



UNIVERSIDAD
DE MÁLAGA



TESIS DOCTORAL
P.D. Tecnologías Informáticas

Aprendizaje automático para la
detección de inicio/fin de la marcha
mediante dos sensores inerciales
y modelado de datos usando aprendizaje
profundo

E.T.S.I. Informática
R.D. 99/2011

Autor
Diego Francisco Terán Pineda

Directores

Dr. Enrique Dominguez Merino
Departamento
Lenguajes y Ciencias de la Computación
Universidad de Málaga

Dr. Karl Thurnhofer Hemsí
Departamento
Lenguajes y Ciencias de la Computación
Universidad de Málaga

Abril 2024






UNIVERSIDAD
DE MÁLAGA



UNIVERSIDAD
DE MÁLAGA

AUTOR: Diego Francisco Terán Pineda

 <https://orcid.org/0000-0003-0899-3564>

EDITA: Publicaciones y Divulgación Científica. Universidad de Málaga



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional:

<http://creativecommons.org/licenses/by-nc-nd/4.0/legalcode>

Cualquier parte de esta obra se puede reproducir sin autorización pero con el reconocimiento y atribución de los autores.

No se puede hacer uso comercial de la obra y no se puede alterar, transformar o hacer obras derivadas.

Esta Tesis Doctoral está depositada en el Repositorio Institucional de la Universidad de Málaga (RIUMA): riuma.uma.es





UNIVERSIDAD
DE MÁLAGA



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD DE LA TESIS PRESENTADA PARA OBTENER EL TÍTULO DE DOCTOR

D./Dña DIEGO FRANCISCO TERÁN PINEDA

Estudiante del programa de doctorado TECNOLOGÍAS INFORMÁTICA de la Universidad de Málaga, autor/a de la tesis, presentada para la obtención del título de doctor por la Universidad de Málaga, titulada: APRENDIZAJE AUTOMÁTICO PARA LA DETECCIÓN DE INICIO/FIN DE LA MARCHA MEDIANTE DOS SENSORES INERCIALES Y MODELADO DE DATOS USANDO APRENDIZAJE PROFUNDO

Realizada bajo la tutorización de DR. ENRIQUE DOMÍNGUEZ MERINO y dirección de DR. KARL THURNHOFER HEMSI (si tuviera varios directores deberá hacer constar el nombre de todos)

DECLARO QUE:

La tesis presentada es una obra original que no infringe los derechos de propiedad intelectual ni los derechos de propiedad industrial u otros, conforme al ordenamiento jurídico vigente (Real Decreto Legislativo 1/1996, de 12 de abril, por el que se aprueba el texto refundido de la Ley de Propiedad Intelectual, regularizando, aclarando y armonizando las disposiciones legales vigentes sobre la materia), modificado por la Ley 2/2019, de 1 de marzo.

Igualmente asumo, ante a la Universidad de Málaga y ante cualquier otra instancia, la responsabilidad que pudiera derivarse en caso de plagio de contenidos en la tesis presentada, conforme al ordenamiento jurídico vigente.

En Málaga, a 22 de ABRIL de 2024

| | |
|--|---|
| Fdo.: DIEGO FRANCISCO TERÁN PINEDA Doctorando/a | Fdo.: DR. ENRIQUE DOMÍNGUEZ MERINO Tutor/a |
| Fdo.: DR. KARL THURNHOFER HEMSI - DR. ENRIQUE DOMÍNGUEZ MERINO Director/es de tesis | |





UNIVERSIDAD
DE MÁLAGA



UNIVERSIDAD DE MÁLAGA

Departamento de Lenguajes y Ciencias de la Computación
Escuela Técnica Superior de Ingeniería Informática
Universidad de Málaga

El Dr. D. Enrique Domínguez Merino, Profesor Catedrático del Departamento de Lenguajes y Ciencias de la Computación de la Universidad de Málaga, y el Dr. Karl Thurnhofer Hemsí, Profesor Ayudante Doctor del Departamento de Lenguajes y Ciencias de la Computación de la Universidad de Málaga.

Certifican que,

Las publicaciones que avalan la tesis de D. Diego Francisco Terán Pineda, Ingeniero Mecatrónico y Magister en Automatización y Control Electrónico Industrial, no han sido utilizadas en tesis anteriores y se ha realizado en el Departamento de Lenguajes y Ciencias de la Computación de la Universidad de Málaga, bajo su dirección, el trabajo de investigación correspondiente a su Tesis Doctoral titulada:

**Aprendizaje automático para la detección de inicio/fin de la marcha
mediante dos sensores inerciales y modelado de datos usando
aprendizaje profundo**

Revisado el presente trabajo, estimamos que puede ser presentado al tribunal que ha de juzgarlo. Y para que conste a efectos de lo establecido en la legislación vigente, autorizamos la presentación de este trabajo en la Universidad de Málaga.

