein es de 5164 muestras sobre las 57772 totales que tiene el conjunto de test (101 x 572 ciclos). Esta métrica nos indica cuántas modificaciones (sustituciones, inserciones o eliminaciones) serían necesarias para transformar la secuencia predicha total en la secuencia real total. En este caso, representa aproximadamente un 8,9%. Se puede ver desde otro punto de vista: más del 91% de la estructura secuencial de fases coincide entre la predicción y la referencia. La siguiente que evaluada se llama segmental F1-score (= 0.626). Es la métrica más estricta que mide cuántos segmentos completos de fase (de inicio a fin) han sido detectados correctamente. Poniendo de manifiesto que la mayor dificultad no está en los *frames* individuales (rendimiento alto), sino en delimitar con los bordes de cada fase.

El error absoluto medio de las transiciones es aproximadamente igual a 15 ms, un error muy bajo y clínicamente aceptable, ya que se considera tolerable hasta ± 20 -30 ms en la literatura.

A continuación, se muestran ejemplos sobre la segmentación predicha por la red y la real (conjunto de test). En la parte superior de cada ejemplo se encuentra el número de muestras clasificadas en cada fase, en primer lugar, las muestras de la señal original (recordamos que estas no necesariamente tienen 101 muestras), las re-muestreadas (son las que entran a la red) y las predichas. En primer lugar, vemos tres segmentaciones con elevadas *accuracies* (98%, 97% y 96% respectivamente, figuras 47, 48 y 49), y las dos últimas en las que se han cometido más errores de clasificación (79.2% y 82.2%, figuras 50 y 51):




Fig. 47. Ejemplo 1: Segmentación con ANN entrenada con pacientes.

Muestras originales : {'LR': 8, 'MST': 29, 'TST': 9, 'PSW': 6, 'ISW': 9, 'MSW': 17, 'TSW': 10}
Muestras re-muestreadas: {'LR': 9, 'MST': 33, 'TST': 11, 'PSW': 7, 'ISW': 10, 'MSW': 20, 'TSW': 11}
Muestras predichas : {'LR': 10, 'MST': 32, 'TST': 11, 'PSW': 8, 'ISW': 9, 'MSW': 21, 'TSW': 10}




Fig. 48. Ejemplo 2: Segmentación con ANN entrenada con pacientes.

Muestras originales : {'LR': 9, 'MST': 33, 'TST': 9, 'PSW': 6, 'ISW': 9, 'MSW': 21, 'TSW': 9}
Muestras re-muestreadas: {'LR': 9, 'MST': 35, 'TST': 10, 'PSW': 6, 'ISW': 9, 'MSW': 23, 'TSW': 9}
Muestras predichas : {'LR': 10, 'MST': 33, 'TST': 10, 'PSW': 8, 'ISW': 8, 'MSW': 23, 'TSW': 9}




Fig. 49. Ejemplo 3: Segmentación con ANN entrenada con pacientes.

Muestras originales : {'LR': 7, 'MST': 25, 'TST': 10, 'PSW': 9, 'ISW': 6, 'MSW': 10, 'TSW': 22}
Muestras re-muestreadas: {'LR': 8, 'MST': 28, 'TST': 12, 'PSW': 10, 'ISW': 7, 'MSW': 11, 'TSW': 25}
Muestras predichas : {'LR': 5, 'MST': 30, 'TST': 10, 'PSW': 11, 'ISW': 9, 'MSW': 23, 'TSW': 13}




Fig. 50. Ejemplo 4: Segmentación con ANN entrenada con pacientes.




Fig. 51. Ejemplo 5: Segmentación con ANN entrenada con pacientes.

Seguimos en este momento con las métricas obtenidas del entrenamiento con el conjunto de *train* y *validation* de los controles. Como se puede ver el rendimiento ha sido bastante mayor obteniendo un 91.21% de *accuracy* ‘estricto’, un 94.83% con una tolerancia de una muestra y de 97.12% con una tolerancia de dos muestras:

Métrica	Valor
Accuracy	0.9121
Precision	0.8956
Recall	0.9027
F1-score	0.8985
IoU	0.8178
Dice	0.8985

Tabla 18. Métricas de rendimiento ANN entrenada con controles.

Fase	Precisión	Recall	F1-score	IoU	Dice
LR	0.853	0.939	0.894	0.809	0.894
MSt	0.951	0.925	0.938	0.883	0.938
TSt	0.843	0.819	0.831	0.711	0.831
PSw	0.828	0.896	0.861	0.756	0.861
ISw	0.904	0.895	0.899	0.817	0.899
MSw	0.938	0.945	0.941	0.889	0.941
TSw	0.952	0.899	0.925	0.860	0.925

Tabla 19. Métricas de rendimiento desglosadas por fases de ANN entrenada con controles.




Fig. 52. Matriz de confusión obtenida de ANN entrenada con controles.

Métrica	Valor (tolerancia de ± 1 muestra)
Accuracy	0.9483
Precision	0.9385
Recall	0.9440
F1-score	0.9409
IoU	0.8896
Dice	0.9409

Tabla 20. Métricas de rendimiento de ANN entrenada con controles con tolerancia de 1 muestra.

Fase	Precisión	Recall	F1-score	IoU	Dice
LR	0.903	0.952	0.927	0.863	0.927
MSt	0.968	0.947	0.957	0.918	0.957
TSt	0.899	0.877	0.888	0.799	0.888
PSw	0.892	0.961	0.925	0.861	0.925
ISw	0.965	0.950	0.958	0.919	0.958
MSw	0.966	0.977	0.971	0.944	0.971
TSw	0.976	0.943	0.960	0.922	0.960

Tabla 21. Métricas de rendimiento desglosadas por fases de ANN entrenada con controles con tolerancia de 1 muestra.




Fig. 53. Matriz de confusión obtenida de ANN entrenada con controles con tolerancia de 1 muestra.

Métrica	Valor (tolerancia de ± 2 muestra)
Accuracy	0.9712
Precision	0.9657
Recall	0.9692
F1-score	0.9673
IoU	0.9373
Dice	0.9673

Tabla 22. Métricas de rendimiento de ANN entrenada con controles con tolerancia de 2 muestras.

Respecto a las diferencias que vemos al comparar ambos entrenamientos encontramos lo siguiente:

En el caso de la fase de contacto inicial (LR), el modelo entrenado con datos patológicos presenta una alta precisión (0.948), pero una baja recall (0.821). Por el contrario, en los controles se observa el patrón inverso (precisión=0.853, recall=0.939).

En la fase de apoyo medio (MSt), ambos modelos alcanzan valores elevados de F1-score (0.927 en PC y 0.938 en controles).

La fase de apoyo terminal (TSst) es la que peor rendimiento tiene en ambos grupos. En ambos casos, los valores de IoU (0.676 y 0.711) confirman que es la fase con mayor dificultad de segmentación.

Las fases de preoscilación (PSw) e inicios de la oscilación (ISw) mantienen un comportamiento semejante en ambos conjuntos, con unos resultados ligeramente superiores en los controles.

En las fases de oscilación media (MSw) y oscilación terminal (TSw) se observan los mejores resultados globales. Esto confirma que las fases de oscilación son más robustas frente a la variabilidad entre poblaciones.

El error absoluto medio de este entrenamiento baja a 12.69 ms. El 91.89% de la estructura secuencial de fases coincide entre la predicción y la referencia y el segmental F1-score aumenta a 0.717, es decir, el modelo acierta alrededor de 7 de cada 10 fases completas. Las figuras 54-58 constituyen algunas de las segmentaciones predichas por la red:




Fig. 54. Ejemplo 1: Segmentación con ANN entrenada con controles.