Málaga, Abril de 2024

Fdo.: Dr. Enrique Domínguez Merino

Fdo.: Dr. Karl Thurnhofer Hemsí



UNIVERSIDAD
DE MÁLAGA

*Tukuy shunkuwan ñukapa papitopa y mamitapa,
paykuna sumak yuyayta kararka kay ñanta katichun
Con todo mi corazón a mi padre y madre,
ellos me brindaron todo su apoyo durante este camino*



UNIVERSIDAD
DE MÁLAGA

Agradecimientos

*La ciencia no es sino una perversión de
sí misma, a menos que tenga como
objetivo final el mejoramiento de la
humanidad.*

Nikola Tesla

Quisiera expresar mi profundo agradecimiento a un gran número de personas que han dejado una huella imborrable en mi viaje hacia esta grandiosa meta en la Universidad de Málaga. En primer lugar, quiero agradecer de todo corazón a mi padre, Carlos Francisco Terán, y a mi madre, Maria Mercedes Luzmila Pineda Lema. Su amor incondicional y comprensión profunda han sido mi roca en medio de las dificultades que he enfrentado. Nunca faltó su aliento de esperanza, lo cual fue fundamental para completar este arduo camino. Además, quiero destacar mi sincero agradecimiento a mis hermanos, hermanas, panicos, sobrinos y, a mis hermosas sobrinas. Su constante alegría y apoyo moral han sido un faro de luz en mi travesía académica.

En estos agradecimientos también me encantaría empezar por nombrar a los Profesores Enrique y Gonzalo. Desde el momento en que los conocí en Ecuador, han sido guías fundamentales en mi viaje académico, brindándome apoyo constante y valiosos consejos.

Yupaychani (Gracias) Profe Enrique, por su dedicación y compromiso. Su conocimiento profesional, científico y personal ha sido un pilar esencial en mi crecimiento como investigador en ciencias informáticas. Aprecio enormemente haber aceptado la propuesta para iniciar el doctorado que Ud me planteó; me alegro mucho de esa decisión.

También deseo expresar mi sincero agradecimiento al laboratorio por su cálida acogida, y especialmente a Karl. Su orientación, experiencia y profesionalismo fueron clave para elevar mi nivel como investigador y mejorar mis conocimientos en Inteligencia Artificial. Gracias a su guía, pude contribuir de manera significativa a la difusión de los avances hacia la sociedad científica.

El tiempo que he pasado en esta grandiosa Universidad no hubiera sido lo mismo sin la presencia y el apoyo incondicional de Enrique y Karl. Estoy convencido de que esta tesis ha sido posible gracias a su interés y dedicación.



Deseo expresar mi profundo agradecimiento a la Universidad de Málaga y a la AUIP por brindarme la valiosa oportunidad de alcanzar una meta y realizar un sueño que guardaba desde hace muchos años. Esta experiencia ha sido un viaje enriquecedor que va más allá de la obtención de un título académico. Gracias Universidad de Málaga y AUIP por ser parte esencial de este viaje transformador.

Este logro no solo es personal, sino también una muestra para mi país y un ejemplo para todas las nacionalidades y pueblos ancestrales y no ancestrales. Quiero demostrar que, independientemente del lugar de nacimiento, se pueden superar los obstáculos de la vida y lograr metas significativas cuando se tiene determinación. Espero que mi experiencia inspire a otros a seguir persiguiendo sus aspiraciones con tenacidad y esperanza.

A toda mi familia, amigos y amigas que me brindaron su inquebrantable apoyo, gracias a todos y todas. Juyayay Runakuna.

Resumen

0.1. Resumen

Los médicos utilizan extensamente el análisis de la marcha para detectar anormalidades y determinar posibles tratamientos para los pacientes. El análisis de la marcha tiene diversas aplicaciones, que incluyen la identificación de patrones de marcha normales y actividades humanas, el diagnóstico médico, la atención geriátrica, el seguimiento y las estrategias deportivas. Históricamente, este análisis se realizaba de manera subjetiva, pero en la actualidad se emplea tecnología para mejorar la recopilación de datos y la precisión de la información.

Esta tesis doctoral se centra en la investigación de la medición y la aplicación de la marcha humana, abordando los siguientes aspectos:

1. Adquisición de datos de la marcha humana mediante tecnologías de Sensores Portátiles-Wearable Sensors.
2. Diseño de un sistema para obtener un modelo de la cinemática de la marcha humana y predecir eventos de la misma utilizando deep learning.
3. Extracción de características a través de un método novedoso para el entrenamiento de algoritmos de machine learning, con el objetivo de evitar la redundancia de información.