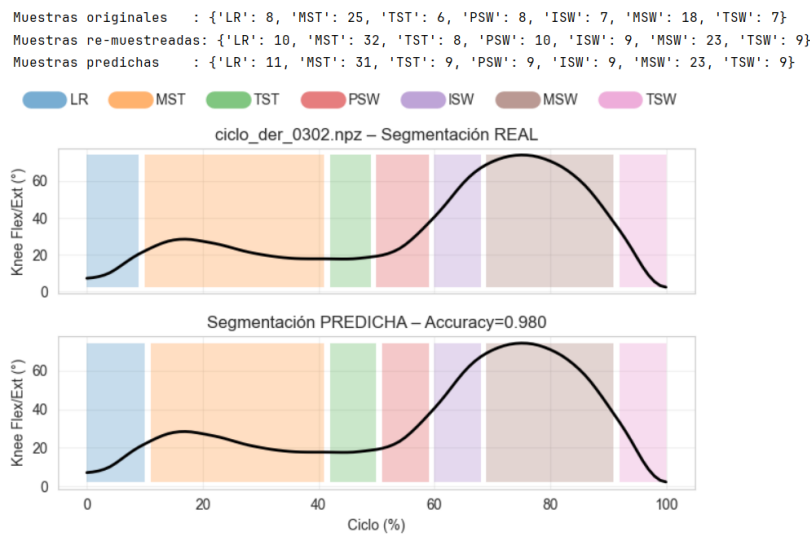


Fig. 55. Ejemplo 2: Segmentación con ANN entrenada con controles.

Muestras originales : {'LR': 5, 'MST': 30, 'TST': 7, 'PSW': 9, 'ISW': 7, 'MSW': 10, 'TSW': 18}
 Muestras re-muestreadas: {'LR': 6, 'MST': 35, 'TST': 8, 'PSW': 11, 'ISW': 8, 'MSW': 12, 'TSW': 21}
 Muestras predichas : {'LR': 12, 'MST': 26, 'TST': 9, 'PSW': 13, 'ISW': 10, 'MSW': 23, 'TSW': 8}




Fig. 56. Ejemplo 3: Segmentación con ANN entrenada con controles.

Muestras originales : {'LR': 9, 'MST': 22, 'TST': 9, 'PSW': 7, 'ISW': 9, 'MSW': 11, 'TSW': 6}
 Muestras re-muestreadas: {'LR': 12, 'MST': 31, 'TST': 12, 'PSW': 10, 'ISW': 13, 'MSW': 15, 'TSW': 8}
 Muestras predichas : {'LR': 13, 'MST': 32, 'TST': 14, 'PSW': 5, 'ISW': 10, 'MSW': 26, 'TSW': 1}




Fig. 57. Ejemplo 4: Segmentación con ANN entrenada con controles.

Muestras originales : {'LR': 4, 'MST': 28, 'TST': 9, 'PSW': 4, 'ISW': 9, 'MSW': 18, 'TSW': 10}
 Muestras re-muestreadas: {'LR': 5, 'MST': 34, 'TST': 12, 'PSW': 4, 'ISW': 12, 'MSW': 22, 'TSW': 12}
 Muestras predichas : {'LR': 11, 'MST': 24, 'TST': 10, 'PSW': 11, 'ISW': 12, 'MSW': 21, 'TSW': 12}




Fig. 58. Ejemplo 5: Segmentación con ANN entrenada con controles.

6. Discusión y limitaciones

6.1 Aplicabilidad y calidad de la base de datos y los informes clínicos automáticos

La base de datos desarrollada tiene como objetivo cubrir las necesidades de la investigación en biomecánica y rehabilitación neurológica. Gracias al protocolo seguido, los datos presentan una alta calidad, buenas relaciones señal-ruido y son comparables entre sí. Además, la información contenida es de carácter multimodal, lo que amplía sus posibles aplicaciones y finalidades. Para la selección de pacientes se siguieron criterios claros y detallados, con el fin de minimizar la variabilidad no deseada. Asimismo, el estudio cuenta con aprobación ética: en el *dataset* no aparecen datos personales y en las grabaciones de video, las caras de los sujetos han sido cubiertas para garantizar su anonimato y cumplir con la normativa de protección de datos.

La base de datos no solo permite realizar comparaciones entre consultas sucesivas de un mismo paciente, sino que también posibilita comparar pacientes y voluntarios, permitiendo generar curvas normativas y facilitando así la identificación de patrones no comunes. Dentro de este contexto, el algoritmo de sincronización entre señales inerciales y de EMG tiene gran potencial, ya que añade valor interpretativo para el clínico, al permitir establecer correspondencias claras, por ejemplo, entre el CI y la activación del TA.

De igual forma, la presentación de curvas por articulación, plano y lado corporal facilita la interpretación, al dar la posibilidad de compararlas. Resulta particularmente valioso en pacientes con PC, donde las asimetrías y compensaciones son frecuentes y relevantes.

Finalmente, la retroalimentación de los profesionales especialistas en rehabilitación neurológica ha sido positiva. Los clínicos han valorado especialmente tres aspectos: reducción de tiempo en la generación de informes, estandarización en la presentación y lectura de resultados y mejora en la objetividad de las decisiones. Además, han destacado el valor de las gráficas comparativas entre consultas que incluyen la banda con las diferencias estadísticamente significativas generadas a través de SPM.

6.2 Comparativa con trabajos previos de análisis SPM en la marcha

En un estudio reciente de *Scientific Reports* (Mestanza Mattos et al., 2023a), los investigadores utilizaron SPM combinado con el *Gait Profile Score* para analizar alteraciones cinemáticas durante todo el ciclo de la marcha en personas con esclerosis múltiple. Esta aproximación permitió superar las limitaciones del análisis subjetivo tradicional. Además, en él se destaca la posibilidad de crear mapas en los que se reflejaban las diferencias de toda una curva, lo que hace que los resultados sean más interpretables.

Uno de nuestros retos era la interpretabilidad de estos resultados mediante bandas de colores. Algo muy similar presentan Alhossary y sus colegas (Alhossary et al., 2023a). En sus resultados de SPM, mapas de colores fáciles de entender. Los usuarios pueden identificar y visualizar rápidamente áreas que se desvían de los datos normativos. El

sistema utiliza un código de colores donde la severidad de la desviación está codificada por colores desde azul (leve) hasta rojo oscuro (muy severo). Este estudio ha demostrado la capacidad de SPM para evaluar mejorías en pacientes mediante comparación de señales con controles antes y después de tratamientos. En MovementRx se evaluó a un paciente masculino de 55 años con osteoartritis de rodilla que se sometió a un reemplazo total. Se detectó una clara reducción de los movimientos en la rodilla derecha, especialmente en la flexión/extensión y la aducción/abducción. SPM también reveló que el paciente después de la operación empezó a sobrecargar la rodilla izquierda provocando riesgo de desarrollar artrosis en el futuro. Este estudio es similar al nuestro comparando registros pre-intervención vs controles, post-intervención vs controles y pre-tratamiento vs post-tratamiento.

6.3 Comparativa con trabajos previos de segmentación de la marcha con métodos tradicionales

Como se ha podido apreciar en las gráficas anteriormente presentadas, en la mayoría de las señales se obtuvieron resultados muy positivos con el algoritmo de segmentación basado en la morfología de la señal de velocidad angular. No obstante, incluso en registros con alta calidad, se identificaron ciertos eventos clasificados erróneamente. Por esta razón, fue necesario aplicar un filtrado de pasos que asegurara la selección únicamente de aquellos que presentaban el orden de las fases correcto (LR, MSt, TSt, PSw, ISw, MSw, TSw) y en los que cada fase aparecía una sola vez. Aun así, dada la elevada cantidad de muestras segmentadas, algunos errores consiguieron superar este filtro. En concreto, se localizaron 27 registros de pacientes en los que la segmentación del ciclo era claramente incorrecta (por ejemplo, detección tardía del evento LR que recortaba la señal o tramos de señal que, por azar, contenían los siete eventos en orden pero no se correspondían a un paso real (figura 59)). En el grupo control únicamente se detectaron 12 ciclos erróneos. Estas cifras representan un porcentaje muy reducido, del 1,29% en pacientes y del 0,86% en controles. Dichos errores no tuvieron mayores consecuencias, ya que tras una revisión visual se eliminaron aquellos ciclos que no se ajustaban a los patrones fisiológicos.

Los resultados obtenidos demuestran una alta viabilidad del método para la detección de las siete fases de la marcha, tanto en niños con desarrollo típico como en aquellos con PC. No obstante, no pudimos valorar cuantitativamente el error de detección al no disponer de un sistema de referencia adicional. Según el artículo en el que nos basamos, el error medio es de 12.3 ms para el HD y de 18.5 ms para el TO, situándose entre los valores más bajos explicados en la literatura. Por su parte, Catalfamo et al. presentan errores de hasta 50 ms en la detección del *toe-off* y su sistema no contemplaba las siete fases de la marcha (Catalfamo et al., 2010a).

Como ya se explicó en la metodología, en el presente algoritmo, no se estableció una diferenciación entre el análisis de niños sanos y patológicos. En las señales se observaban claramente los dos máximos y el mínimo descritos en el artículo de referencia, por lo que no se consideró necesario modificar el algoritmo. Tampoco se implementó el algoritmo de *auto-thresholding*. La mayoría de los registros respondían bien a los umbrales propuestos y en aquellos casos en los que no era así, el valor se modificaba manualmente. Es posible que, durante el análisis masivo de datos, esta estrategia haya ocasionado que algunos pasos no se hayan detectado correctamente y que, con el anterior ajuste, sí lo

hubieran hecho. No obstante, esta limitación se contempla como una línea de trabajo futura.

Trabajos como el de (Senanayake & Senanayake, 2010a) son capaces de identificar las siete fases de la marcha, pero requieren del uso de 12 sensores y 22 señales distintas, lo que supone un montaje más lento, complejo y menos práctico para su aplicación diaria. En conclusión, el sistema desarrollado es una alternativa viable frente a métodos de adquisición más complejos. Su capacidad de adaptarse a los patrones de marcha de pacientes con parálisis cerebral, combinada el uso de un solo sensor, lo convierten en una herramienta con un gran potencial.




Fig. 59. Pasos mal segmentados por el algoritmo basado en la velocidad angular.

6.4 Comparativa con trabajos previos de segmentación de la marcha con Deep Learning

A continuación, se muestra una tabla comparativa de trabajos previos similares al nuestro:

Estudio	Única entrada: ángulos articulares	Segmentación en fases discretas	Arquitectura de la red	Métricas	Nº sujetos	División conjuntos: train/val/test
(Di Nardo et al., 2020a)	Ángulo sagital de la rodilla	Salida binaria: apoyo / balanceo junto con otros eventos	MLP (3 capas ocultas y salida sigmoide)	Acc. de 90.6% ± 2.9 MAE HS 29.4 $\pm$ 13.7 ms MAE TO 99.5 $\pm$ 28.9 ms Precisión/recall/F1 $\approx$ 0.99-1.00.	23 adultos sanos ($\approx$ 10.000 zancadas).	Inter-sujeto (LOSO) 90/10 validación para early stopping (por épocas). % de val. exacto N/R.
(D. X. Liu et al., 2016a)	Sensores angulares articulares en cadera y rodilla (4 señales)	8 fases: init-LSw, mid-LSw, term-LSw, DS1, init-RSw, mid-RSw, term-RSw, DS2	MLP	Correct rate por conjunto 94.45% (CRS) y por fase 87.22% (CRP).	20 sujetos sanos	Validación cruzada
(Ma et al., 2019a)	Ángulos de cadera y rodilla	4 fases: heel strike (HS), foot flat (FF), heel off (HO) y swing (SW)	KRLS (Kernel Recursive Least Squares)	Acc. aproximado de 86%	10 voluntarios sanos	Diferentes pruebas: • 70% train / 30% test para cada sujeto • 5 voluntarios train / 2 voluntarios test • K-fold

(K. Liu et al., 2023a)	Ángulos de 6 articulaciones extraídos con IMUs. Se utiliza plataforma de fuerza, pero para el etiquetado, no como entrada	4 fases: SU-RHS, SW-L, SU-LHS, SW-R.	LSTM-CNN con fusión probabilística dinámica	Con LSTM-CNN Accuracy 96.49%, macro-F1 95.64% Con DPF-LSTM-CNN: Accuracy 97.21% y Macro-F1 96.48% (mejor que DCNN y CNN-LSTM).	20 sujetos sanos (10 jóvenes y 10 mayores)	70% train / 30% test. 20% de los ciclos de cada sujeto (no usados en entrenamiento) como validación para comparar LSTM-CNN-1 vs DPF-LSTM-CNN
(Kidziński et al., 2019a)	Trayectorias de marcadores (pie, tibia, muslo, pelvis) y rotaciones de pelvis, cadera, rodilla, tobillo y pie	Detecta eventos (FC y FO)	LSTM	Error medio: 10 ms (contacto) y 12-13 ms (despegue); cobertura FC 99%, FO 95%.	9092 ciclos anotados; 73% de ellos obtenidos de pacientes con PC	81%/ 9%/ 10% (train/val/test)

Tabla 23. Resumen trabajos previos comparables al nuestro.

La arquitectura desarrollada, que combina capas BiLSTM con mecanismos MultiHeadAttention y restricciones fisiológicas, ha demostrado un buen rendimiento tanto en población control como en población patológica. Los resultados globales muestran un *accuracy frame a frame* del 91.21% en controles y del 89.64% en pacientes, que se incrementa hasta 94.83% y 92.36% respectivamente cuando se aplica una tolerancia de ± 1 muestra (10 ms). Estos valores son comparables a los descritos en la literatura, a pesar de que la mayoría de estudios previos realizan tareas más simples y entrenan con poblaciones sanas. Por ejemplo, en uno de los estudios que analizaba marchas pediátricas anteriormente comentado (Kidziński et al., 2019a), emplearon una arquitectura LSTM para predecir únicamente eventos de contacto y despegue en niños, alcanzando errores promedios algo menores a los nuestros (10-13 ms). También encontramos estudios con rendimientos inferiores en comparación al obtenido, el algoritmo *Kernel Recursive Least Squares* (Ma et al., 2019a), capaz de detectar cuatro clases, o el modelo de de Attal (*accuracy* máximo del 84%) capaz de segmentar seis fases (Attal, 2018).

Como ya hemos comentado en estudios recientes que implementan redes neuronales para segmentación de la marcha, el número de fases suele ser reducido. Así ocurre en el trabajo DPF-LSTM-CNN (K. Liu et al., 2023a), que obtiene *accuracies* y F1-scores superiores al 95% utilizando únicamente sujetos sanos. En contraposición, la arquitectura presentada aquí, basada en BiLSTM + MultiHeadAttention + restricciones fisiológicas, segmenta siete fases de la marcha e incluye población patológica, lo que supone un desafío mayor. Es especialmente destacable el error absoluto medio en las transiciones: 15 ms en pacientes y 12.7 ms en controles, valores claramente inferiores a los descritos en otros estudios (Di Nardo et al., 2020a)(entre 20 y 100 ms). Los errores absolutos obtenidos en nuestro estudio se mantienen muy por debajo de los márgenes de tolerancia aceptados en este contexto (± 10 -30 ms) tal y como se ha reportado en otros trabajos.

En el análisis por fases, la red muestra un comportamiento robusto en fases largas y estables, donde los F1-scores superan en la mayoría de los casos el 0.92. Esto se atribuye a que las restricciones temporales favorecen la detección de patrones prolongados y

predecibles. Sin embargo, fases más cortas y rápidas como TSt y PSw presentan una detección menos precisa. Esta limitación coincide con observaciones de otros trabajos: Su et al. identificaron la precisión mínima en la fase de *Terminal Stance*, corroborando que las fases de corta duración son más difíciles de clasificar (Su et al., 2020a).

Comparando las métricas entre ambos grupos, se observa un rendimiento ligeramente superior en controles respecto a pacientes, tanto en métricas globales como por fase. Este resultado era esperable, dada la mayor variabilidad presente en los patrones de marcha patológica. Aun así, el modelo mantiene valores clínicamente relevantes en ambos casos.