La tesis se estructura en cuatro partes fundamentales. La primera se dedica a una revisión general que aborda la motivación, los objetivos, la contribución y los propósitos del documento. La segunda parte se centra en exponer los fundamentos de la marcha humana, los algoritmos de inteligencia artificial, y posteriormente, ofrece una revisión del estado del arte enfocada en el estudio de aplicaciones de la marcha humana. La tercera parte aborda las publicaciones que respaldan esta investigación.

Finalmente, se presentan y discuten las conclusiones generales de la investigación, así como las posibles líneas de investigación futuras que podrían aprovechar los resultados obtenidos en esta tesis doctoral.



UNIVERSIDAD
DE MÁLAGA

Abstract

Medics extensively utilize gait analysis to detect abnormalities and determine potential patient treatments. Gait analysis has various applications, including identifying standard gait patterns and human activities, medical diagnosis, geriatric care, monitoring, and sports strategies. Historically, this analysis was performed subjectively, but nowadays, technology enhances data collection and information accuracy.

This doctoral work focuses on the research of human gait measurement and applications, addressing the following aspects:

1. The acquisition of human gait data using WS technologies
2. The design of a system to obtain a model of human gait kinematics and predict events using deep learning
3. Feature extraction through a novel method for training machine learning algorithms, aiming to avoid information redundancy

The thesis is structured into four fundamental parts. The first is dedicated to a general review that addresses the document's motivation, objectives, contribution, and purposes. The second part focuses on presenting the fundamentals of human gait and artificial intelligence algorithms and reviews the state-of-the-art studies of human gait applications. The third part addresses the publications supporting this research.

Finally, the general conclusions of the research are presented and discussed, along with possible future research directions that could leverage the results obtained in this doctoral thesis.



UNIVERSIDAD
DE MÁLAGA

Índice

| | |
|--|-------------|
| Agradecimientos | XI |
| Resumen | XIII |
| 0.1. Resumen | XIII |
| Abstract | XV |
| 1. Introducción | 1 |
| 1.1. Motivación | 2 |
| 1.2. Objetivos | 4 |
| 1.3. Fases | 5 |
| 1.4. Contribuciones de la tesis | 6 |
| 1.5. Organización | 7 |
| I Contexto y Fundamentos | 9 |
| 2. Fundamentos y Estado de Arte | 11 |
| 2.1. Fundamentos de la marcha humana | 11 |
| 2.1.1. Fases de la marcha | 12 |
| 2.1.2. Medición de la marcha humana | 13 |
| 2.2. Algoritmos de Inteligencia Artificial | 17 |
| 2.2.1. Aprendizaje automático - Machine Learning | 18 |
| 2.2.2. Aprendizaje profundo - Deep Learning | 29 |
| 2.3. Evaluación del rendimiento. | 33 |
| 2.3.1. Medidas de rendimiento | 33 |
| 2.4. Señales | 36 |
| 2.4.1. Análisis de frecuencia | 38 |
| 2.5. Conjunto de datos | 40 |
| 2.5.1. Base de datos de la marcha humana - HuGaDB | 40 |
| 2.6. Estado del arte | 41 |
| 2.6.1. Métodos usados para reconocer actividades humanas | 42 |



| | |
|--|-----------|
| 2.6.2. Método usados para reconocer eventos de la marcha humana. | 45 |
| II Eventos de la Marcha Humana | 47 |
| 3. Sistema de Adquisición de Datos | 49 |
| 3.1. Introducción | 49 |
| 3.2. Métodos para adquisición de Marcha Humana | 50 |
| 3.2.1. Modelos de predicción | 51 |
| 3.2.2. Resultados | 53 |
| 3.3. Conclusión | 54 |
| 4. Detección de evento de la marcha humana basado en aprendizaje profundo | 57 |
| 4.1. Introducción | 58 |
| 4.2. Metodología | 60 |
| 4.2.1. Sistema de Adquisición de Datos (DAS) | 60 |
| 4.2.2. Contrucción del Modelo | 62 |
| 4.3. Resultados | 69 |
| 4.3.1. Dataset | 71 |
| 4.3.2. Preparación de datos | 71 |
| 4.3.3. Evaluación del rendimiento | 73 |
| 4.4. Conclusiones | 77 |
| III Modelado de la Marcha Humana | 79 |
| 5. Modelado para reconocimiento de actividades | 81 |
| 5.1. Introducción | 82 |
| 5.2. Trabajos relacionados | 84 |
| 5.3. Modelado para reconocimiento de actividades | 85 |
| 5.3.1. Procesamiento de señal | 86 |
| 5.3.2. Análisis de ancho de banda deslizante | 96 |
| 5.4. Resultados | 97 |
| 5.4.1. Descripción de la Base de Datos | 97 |
| 5.4.2. Experimento utilizado algoritmos clasificadores | 98 |
| 5.4.3. Análisis de Ancho de Banda | 99 |
| 5.4.4. Estudio de ablación con menos sensores | 101 |
| 5.4.5. Experimento con el sistema DAS | 110 |
| 5.5. Conclusiones | 111 |

| | |
|--|------------|
| ÍNDICE | XIX |
| IV Conclusiones | 113 |
| 6. Conclusiones y trabajos futuros | 115 |
| V Apéndices | 119 |
| A. Resumen de publicaciones obtenidas | 121 |
| A.1. Revistas indexadas en el JCR | 121 |
| A.2. Artículos publicados en congresos Internacionales | 122 |
| B. Publicaciones obtenidas | 125 |
| Bibliografía | 133 |