El modelo implementado integra varias innovaciones:

- Información multimodal: Se ha considerado la información cinemática y contextual a través de la BiLSTM y las capas *Dense* respectivamente. De esta manera se ha procesado tanto la información de las señales temporales como la información de posición en el ciclo. Mejorando así el rendimiento en comparación con simples CNN (Convolutional Neural Network) y LSTM que tienen una alta tasa de pérdida de información temporal y espacial.
- La adición de dos capas de MultiHeadAttention con diferente número de cabezas (6 y 4) permite considerar dependencias temporales a múltiples escalas.
- Se ha realizado un preprocesamiento robusto (normalización temporal a 101 *frames*) que nos ha proporcionado consistencia independientemente de la velocidad de marcha.
- Las técnicas de aumento de datos utilizadas (temporal shift, *time warping*, *phase-specific noise*) han permitido robustez ante variabilidad.
- La implementación de restricciones temporales mediante penalizaciones por transiciones inválidas garantiza la coherencia fisiológica en las predicciones, evitando saltos imposibles.

6.5 Limitaciones del estudio

A pesar de los buenos resultados obtenidos, nuestro estudio no está exento de limitaciones, estas se discuten a continuación:

- Tamaño muestral reducido: limita la capacidad de generalización del modelo de Deep Learning a condiciones no vistas en el entrenamiento.
- Heterogeneidad del protocolo en los registros más antiguos: al comienzo de la recopilación de la base de datos los pacientes realizaban un salto y luego estaban varios segundos parados. Esto se realizaba con intención de posteriormente sincronizar las señales inerciales y de EMG. En algunos casos, debido a este inicio de movimiento y posterior parada, el giro en el algoritmo de segmentación se detecta de forma errónea.
- Desbalance en el número de muestras de las fases de marcha y posibles imprecisiones en las etiquetas de referencia: afecta negativamente al entrenamiento de los modelos de clasificación.
- Variabilidad en las curvas de velocidad angular.

-
- Dependencia de la colocación de los sensores: se requiere un posicionamiento preciso para obtener buenos resultados.
 - Capacidad computacional limitada del equipo utilizado para ejecutar las redes neuronales. Serían necesarios equipos de mayor rendimiento para optimizar los tiempos de entrenamiento y permitir arquitecturas más complejas.
 - Ha sido necesaria una revisión manual de todos los ciclos segmentados a través del algoritmo de velocidad angular para posteriormente eliminar aquellos incorrectamente segmentados.
 - Imposibilidad de conexión a internet en el hospital: impide la subida de registros a la nube y la generación automática de informes (el médico sí puede hacerlo).
 - Ejecución de gráficas de EMG y cinemática en distintos equipos: ralentiza el proceso de generación de informes.
 - Ausencia de un Excel conjunto con todo el equipo médico: dificulta la determinación precisa de fechas de intervención.
 - Necesidad de personal sanitario capaz de leer e interpretar los mapas SPM, así como las señales electromiográficas y cinemáticas.
 - Ausencia de evaluación biomecánica en controles: aunque los sujetos control fueron seleccionados bajo criterios de aparente marcha normal, existe la posibilidad de que algunos presenten alteraciones biomecánicas subclínicas no identificadas. Esto puede afectar a las comparaciones y a los modelos entrenados.

7. Conclusiones y trabajos futuros

7.1 Síntesis de hallazgos principales

La metodología seguida en el presente trabajo ha demostrado viabilidad técnica y utilidad clínica en el análisis de la marcha en pacientes con PC y voluntarios pediátricos. Los principales hallazgos y conclusiones se sintetizan en este apartado:

Se ha implementado exitosamente en la práctica clínica diaria un conjunto de técnicas que utilizan información de la actividad muscular e inercial. Se ha desarrollado una técnica para visualizar y cuantificar desviaciones respecto a patrones normales. Este sistema ha aportado objetividad en el seguimiento de pacientes, reduciendo tiempos y estandarizando la interpretación de resultados. La retroalimentación positiva de los profesionales sanitarios confirma que estas herramientas facilitan las decisiones terapéuticas al combinar cinemática, fases de la marcha, activación muscular y sus sincronizaciones.

La creación de la base de datos ha sido posible gracias al protocolo ideado. Este *dataset* contiene información de alta calidad que puede servir para trabajos posteriores. Por otro lado, SPM ha superado a las métricas discretas tradicionales, permitiendo localizar diferencias significativas en lugares concretos del ciclo de marcha. Los hallazgos más frecuentes se localizan en la rodilla y tobillo en el eje sagital, destacando alteraciones en el apoyo medio, apoyo terminal y despegue.

El algoritmo de segmentación de la marcha basado en la morfología de señal ha demostrado robustez en la detección de eventos. Sin embargo, presenta limitaciones en giros, cambios bruscos de velocidad o señales de pacientes con la marcha muy patológica o mal registradas. Por su parte, la red neuronal propuesta mostró un buen rendimiento, alcanzando en pacientes una exactitud del 92,4% y en controles del 94,8% con tolerancias de ± 1 muestra. El error medio en la detección de transiciones fue de 12–15 ms, dentro de los márgenes descritos en la literatura. No obstante, la generalización del modelo se ve limitada por el tamaño muestral y la posible presencia de errores en las etiquetas de referencia. Como aporte metodológico, cabe destacar el uso del algoritmo basado en la velocidad angular para la anotación de los datos de entrenamiento de la red. Aunque el modelo toma como entrada únicamente curvas cinemáticas, estas han sido previamente segmentadas a partir de la velocidad angular, sin que dicha información llegue a introducirse de forma directa en la red. Este aspecto resulta especialmente relevante, ya que la velocidad angular únicamente puede obtenerse mediante un software *premium* de alto coste y las curvas cinemáticas pueden generarse con herramientas más baratas, lo que reduce significativamente el gasto económico.

7.2 Implicaciones clínicas y para la investigación

Empezando con las implicaciones clínicas, considero que el presente trabajo constituye un avance en la evaluación funcional objetiva y estandarizada de la marcha en pacientes con PC. La información inercial y electromiográfica, combinada con su segmentación y análisis mediante SPM, permite pasar de una valoración cualitativa a una valoración cuantitativa y comparable entre registros.

Una de las contribuciones más relevantes es el análisis de las alteraciones a través de la señal completa con SPM, en vez de utilizar medidas discretas. Gracias a esto identificamos patrones patológicos a lo largo del ciclo que podrían pasar desapercibidos en análisis puntuales. Además, los informes generados ofrecen una presentación estandarizada de los resultados, facilitando la interpretación clínica, la toma de decisiones terapéuticas, el seguimiento del paciente y la detección temprana de cambios funcionales. La estandarización resulta especialmente importante entre personal sanitario multidisciplinario.

Este trabajo claramente contribuye a que los pacientes mejoren. Para demostrarlo se muestra la comparación de los ángulos de la rodilla durante la marcha en la figura 60. Entre ambas sesiones hay 1 año y 4 meses de diferencia:




Fig. 60. Posiciones angulares de la rodilla del mismo paciente con 1 año y 4 meses de diferencia (derecha inicial, izquierda actual).

Siguiendo con las implicaciones para la investigación, podemos decir que este trabajo establece un protocolo robusto para la adquisición y anotación de datos de marcha. Esta metodología podrá servir como referencia para estudios futuros en este campo. Los procedimientos desarrollados para la sincronización de señales EMG-cinemática y el etiquetado de referencia constituyen una contribución valiosa en investigación biomecánica.

El trabajo combina métodos tradicionales basados en eventos, caracterizados por su interpretabilidad, con técnicas de *Deep Learning*. Este enfoque aprovecha las fortalezas de ambas metodologías. La incorporación de restricciones biomecánicas en el orden temporal de las fases en los modelos de aprendizaje automático representa un avance que contribuye a reducir los errores de predicción, mientras que la aplicación de SPM como herramienta de explicabilidad constituye una aportación relevante hacia métodos más transparentes. Finalmente, la futura publicación de la base de datos de forma anonimizada facilitará su uso por parte de otros investigadores, contribuyendo al progreso en este ámbito de estudio.