UNIVERSIDAD
DE MÁLAGA

Índice de figuras

| | |
|--|----|
| 2.1. Fases de la marcha humana. | 14 |
| 2.2. Técnicas de medición de movimiento. | 15 |
| 2.3. Diagrama que describe cómo funciona un arboles de decisión. | 22 |
| 2.4. Diagrama que describe cómo funciona el algoritmo de Bayes. | 23 |
| 2.5. Funcionamiento del algoritmo SVM. | 24 |
| 2.6. Ilustración del algoritmo de clasificación del vecino más cercanos de dos características x_1 y x_2 | 26 |
| 2.7. Representación de una red biológica. | 26 |
| 2.8. Perceptrón multicapa. | 27 |
| 2.9. Arquitectura de las Redes Neuronales. | 29 |
| 2.10. Red Neuronal Recurrente. | 30 |
| 2.11. Red LSTM. | 31 |
| 2.12. Red convolucional. | 32 |
| 2.13. Modelo de secuencia a secuencia | 33 |
| 2.14. Matriz de confusión | 35 |
| 2.15. Espectro de una señal | 38 |
| 2.16. Instalación de sensores en la extremidad inferior | 42 |
| 3.1. Marcha humana adquirida por el sistema DAS. | 51 |
| 3.2. Modelo de curva cinemática. | 52 |
| 4.1. Arquitectura de flujo del modelo propuesto | 61 |
| 4.2. Señal angular adquirida mediante el sistema DAS | 62 |
| 4.3. Eliminación de tendencia de la señal | 63 |
| 4.4. Modelado de datos de la cinemática mediante Redes Neuronales Profundas | 65 |
| 4.5. Modelado de datos de la cinemática mediante Red Neuronal Recursiva | 65 |
| 4.6. Modelado de datos de la cinemática mediante LSTM | 66 |
| 4.7. Modelado cinemática con una Banda de Confianza del 95 % | 66 |
| 4.8. Ventanas deslizantes entre el vector de consulta Q y los datos recopilados X | 67 |



| | |
|---|-----|
| 4.9. Búsqueda de señal con ventanas deslizantes | 69 |
| 4.10. Evento HS detectado en el conjunto de marcha | 70 |
| 4.11. Detección automática de eventos HS | 70 |
| 4.12. Señal adquirida de DAS, con impulsos FSR | 72 |
| 4.13. Datos sin impulsos FSR | 73 |
| 4.14. Eventos HS generados manualmente a partir de los pulsos del FSR | 73 |
| 4.15. Predicción de eventos HS | 73 |
| 4.16. Error de predicciones | 74 |
| 4.17. Eventos detectados en la marcha humana | 74 |
| 4.18. Corrección de sucesos | 74 |
| 4.19. Entrenamiento con el subconjunto de mujeres | 75 |
| 4.20. Entrenamiento con el subconjunto de hombres | 75 |
| 4.21. Entrenamiento con todos los datos mujeres | 76 |
| 4.22. Entrenamiento con todos los datos hombres | 76 |
| 5.1. Diagrama de flujo de la metodología | 86 |
| 5.2. Señal bruta del acelerómetro del eje X | 87 |
| 5.3. Representación de la señal en el dominio de la frecuencia du- rante la actividad de caminar | 89 |
| 5.4. Espectro del pie derecho | 91 |
| 5.5. Espectro de la tibia derecha | 91 |
| 5.6. Espectro del muslo derecho | 92 |
| 5.7. Espectro del pie izquierdo | 93 |
| 5.8. Espectro de la tibia izquierda | 93 |
| 5.9. Espectro del muslo izquierdo | 94 |
| 5.10. Ejemplo del cálculo del complejo QRS en el primer espectro | 94 |
| 5.11. Ejemplo del ancho de banda seleccionado | 97 |
| 5.12. Evolución de la precisión en diferentes anchos de banda | 100 |
| 5.13. Análisis Discriminante para Clasificación (DA) | 101 |
| 5.14. Clasificación mediante Máquinas de Vectores de Soporte (SVM) | 102 |
| 5.15. Clasificación mediante Redes Neuronales (NN) | 102 |
| 5.16. Evolución de la precisión disminuyendo sensores | 103 |
| 5.17. Precisión de actividades: Seis sensores | 104 |
| 5.18. Precisión de actividades: Cinco sensores | 104 |
| 5.19. Precisión de actividades: Cuatro sensores | 105 |
| 5.20. Precisión de actividades: Tres sensores | 105 |
| 5.21. Precisión de actividades: Dos sensores | 106 |
| 5.22. Ubicación de los sensores en las extremidades inferiores del cuerpo | 107 |