7.3 Líneas futuras

Este trabajo puede seguir contribuyendo a la evaluación clínica objetiva de la marcha. Las líneas futuras que darán lugar a una herramienta más útil se estructuran en tres grupos:

Ampliación y aumento de la diversidad del conjunto de datos

Una primera línea futura se centra en el aumento del conjunto de datos actual. Se podría intentar incluir pacientes con diferentes patologías neurológicas, como personas que han sufrido ictus. Si esto último se llevase a cabo, sería necesario registrar adultos sanos para poder realizar las comparaciones, ya que la marcha varía dependiendo de la edad. La colaboración actual se realiza con un único centro médico, lo que constituye una limitación. Esta podría solucionarse mediante el desarrollo del protocolo propuesto en otros hospitales, facilitando así la obtención de más datos de PC y de otras enfermedades.

Refinamiento de los algoritmos y modelo de Deep Learning

En segundo punto, respecto al algoritmo de segmentación de las fases de la marcha a través de la velocidad angular se podría implementar un método de selección de umbrales automáticos en la detección de eventos. De esta manera aumentaría el número de pasos correctamente segmentados.

Siguiendo con el aprendizaje profundo, se podría intentar mejorar la arquitectura de los modelos e implementar *transfer learning*, que ayudaría mejorar la generalización. Se podrían explorar arquitecturas más sofisticadas, como Transformers, pero para ello se necesitaría una mayor capacidad computacional. Además, sería relevante refinar la detección de fases críticas como TSt y PSw que actualmente presentan mayor dificultad de clasificación.

Otra opción de mejora sería la incorporación de información de EMG como input predictivo de los modelos, dado que, con ella, la literatura demuestra un incremento en la precisión de la segmentación. Adicionalmente, podrían integrarse las grabaciones de video o utilizarlas para validar la segmentación realizada.

Relevancia y aplicabilidad clínica

En último lugar, nos podríamos centrar en la relevancia a nivel práctico. SPM calcula diferencias significativas, pero estas no necesariamente poseen relevancia clínica, dado que no toda significación estadística implica relevancia en la práctica. Es aquí cuando la capacidad interpretativa del clínico adquiere un papel fundamental para determinar la utilidad real de los hallazgos. Por ello se podrían determinar umbrales de diferencia mínima clínicamente importantes específicos para cada articulación y fase de la marcha. También se podría evaluar si clústeres por encima de $+z^*$ o por debajo de $-z^*$ están relacionados con la mejora/empeoramiento de los pacientes.

De cara al futuro, se puede plantear la extensión del estudio mediante redes neuronales hacia modelos capaces de detectar dinámicamente los eventos de la marcha, con el fin de aplicar estimulación eléctrica funcional (FES) durante la rehabilitación y activar cada grupo muscular en el momento adecuado.

La siguiente línea futura se podría haber incluido en el grupo anterior. La explicabilidad de los modelos mediante técnicas como SHAP (SHapley Additive exPlanations), proporcionaría una comprensión intuitiva de las decisiones del modelo, facilitando su aceptación por los médicos. Esta transparencia es muy relevante en el contexto sanitario, donde la confianza en las herramientas de ayuda a la decisión es fundamental. Esta información debería incluirse en los informes clínicos junto con la predicción de la segmentación realizada por la red.

Finalmente, comentar que el desarrollo de una interfaz más sofisticada para la generación de informes representaría un paso definitivo hacia la implementación práctica. Asimismo, debería realizarse la generación de las gráficas de EMG desde el mismo ordenador que genera las curvas de cinemática y los informes.

8. Bibliografia

- Aftab, Z., & Ahmed, G. (2022a). Validity of Dual-Minima Algorithm for Heel-Strike and Toe-Off Prediction for the Amputee Population. *Prosthesis*, 4(2), 224–233. <https://doi.org/10.3390/prosthesis4020022>
- Ahmad, N., Ghazilla, R. A. R., Khairi, N. M., & Kasi, V. (2013). Reviews on Various Inertial Measurement Unit (IMU) Sensor Applications. *International Journal of Signal Processing Systems*, 256–262. <https://doi.org/10.12720/ijsp.1.2.256-262>
- Albarbar, A., Mekid, S., Starr, A., & Pietruszkiewicz, R. (2008). Suitability of MEMS accelerometers for condition monitoring: An experimental study. *Sensors*, 8(2), 784–799. <https://doi.org/10.3390/s8020784>
- Aleksandrowicz, K., Kosowski, W., Michalska, A., & Winiarski, S. (2025). SPM Differences in Gait Pattern of Women After Total Hip Replacement: A Longitudinal Study. *Journal of Clinical Medicine*, 14(12). <https://doi.org/10.3390/jcm14124316>
- Alhossary, A., Pataky, T., Ang, W. T., Chua, K. S. G., Kwong, W. H., & Donnelly, C. J. (2023). Versatile clinical movement analysis using statistical parametric mapping in MovementRx. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-29635-4>
- Aqueveque, P., Germany, E., Osorio, R., & Pastene, F. (2020). Gait segmentation method using a plantar pressure measurement system with custom-made capacitive sensors. *Sensors (Switzerland)*, 20(3). <https://doi.org/10.3390/s20030656>
- Behboodi, A., Zahradka, N., Wright, H., Alesi, J., & Lee, S. C. K. (2019a). Real-time detection of seven phases of gait in children with cerebral palsy using two gyroscopes. *Sensors (Switzerland)*, 19(11). <https://doi.org/10.3390/s19112517>
- Boyer, M., Bouyer, L., Roy, J. S., & Campeau-Lecours, A. (2023). Reducing Noise, Artifacts and Interference in Single-Channel EMG Signals: A Review. In *Sensors* (Vol. 23, Issue 6). MDPI. <https://doi.org/10.3390/s23062927>
- Catalfamo, P., Ghoussayni, S., & Ewins, D. (2010). Gait event detection on level ground and incline walking using a rate gyroscope. *Sensors*, 10(6), 5683–5702. <https://doi.org/10.3390/s100605683>
- Chen, H., Wang, X., Xiao, Y., Wu, B., Wang, Z., Liu, Y., Wang, P., Chen, C., & Wu, X. (2024a). iP3T: an interpretable multimodal time-series model for enhanced gait phase prediction in wearable exoskeletons. *Frontiers in Neuroscience*, 18. <https://doi.org/10.3389/fnins.2024.1457623>
- Chernak Slane, L., & Thelen, D. G. (2014). The use of 2D ultrasound elastography for measuring tendon motion and strain. *Journal of Biomechanics*, 47(3), 750–754. <https://doi.org/10.1016/j.jbiomech.2013.11.023>
- Cicirelli, G., Impedovo, D., Dentamaro, V., Marani, R., Pirlo, G., & D’Orazio, T. R. (2022a). Human Gait Analysis in Neurodegenerative Diseases: A Review. *IEEE Journal of Biomedical and Health Informatics*, 26(1), 229–242. <https://doi.org/10.1109/JBHI.2021.3092875>
- Di Nardo, F., Morbidoni, C., Cucchiarelli, A., & Fioretti, S. (2020a). Recognition of gait phases with a single knee electrogoniometer: A deep learning approach. *Electronics (Switzerland)*, 9(2). <https://doi.org/10.3390/electronics9020355>

-
- Dialameh, M., Hamzeh, A., Rahmani, H., Dialameh, S., & Kwon, H. J. (2024). DL-Reg: A deep learning regularization technique using linear regression. *Expert Systems with Applications*, 247. <https://doi.org/10.1016/j.eswa.2024.123182>
- Dumphart, B., Slijepcevic, D., Zeppelzauer, M., Kranzl, A., Unglaube, F., Baca, A., & Horsak, B. (2023). Robust deep learning-based gait event detection across various pathologies. *PLoS ONE*, 18(8 August). <https://doi.org/10.1371/journal.pone.0288555>
- Fellin, R. E., Rose, W. C., Royer, T. D., & Davis, I. S. (2010). Comparison of methods for kinematic identification of footstrike and toe-off during overground and treadmill running. *Journal of Science and Medicine in Sport*, 13(6), 646–650. <https://doi.org/10.1016/j.jsams.2010.03.006>
- Fukuchi, C. A., Fukuchi, R. K., & Duarte, M. (2018). A public dataset of overground and treadmill walking kinematics and kinetics in healthy individuals. *PeerJ*, 2018(4). <https://doi.org/10.7717/peerj.4640>
- Ghojogh, B., & Ghodsi, A. (2023). *Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey*. <http://arxiv.org/abs/2304.11461>
- Gill, W. A., Howard, I., Mazhar, I., & McKee, K. (2022). A Review of MEMS Vibrating Gyroscopes and Their Reliability Issues in Harsh Environments. In *Sensors* (Vol. 22, Issue 19). MDPI. <https://doi.org/10.3390/s22197405>
- Graham, H. K., Rosenbaum, P., Paneth, N., Dan, B., Lin, J. P., Damiano, Di. L., Becher, J. G., Gaebler-Spira, D., Colver, A., Reddihough, Di. S., Crompton, K. E., & Lieber, R. L. (2016). Cerebral palsy. In *Nature Reviews Disease Primers* (Vol. 2). Nature Publishing Group. <https://doi.org/10.1038/nrdp.2015.82>
- Guerra, B. M. V., Schmid, M., Sozzi, S., Pizzocaro, S., De Nunzio, A. M., & Ramat, S. (2024). A Recurrent Deep Network for Gait Phase Identification from EMG Signals During Exoskeleton-Assisted Walking. *Sensors*, 24(20). <https://doi.org/10.3390/s24206666>
- Halvorsen, K., Peng, W., Olsson, F., & Åberg, A. C. (2025). Two-step deep-learning identification of heel keypoints from video-recorded gait. *Medical and Biological Engineering and Computing*, 63(1), 229–237. <https://doi.org/10.1007/s11517-024-03189-7>
- Harris, E. J., Khoo, I. H., & Demircan, E. (2022). A Survey of Human Gait-Based Artificial Intelligence Applications. In *Frontiers in Robotics and AI* (Vol. 8). Frontiers Media S.A. <https://doi.org/10.3389/frobt.2021.749274>
- He, Y., Chen, Y., Tang, L., Chen, J., Tang, J., Yang, X., Su, S., Zhao, C., & Xiao, N. (2024). Accuracy validation of a wearable IMU-based gait analysis in healthy female. *BMC Sports Science, Medicine and Rehabilitation*, 16(1). <https://doi.org/10.1186/s13102-023-00792-3>
- Hermens, H. J., F. B., D.-K. C., & R. G. (2000). Development of recommendations for SEMG sensors and sensor placement procedures. *Journal of Electromyography and Kinesiology*, 10(5), 361–374.
- Holm, I., Tveter, A. T., Fredriksen, P. M., & Vøllestad, N. (2009). A normative sample of gait and hopping on one leg parameters in children 7-12 years of age. *Gait and Posture*, 29(2), 317–321. <https://doi.org/10.1016/j.gaitpost.2008.09.016>
- Ito, T., Noritake, K., Ito, Y., Tomita, H., Mizusawa, J., Sugiura, H., Matsunaga, N., Ochi, N., & Sugiura, H. (2022). Three-dimensional gait analysis of lower extremity gait parameters in Japanese children aged 6 to 12 years. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-11906-1>

-
- J. Perry and J. M. Burnfield. (2010). *Gait Analysis: Normal and Pathological Function. 2nd Ed. Thorofare, NJ, USA: SLACK Inc.*
- Ji, N., Zhou, H., Guo, K., Samuel, O. W., Huang, Z., Xu, L., & Li, G. (2019). Appropriate mother wavelets for continuous gait event detection based on time-frequency analysis for hemiplegic and healthy individuals. *Sensors (Switzerland)*, 19(16). <https://doi.org/10.3390/s19163462>
- Kidziński, Ł., Delp, S., & Schwartz, M. (2019a). Automatic real-time gait event detection in children using deep neural networks. *PLoS ONE*, 14(1). <https://doi.org/10.1371/journal.pone.0211466>
- Kim, J., Kim, H., Kim, H. G., Lee, D., & Yoon, S. (2025). A comprehensive survey of deep learning for time series forecasting: architectural diversity and open challenges. *Artificial Intelligence Review*, 58(7). <https://doi.org/10.1007/s10462-025-11223-9>
- Kim, Y. K., Visscher, R. M. S., Viehweger, E., Singh, N. B., Taylor, W. R., & Vogl, F. (2022). A deep-learning approach for automatically detecting gait-events based on foot-marker kinematics in children with cerebral palsy-Which markers work best for which gait patterns? *PLoS ONE*, 17(10 October). <https://doi.org/10.1371/journal.pone.0275878>
- Kim, Y., Kim, J., Moon, J., Kang, S., Shim, Y., Choi, M. T., & Kim, S. J. (2025a). Deep Learning-Based Recognition of Locomotion Mode, Phase, and Phase Progression Using Inertial Measurement Units. *Journal of Bionic Engineering*. <https://doi.org/10.1007/s42235-025-00723-7>
- Kok, M., Hol, J. D., & Schön, T. B. (2017). Using inertial sensors for position and orientation estimation. In *Foundations and Trends in Signal Processing* (Vol. 11, Issues 1–2, pp. 1–153). Now Publishers Inc. <https://doi.org/10.1561/20000000094>
- Lau, H., & Tong, K. (2008). The reliability of using accelerometer and gyroscope for gait event identification on persons with dropped foot. *Gait and Posture*, 27(2), 248–257. <https://doi.org/10.1016/j.gaitpost.2007.03.018>
- Leardini, A., Chiari, A., Della Croce, U., & Cappozzo, A. (2005). Human movement analysis using stereophotogrammetry Part 3. Soft tissue artifact assessment and compensation. In *Gait and Posture* (Vol. 21, Issue 2, pp. 212–225). Elsevier Ireland Ltd. <https://doi.org/10.1016/j.gaitpost.2004.05.002>
- Liman, M. D., Ibrahim, S. O., Alu, E. S., & Zakariya, S. (2024). Regularization effects in deep learning architecture. *Journal of the Nigerian Society of Physical Sciences*, 6(2), 1911. <https://doi.org/10.46481/jnsps.2024.1911>
- Lin, S., Evans, K., Hartley, D., Morrison, S., McDonald, S., Veidt, M., & Wang, G. (2025). A Review of Gait Analysis Using Gyroscopes and Inertial Measurement Units. In *Sensors* (Vol. 25, Issue 11). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/s25113481>
- Liu, D. X., Wu, X., Du, W., Wang, C., & Xu, T. (2016a). Gait phase recognition for lower-limb exoskeleton with only joint angular sensors. *Sensors (Switzerland)*, 16(10). <https://doi.org/10.3390/s16101579>
- Liu, K., Liu, Y., Ji, S., Gao, C., Zhang, S., & Fu, J. (2023a). A Novel Gait Phase Recognition Method Based on DPF-LSTM-CNN Using Wearable Inertial Sensors. *Sensors*, 23(13). <https://doi.org/10.3390/s23135905>