5.23. Ubicación de los sensores en las extremidades inferiores del cuerpo 107

5.24. Ubicación de los sensores en las extremidades inferiores del cuerpo 108

5.25. Ubicación de los sensores en las extremidades inferiores del cuerpo 108

5.26. Comparación de precisión del sensor instalado en una pierna: LT con LS, experimento con clasificador DA 108

5.27. Comparación de precisión del sensor instalado en una pierna: LT con LS, experimento con clasificador SVM 109

5.28. Comparación de precisión del sensor instalado en una pierna: LT con LS, experimento con clasificador NN 109

5.29. Comparación de precisión del sensor instalado en una pierna: RT con RS, experimento con clasificador DA 109

5.30. Comparación de precisión del sensor instalado en una pierna: RT con RS, experimento con clasificador SVM 109

5.31. Comparación de precisión del sensor instalado en una pierna: RT con RS, experimento con clasificador NN 110

5.32. Diagrama de bloque del sistema DAS 110





UNIVERSIDAD
DE MÁLAGA

Capítulo 1

Introducción

Es crucial buscar formas de compartir la información derivada de la ciencia y tecnología con aquella sociedad que enfrentan dificultades para acceder a ella.

Dieguin Ck

RESUMEN: Este capítulo proporciona una breve introducción a la tesis, presentando el contexto y la motivación en los que se desarrolla, así como los objetivos establecidos y la metodología empleada. Finalmente, se describe la estructura utilizada en esta tesis.

Una de las actividades más comunes y naturales en la vida diaria humana es caminar; la habilidad de caminar involucra la coordinación del cerebro, nervios y músculos, y es necesaria para entender los movimientos de los humanos (cinemática) y las fuerzas (cinética) que son aplicadas en las articulaciones móviles [51, 57, 28]. Asimismo, la tendencia a evaluar el estado, tratamiento y recuperación de los casos son examinados por fisioterapeutas, ortopedistas y neurólogos [48]. En [53], la marcha humana puede ser difícil de diagnosticar; además, el análisis del movimiento es esencial en neurología, rehabilitación y fisioterapia para detectar trastornos y controlar diferentes síntomas neurológicos en la marcha humana [11, 31, 20].

El estudio de la marcha humana normal y anormal explora muchos parámetros, entre los que se incluyen la amplitud y el patrón del movimiento articular, las fuerzas de reacción del suelo, el momento del contacto entre el pie y el suelo, las velocidades de la marcha, las cadencias, las longitudes de zancada, las relaciones entre las fases de balanceo y apoyo, los ángulos articulares en reposo, los pares isométricos y las actividades musculares fásicas. Además, los parámetros de la fase de balanceo a la de apoyo tienen tres eventos importantes en un ciclo de la marcha: el balanceo medio (MS),



el golpe de talón (HS) y el despegue de la punta del pie (TO); normalmente, el 60 % del ciclo de la marcha transcurre en la fase de apoyo y el 40 % en la fase de balanceo.

La identificación del patrón de marcha normal, el diagnóstico médico, el cuidado geriátrico o de personas mayores, el control y las tácticas deportivas forman parte de la aplicación basada en el análisis de la marcha. La disponibilidad de parámetros cuantitativos de la marcha normal es esencial para la detección de trastornos de la marcha, así como: la identificación de las características del equilibrio, la evaluación de las intervenciones de la marcha médica y desarrollos de rehabilitación con la medición objetiva cuantitativa de los diferentes parámetros de la marcha y sobre la evolución y el diagnóstico precoz de diferentes enfermedades [48, 55]. Existen factores extrínsecos, intrínsecos, físicos psicológicos y patológicos que influyen la marcha normal, por lo que determinar los parámetros de marcha normal es una tarea muy compleja, siendo difícil el diagnóstico de la marcha [53].