-
- Lv, H., & Hao, B. (2025). Convolutional neural network and long short-term memory hybrid model-based gait prediction for spacesuit intelligent assistive device in low gravity environment. *Acta Astronautica*, 236, 199–212. <https://doi.org/10.1016/j.actaastro.2025.06.049>
- Ma, Y., Wu, X., Wang, C., Yi, Z., & Liang, G. (2019a). Gait phase classification and assist torque prediction for a lower limb exoskeleton system using kernel recursive least-squares method. *Sensors (Switzerland)*, 19(24). <https://doi.org/10.3390/s19245449>
- Marcos Mazon, D., Groefsema, M., Schomaker, L. R. B., & Carloni, R. (2022a). IMU-Based Classification of Locomotion Modes, Transitions, and Gait Phases with Convolutional Recurrent Neural Networks. *Sensors*, 22(22). <https://doi.org/10.3390/s22228871>
- Mestanza Mattos, F. G., Luciano, F., Lencioni, T., Gervasoni, E., Jonsdottir, J., Anastasi, D., Pavei, G., Clerici, M., & Cattaneo, D. (2023a). Complementary use of statistical parametric mapping and gait profile score to describe walking alterations in multiple sclerosis: a cross-sectional study. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-36916-5>
- Mitternacht, J., Hermann, A., & Carqueville, P. (2022). Acquisition of Lower-Limb Motion Characteristics with a Single Inertial Measurement Unit—Validation for Use in Physiotherapy. *Diagnostics*, 12(7). <https://doi.org/10.3390/diagnostics12071640>
- Morris, C. (2007). Definition and classification of cerebral palsy: A historical perspective. *Developmental Medicine and Child Neurology*, 49(SUPPL. 2), 3–7. <https://doi.org/10.1111/j.1469-8749.2007.tb12609.x>
- Xsens Technologies B.V. (2005). *MVN User Manual*. Xsens Technologies. Retrieved from https://www.movella.com/hubfs/User_Manual_Xsens%202025.pdf
- Neto, P., Pires, J. N., & Moreira, A. P. (2013, noviembre 18). *3-D position estimation from inertial sensing: Minimizing the error from the process of double integration of accelerations* [Preprint]. arXiv.
- Nova-Díaz, D. M., Arana-Rivera, P., Sánchez-Iriso, E., & Aguilera-Albesa, S. (2025). The economic and social burden of pediatric cerebral palsy in Spain: a cost-of-illness study. *Frontiers in Public Health*, 13. <https://doi.org/10.3389/fpubh.2025.1589114>
- Papageorgiou, E., Nieuwenhuys, A., Vandekerckhove, I., Van Campenhout, A., Ortibus, E., & Desloovere, K. (2019). Systematic review on gait classifications in children with cerebral palsy: An update. In *Gait and Posture* (Vol. 69, pp. 209–223). Elsevier B.V. <https://doi.org/10.1016/j.gaitpost.2019.01.038>
- Papavasiliou, A., Ben-Pazi, H., Mastroianni, S., & Ortibus, E. (2021). Editorial: Cerebral Palsy: New Developments. In *Frontiers in Neurology* (Vol. 12). Frontiers Media S.A. <https://doi.org/10.3389/fneur.2021.738921>
- Park, S., & Yoon, S. (2021). Validity evaluation of an inertial measurement unit (IMU) in gait analysis using statistical parametric mapping (SPM). *Sensors*, 21(11). <https://doi.org/10.3390/s21113667>
- Pataky, T. C. (2010). Generalized n-dimensional biomechanical field analysis using statistical parametric mapping. *Journal of Biomechanics*, 43(10), 1976–1982. <https://doi.org/10.1016/j.jbiomech.2010.03.008>
- Pataky, T. C. (2018). *Statistical testing of 1D continua*. SPM1D Documentation.

-
- Pataky, T. C., Robinson, M. A., & Vanrenterghem, J. (2016). Region-of-interest analyses of onedimensional biomechanical trajectories: Bridging 0D and 1D theory, augmenting statistical power. *PeerJ*, 2016(11). <https://doi.org/10.7717/peerj.2652>
- Patel, D. R., Neelakantan, M., Pandher, K., & Merrick, J. (2020). Cerebral palsy in children: A clinical overview. In *Translational Pediatrics* (Vol. 9, pp. S125–S135). AME Publishing Company. <https://doi.org/10.21037/tp.2020.01.01>
- Paul, S., Nahar, A., Bhagawati, M., & Kunwar, A. J. (2022). A Review on Recent Advances of Cerebral Palsy. In *Oxidative Medicine and Cellular Longevity* (Vol. 2022). Hindawi Limited. <https://doi.org/10.1155/2022/2622310>
- Prisco, G., Pirozzi, M. A., Santone, A., Esposito, F., Cesarelli, M., Amato, F., & Donisi, L. (2025). Validity of Wearable Inertial Sensors for Gait Analysis: A Systematic Review. In *Diagnostics* (Vol. 15, Issue 1). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/diagnostics15010036>
- Radhakrishnan, V., Robinson, M., Fiorentino, N. M., Patil, S. B., & Pelah, A. (2025). Reducing soft tissue artefacts through projection of markers and microwave imaging: An exploratory study. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-025-89586-w>
- Sabatini, A. M. (2011). Kalman-filter-based orientation determination using inertial/magnetic sensors: Observability analysis and performance evaluation. *Sensors*, 11(10), 9182–9206. <https://doi.org/10.3390/s111009182>
- Sadowska, M., Sarecka-Hujar, B., & Kopyta, I. (2020). Cerebral palsy: Current opinions on definition, epidemiology, risk factors, classification and treatment options. In *Neuropsychiatric Disease and Treatment* (Vol. 16, pp. 1505–1518). Dove Medical Press Ltd. <https://doi.org/10.2147/NDT.S235165>
- Salminen, M., Perttunen, J., Avela, J., & Vehkaoja, A. (2024a). A novel method for accurate division of the gait cycle into seven phases using shank angular velocity. *Gait and Posture*, 111, 1–7. <https://doi.org/10.1016/j.gaitpost.2024.04.006>
- Schust, G., Manning, M., & Weil, A. (2022). OpenNotes and Patient Safety: a Perilous Voyage into Uncharted Waters. In *Journal of General Internal Medicine* (Vol. 37, Issue 8, pp. 2074–2076). Springer. <https://doi.org/10.1007/s11606-021-07384-2>
- Senanayake, C. M., & Senanayake, S. M. N. A. (2010). Computational intelligent gait-phase detection system to identify pathological gait. *IEEE Transactions on Information Technology in Biomedicine*, 14(5), 1173–1179. <https://doi.org/10.1109/TITB.2010.2058813>
- Shrader, W., Shih, C., & McDonald, T. (2021). Instrumented gait analysis in the care of children with cerebral palsy: Current concept review. *Journal of the Pediatric Orthopaedic Society of North America*, 3(1). <https://doi.org/10.55275/JPOSNA-2021-237>
- Smith, Y., Louw, Q., & Brink, Y. (2016). The three-dimensional kinematics and spatiotemporal parameters of gait in 6-10 year old typically developed children in the Cape Metropole of South Africa - a pilot study. *BMC Pediatrics*, 16(1). <https://doi.org/10.1186/s12887-016-0736-1>
- Spaich, E. G., Svaneborg, N., Jørgensen, H. R. M., & Andersen, O. K. (2014). Rehabilitation of the hemiparetic gait by nociceptive withdrawal reflex-based functional electrical therapy: A randomized, single-blinded study. *Journal of NeuroEngineering and Rehabilitation*, 11(1). <https://doi.org/10.1186/1743-0003-11-81>