Las afecciones neurológicas, como las secuelas de un derrame, un accidente o la enfermedad de Parkinson, pueden provocar el deterioro de las habilidades motoras y una disminución de la capacidad para caminar, lo que repercute significativamente en el bienestar general y la salud de las personas[36]. El rápido proceso de envejecimiento ha aumentado la prevalencia de las enfermedades neurológicas, y muchas alteraciones de las funciones motoras del organismo son irreversibles, lo que representa un desafío importante para el sistema sanitario [8]. En consecuencia, existe una necesidad urgente de ayudar a las personas mayores o a los pacientes a superar los trastornos del movimiento y a recuperar su capacidad para caminar, mejorando en última instancia su vida cotidiana. Por ejemplo, un artículo citado en [57] destaca que entre las personas mayores, las caídas son la principal causa de mortalidad en los Estados Unidos, representando el 56 % de las muertes no intencionadas o no tratadas en 2014[14]. Para respaldar esta observación a nivel mundial, [48] presenta diversos resultados sobre las muertes relacionadas con caídas, que incluyen un 33 % en Australia, un 19.3 % en Hong Kong, un 21.6 % en Bridgetown (Barbados), un 29 % en La Habana (Cuba), un 33 % en Ciudad de México (México) y un 34 % en Santiago (Chile). Por lo tanto, es esencial conocer los eventos de la marcha (HS y TO) e identificar con precisión las fases de la marcha en tiempo real para una intervención médica eficaz en la rehabilitación [69].

1.1. Motivación

Los médicos utilizan extensamente el análisis de la marcha para detectar anomalías y determinar posibles tratamientos para los pacientes. El análisis de la marcha tiene diversas aplicaciones, que incluyen la identificación de patrones de marcha normales y actividades humanas, el diagnóstico

médico, la atención geriátrica, el seguimiento y las estrategias deportivas. Históricamente, este análisis se realizaba de manera subjetiva, pero en la actualidad se emplea tecnología para mejorar la recopilación de datos y la precisión de la información.

Esta tecnología se clasifica en tres enfoques: a) Sensores portátiles - Wearable Sensor (WS), b) Sensores no portátiles - Nowearable sensor (NWS), y c) Sistemas híbridos. Estas técnicas han permitido estudiar la marcha humana normal y anormal explicando varios parámetros como: amplitud y el patrón de movimiento de las articulaciones, fuerzas de reacción del suelo, momento de contacto pie/suelo, velocidades de marcha, cadencias, longitudes de zancada, relaciones de fase relaciones de fase, ángulos articulares en reposo, pares isométricos y actividades musculares básicas.

En desarrollo computacional de las herramientas de Inteligencia Artificial (Machine Learning y Deep Learning) los investigadores de esta área se han centrado en mejorar la salud, la seguridad de la comunidad y sistemas de entrenamiento de marcha integrando tecnologías mecánicas, electrónicas y robóticas. Además, se puede mencionar que existen tres áreas fundamentales de investigación: (1) la medición de la marcha y la intención de caminar, (2) la evaluación de la marcha y (3) la estrategia de control de la marcha para lograr comprender y medir la marcha humana tanto para su aplicación en el ámbito clínico como para la prevención de futuras enfermedades.

Dado este contexto, se han identificado un conjunto de problemas vinculado a la investigación de la marcha humana.

- El acceso a la tecnología WS y NWS para adquirir datos de la marcha humana. El empleo del NWS implica la necesidad de una sala equipada con sensores (Cámara triangular, adquisición de video 3D mediante cámara en tiempo de vuelo, luz de estructura, cámaras termográficas y sensores de fuerza instalados en el piso) para registrar la marcha del sujeto al caminar, lo que conlleva principalmente un aumento en los gastos de instalación y adquisición de equipo. Sin embargo, el empleo de tecnología WS se ha incrementado para resolver el problema de uso de laboratorios; debido a que, estos sensores son instalados en el cuerpo y extraen información significativa de las actividades de las personas. Los sensores inerciales (sensores multimodales) y gionómetros son los más utilizados para desarrollar este tipo de tecnología. Es necesario por tanto, desarrollar un sistema de adquisición que acerquen a la tecnología WS.
- El segundo problema se refiere al número de sensores WS instalados en el cuerpo para estudiar la marcha humana y entrenar modelos de IA; para lo cual, este problema se divide en dos partes: 1) mejorar el aprendizaje de algoritmos IA extrayendo extrayendo características (features) con métodos novedosos y evitar información redundante y,

- 2) reducir el número de sensores.
 1. Es crucial utilizar métodos de selección que permitan identificar las características más significativas en los conjuntos de datos, con el propósito de simplificar los modelos aprendidos y reducir la complejidad computacional, mejorando así la eficiencia del modelo. La extracción de características más avanzadas, como medidas de entropía o frecuencia, ha demostrado ofrecer resultados prometedores. Los autores propusieron una metodología novedosa basada en el dominio de la frecuencia y reducción del ancho de banda de las señales del acelerómetro IMU para aplicaciones de reconocimiento de actividades-HAR (se ha utilizado la base de datos HuGaDB para analizar los resultados). Además, se analizó la cantidad mínima de características necesarias para obtener un buen rendimiento en el entrenamiento del modelo y disminuir el tiempo computacional del procesado de la señal y la clasificación.
 2. Utilizar los datos de nuestro sistema de adquisición con tecnología de Sensores Portátiles-Wearable Sensors (DAS System) con el menor número de sensores para mejorar la ergonomía del paciente y reducir el tiempo de procesamiento de las señales adquiridas para entrenar el algoritmo IA. Los autores aplican transformaciones a la señal con el objetivo de simplificar la carga computacional y número de sensores, reduciendo la dimensionalidad de las características. Para evaluar la eficacia de nuestro enfoque, se emplean clasificadores ampliamente aceptados. Esta metodología se pone a prueba con éxito en un conjunto de datos público de referencia denominado Human Gait Database (HuGaDB) antes de su validación en nuestro propio conjunto de datos, utilizando diversos clasificadores de aprendizaje automático bien conocidos.
- Otro problema que se detectó es la validación de nuestra metodología para detectar los pasos de inicio y fin de la marcha humana. Por ello, se realizó un análisis bibliográfico profundo para seleccionar el método, y seguido implantar para comparar con nuestro método.