-
- States, R. A., Krzak, J. J., Salem, Y., Godwin, E. M., Bodkin, A. W., & McMulkin, M. L. (2021). Instrumented gait analysis for management of gait disorders in children with cerebral palsy: A scoping review. In *Gait and Posture* (Vol. 90, pp. 1–8). Elsevier B.V. <https://doi.org/10.1016/j.gaitpost.2021.07.009>
- Su, B., Smith, C., & Farewik, E. G. (2020). Gait Phase Recognition Using Deep Convolutional Neural Network with Inertial Measurement Units. *Biosensors*, 10(9). <https://doi.org/10.3390/bios10090109>
- Sui, J. De, Chen, W. H., Shiang, T. Y., & Chang, T. S. (2020). Real-time wearable gait phase segmentation for running and walking. *Proceedings - IEEE International Symposium on Circuits and Systems, 2020-October*. <https://doi.org/10.1109/iscas45731.2020.9181210>
- Taborri, J., Palermo, E., Rossi, S., & Cappa, P. (2016). Gait partitioning methods: A systematic review. In *Sensors (Switzerland)* (Vol. 16, Issue 1). MDPI AG. <https://doi.org/10.3390/s16010066>
- Terrell, Z. T., Moudy, S. C., Hensel, K. L., & Patterson, R. M. (2022). Effects of osteopathic manipulative treatment vs. osteopathic cranial manipulative medicine on Parkinsonian gait. *Journal of Osteopathic Medicine*, 122(5), 243–251. <https://doi.org/10.1515/jom-2021-0203>
- Trigo, C., Crenna, F., Vecchia, P. Della, Torres-Pardo, A., Gómez-García, J. A., Ratto, G., Millán, T. R., Torre, R. M. S. de la, Tornero, J., Moreno, J. C., & Torricelli, D. (2025). *Benchmarking of IMU-based Gait Event Detection Algorithms across Diverse Terrain Conditions*. <https://doi.org/10.36227/techrxiv.173612674.40285464/v1>
- Vancanneyt, T., Le Moal, C., Blard, M., Lenoir, J., Roche, N., Bonnyaud, C., & Dubois, F. (2025). Automatic detection of human gait events: a simple but versatile 3D algorithm. *Journal of NeuroEngineering and Rehabilitation*, 22(1). <https://doi.org/10.1186/s12984-025-01544-9>
- Vu, H. T. T., Dong, D., Cao, H. L., Verstraten, T., Lefeber, D., Vanderborght, B., & Geeroms, J. (2020). A review of gait phase detection algorithms for lower limb prostheses. In *Sensors (Switzerland)* (Vol. 20, Issue 14, pp. 1–19). MDPI AG. <https://doi.org/10.3390/s20143972>
- Wang, C., Wang, X., Long, Z., Tian, T., Gao, M., Yun, X., Qian, Y., & Li, J. (2018, October). Estimation of Spatial-Temporal Gait Parameters Based on the Fusion of Inertial and Film-Pressure Signals. *Proceedings of the 2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 1232–1239. <https://doi.org/10.1109/BIBM.2018.8621216>
- Wright, E., Darer, J., Tang, X., Thompson, J., Tusing, L., Fossa, A., Delbanco, T., Ngo, L., & Walker, J. (2015). Sharing physician notes through an electronic portal is associated with improved medication adherence: Quasi-experimental study. *Journal of Medical Internet Research*, 17(10). <https://doi.org/10.2196/jmir.4872>
- Wu, C. C., Chen, Y. J., Hsu, C. S., Wen, Y. T., & Lee, Y. J. (2020). Multiple Inertial Measurement Unit Combination and Location for Center of Pressure Prediction in Gait. *Frontiers in Bioengineering and Biotechnology*, 8. <https://doi.org/10.3389/fbioe.2020.566474>
- Xia, Y., Li, J., Yang, D., & Wei, W. (2023). Gait Phase Classification of Lower Limb Exoskeleton Based on a Compound Network Model. *Symmetry*, 15(1). <https://doi.org/10.3390/sym15010163>
- Yan, L., Zhen, T., Kong, J. L., Wang, L. M., & Zhou, X. L. (2020). Walking gait phase detection based on acceleration signals using voting-weighted integrated neural network. *Complexity*, 2020. <https://doi.org/10.1155/2020/4760297>

-
- Yin, L., Chen, P., Xu, J., Gong, Y., Zhuang, Y., Chen, Y., & Wang, L. (2025). Validity and reliability of inertial measurement units for measuring gait kinematics in older adults across varying fall risk levels and walking speeds. *BMC Geriatrics*, 25(1). <https://doi.org/10.1186/s12877-025-05993-8>
- Yu, H., Alaqtash, M., Spier, E., & Sarkodie-Gyan, T. (2010). Analysis of muscle activity during gait cycle using fuzzy rule-based reasoning. *Measurement: Journal of the International Measurement Confederation*, 43(9), 1106–1114. <https://doi.org/10.1016/j.measurement.2010.04.010>
- Zahradka, N., Verma, K., Behboodi, A., Bodt, B., Wright, H., & Lee, S. C. K. (2020a). An evaluation of three kinematic methods for gait event detection compared to the kinetic-based ‘gold standard.’ *Sensors (Switzerland)*, 20(18), 1–15. <https://doi.org/10.3390/s20185272>
- 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 and Posture*, 27(4), 710–714. <https://doi.org/10.1016/j.gaitpost.2007.07.007>
- Zhang, K., Li, X., Chen, X., Yu, L., Jin, Y., Fan, B., Du, M., Bao, G., Wu, X., & Cai, S. (2025a). Complete Gait Phase Recognition Based on Muscle Synergy Using PSO-CNN-LSTM Algorithm. *IEEE Sensors Journal*, 25(10), 16775–16786. <https://doi.org/10.1109/JSEN.2025.3555287>

ANEXO

Diseño del código para la generación de informes clínicos en Python:

En este anexo se describe el procedimiento desarrollado para la generación automática de informes clínicos de marcha a partir de los registros obtenidos a través de sensores inerciales Xsens y sensores de EMG Delsys. El objetivo es facilitar al personal clínico un documento estructurado, con parámetros cuantitativos y representaciones gráficas, que complemente la valoración tradicional. Para ello se diseñó un código en Python que integra distintas fuentes de información (Excel general, archivos procesados en MVN Analyze y datos de EMG) y automatiza la creación de un informe en formato PDF y Word mediante plantillas HTML. A continuación, se detalla la organización de los datos de entrada, la secuencia de tareas implementadas y las librerías utilizadas en el proceso.

El código extrae la información de cada paciente desde un Excel general, utilizando el identificador. En este documento encontramos el nombre del paciente, su género y su fecha de nacimiento, lo que nos permite calcular automáticamente su edad en el momento del último registro. En cambio, los parámetros espaciotemporales (velocidad, cadencia, longitudes y anchos de paso (derecho, izquierdo y promedio), longitudes de zancada y diferencias entre lados) se leen de los archivos .xlsx generados por el software de Xsens tras procesar los archivos originales .mvn. Estos archivos además de contener los parámetros anteriores incluyen los pasos segmentados y normalizados.

La cadena de tareas que tiene lugar al ejecutar el código es la siguiente:

1. Selección de la carpeta del paciente mediante un interfaz con el usuario.
2. Elección de hasta tres archivos Excel que poseen tanto los parámetros espaciotemporales como la cinemática. El nombre de cada uno de estos archivos incluye el código del paciente, el estado del estudio (T0, T1 o T2) y la fecha en formato año-mes-día, esto es muy importante porque permite ordenarlos temporalmente.
3. Extracción de los datos: se extraen las métricas y se ordenan por fecha para generar la tabla de parámetros espaciotemporales. La fecha del informe será la misma que la del registro más nuevo.
4. El contenido del informe se ha descrito con HTML. Se ha añadido:
 - Logotipos del Hospital Río Hortega y del organismo público SACYL.
 - Tabla clínica y observacionales descritas en HTML.
 - Espacios en blanco para las secciones de: motivo y antecedentes de consulta, historia clínica, conclusiones, recomendaciones y firma, que se completan manualmente por el médico en el WORD final.
 - Las gráficas de cinemática se ordenan siempre de la siguiente forma: pelvis, cadera, rodilla, tobillo y pie, y siempre el lado derecho antes que el lado izquierdo.

- Se incluyen las de imágenes de EMG en formato .png que deberán estar disponibles en la carpeta del usuario en una carpeta llamada ‘EMG’. En el caso de que no estén, el código no dará error, simplemente no lo añadirá.

5. Finalmente, el archivo resultante (informe_analisis_marcha.pdf) se guarda en la carpeta del paciente.

Se pueden observar las ventanas de selección de paciente y registros sobre las siguientes figuras:




Fig. 61. Elección de carpetas y registros.

Las librerías necesarias para la correcta ejecución de este código han sido:

- Tkinter: permite que aparezca la ventana que posibilita elegir la carpeta y los archivos donde están los registros.
- Pandas: permite la lectura de archivos Excel y su extracción de parámetros.
- Jinja2: para el procesamiento gráfico de la plantilla HTML.
- pdfkit + wkhtmltopdf: hace posible la conversión de HTML a PDF.

Una vez programado el código se hicieron una serie de pruebas para comprobar su correcto funcionamiento. Algunas de ellas fueron: uso de uno, dos y tres archivos, archivos con las mismas fechas, ausencia de imágenes EMG...

Para garantizar la correcta ejecución de este código, es necesario proporcionar el entorno de trabajo (*requirements.txt*) y mantener una estructura de carpetas y nombre de archivos unificado.