1.2. Objetivos

Cada vez gana más interés el estudio de la marcha humana usando técnica WS, no solo en el campo de la medicina, también en otros campos de investigación, como obtener el modelo de la cinemática para ayudar el estudio físico del sujeto. Es posible establecer diferentes técnicas de modelación de sistemas, así como la adquisición de datos mediante técnicas WS. Cabe recalcar que las pruebas en cintas de correr con NWS no dan datos reales

debido a que afecta la caminata normal y en deportistas la carrera normal, por tanto, afecta a la precisión del análisis que en deportistas desean conocer.

El objetivo principal que se pretende conseguir con este sistema es diseñar un sistema para modelar la cinemática de la marcha humana mediante la adquisición de datos de dos sensores inerciales. Para lo cual se pretende enseñar al sistema por medio de aprendizaje automático la detección de inicio y fin de la marcha; además, mediante aprendizaje profundo encontrar un modelo de marcha del sujeto.

Para la realización de este trabajo es necesario llevar a cabo otros objetivos más específicos que lleven a la consecución del objetivo final, entre ellos:

- Conocer nuevas técnicas de las tendencias en el desarrollo de aprendizaje automático en la obtención de la cinemática de la marcha humana; como también en las técnicas de aprendizaje profundo para encontrar un patrón.
- Conocer el funcionamiento del sistema diseñado con los datos adquiridos de los sensores inerciales para una mejora continua.
- Analizar la aplicación en entorno real con la ayuda de un especialista para obtener resultados factibles para el especialista.
- Evaluar empíricamente los resultados obtenidos en torno a actividades normales.

1.3. Fases

Para alcanzar los objetivos específicos de cada área de investigación, se llevaron a cabo las siguientes etapas o fases:

- Revisión exhaustiva del estado actual de la investigación en estudios de la marcha humana, y se investigaron diversas herramientas de algoritmos inteligentes utilizadas para detectar el inicio y el final de la marcha humana mediante el uso de dos sensores inerciales. Se evaluaron las técnicas de optimización existentes y se exploró la posibilidad de incorporar nuevos algoritmos con el fin de mejorar los resultados. Además, se llevó a cabo un análisis práctico de la utilidad de los sensores inerciales, investigando su aplicación en la clasificación de actividades y la detección de eventos relacionados con la marcha humana.
- Para lograr este objetivo, se ha desarrollado una mejora continua de un sistema de adquisición portátil no invasivo que utiliza un algoritmo recursivo en línea. Este sistema cuenta con un microcontrolador encargado de procesar y filtrar las señales provenientes de los sensores. El

sistema de adquisición de datos, conocido como DAS (Data Acquisition System), emplea una resistencia sensible a la fuerza (FSR) y dos sensores de inercia. Además, el DAS cuenta con una interfaz inalámbrica que almacena los datos recopilados. De esta manera, hemos logrado obtener la curva cinemática de la marcha humana correspondiente a la zona sagital de la rodilla.

- Después de disponer de una amplia gama de datos, se llevó a cabo un estudio de investigación detallado en el que se aplicaron métodos destinados a identificar las características más significativas en los conjuntos de datos. Como resultado, se diseñó un método innovador basado en el análisis del dominio de la frecuencia para identificar los espectros de potencia que contienen la información más relevante. Los resultados obtenidos contribuyeron a simplificar el número de sensores inerciales necesarios y a reducir la dimensionalidad de las características de manera efectiva.
- Por último, se llevó a cabo un análisis exhaustivo de los algoritmos de detección de eventos en la marcha humana, como el inicio y el fin de la misma. A continuación, se desarrolló un innovador enfoque para la detección de eventos en la marcha utilizando un modelo cinemático que incorpora algoritmos de redes neuronales y correlación cruzada. En este estudio, se emplearon sensores FSR exclusivamente para entrenar el modelo cinemático, seguido por el uso de tan solo dos sensores IMU para optimizar y detectar el inicio y el fin de la marcha. Para validar este método, se planea llevar a cabo una comparación con otro enfoque utilizando nuestros propios datos como referencia. Este estudio proporcionó publicaciones de resultados en diferentes revistas JCR y congresos internacionales.

1.4. Contribuciones de la tesis

La principal meta de contribución establecida en esta tesis es la mejora de la precisión en la detección del inicio y fin de la marcha humana, así como en la clasificación de las actividades humanas. Por esta razón, resulta fundamental examinar y analizar el proceso de modelado para poder desarrollar métodos que se adapten a diversas necesidades. Esto implica la creación de nuevos algoritmos de detección o clasificación, tanto en un contexto general como específico, teniendo en cuenta las particularidades del hardware y los escenarios particulares.

Con el fin de cumplir estos objetivos generales, se destacan las principales contribuciones de esta tesis:

- Propuesta de la adquisición de datos basado en la marcha humana

utilizando tecnología de Sensores Portátiles-Wearable Sensors la cuál incluye dos sensores inerciales y un sensor FSR. Versión de acceso libre para su mejora continua y su posterior distribución pública.

- Propuesta e implementación de un sistema para la extracción de un modelo cinemático correspondiente a la rodilla en la zona sagital de la marcha humana.
- Propuesta e implementación de un método novedoso de extracción de características utilizado en el dominio de la frecuencia y espectro de potencia.
- Propuesta e implementación de un método novedoso para analizar el número de sensores necesarios y su posición para detectar actividades humanas.
- Propuesta e implementación de un método novedoso para detectar el inicio y fin de la marcha humana.

1.5. Organización

Esta tesis ha sido estructurada de la siguiente manera. El capítulo actual consiste en una introducción al trabajo realizado, donde se presenta la motivación que impulsó su realización, los objetivos que se persiguieron, las etapas que se siguieron para alcanzar dichos objetivos y las principales contribuciones de la tesis.

La Parte I se dedica a describir los principios de los algoritmos de aprendizaje automático y profundo que se utilizaron para abordar el problema, además de ofrecer una exposición de los conceptos tecnológicos aplicados a la adquisición de datos relacionados con la marcha humana y a los aspectos vinculados a los diversos tipos de señales involucrados. Además, esta Parte aborda el estado del arte principal correspondiente a nuestro trabajo.

En la Parte II se examina el problema de la detección de eventos durante la marcha humana, dividido en dos capítulos principales: el Método de Adquisición de la Marcha Humana (Capítulo 3) y un enfoque novedoso para predecir eventos de la marcha utilizando técnicas de aprendizaje profundo (Capítulo 4). Por otro lado, la Parte III se centra en la detección de actividades humanas, presentando un nuevo método de extracción de características diseñado para el entrenamiento de algoritmos de aprendizaje automático. El objetivo principal de este enfoque es evitar la redundancia de información y mejorar la precisión en la detección de actividades.

Por último, la Parte IV engloba las conclusiones de esta disertación, así como las posibles líneas de investigación futuras que podrían surgir a partir de este estudio.



UNIVERSIDAD
DE MÁLAGA

Parte I

Contexto y Fundamentos



UNIVERSIDAD
DE MÁLAGA

Capítulo 2

Fundamentos y Estado de Arte

Lo que todos tenemos que hacer es asegurarnos de que estamos usando la IA de una manera que sea en beneficio de la humanidad, no en detrimento de la humanidad.

Tim Cook

RESUMEN:

En este capítulo nos centramos en la definición y la teoría de la marcha humana, así como sus aplicaciones en diferentes áreas. Proporcionamos una descripción de las tecnologías relacionadas con la adquisición de señales de la marcha. Luego, basándonos en la literatura revisada, presentamos el impacto y los usos que ha tenido esta tecnología, así como la aplicación de algoritmos de inteligencia artificial en áreas como las Ciencias de la Vida y la atención de la salud.

2.1. Fundamentos de la marcha humana

Antes de abordar sobre los fundamentos teóricos, técnicas de marcha y algoritmos, es importante examinar la definición de los términos marcha y caminar. Según la definición del investigador Nutt et al. [42], la marcha se define como un movimiento coordinado de los miembros inferiores que implica flexión y extensión repetitiva e involuntaria. El patrón de locomoción, ya sea caminar, correr, gatear, entre otros, junto con la postura asociada, se denomina “marcha”.

La marcha humana constituye una forma específica de locomoción, ya que los seres humanos son una especie bípeda, lo que significa que se desplazan sobre dos extremidades. Aunque las personas a menudo utilizan las palabras andar y caminar de manera intercambiable, es importante destacar que la



marcha se refiere más a una forma específica de caminar que al acto general de caminar. Whittle [71] sugiere que tiene más sentido comparar los patrones de marcha en lugar de los patrones de caminar.

Una vez abordados y definidos los términos “marcha” y “caminar”, se puede establecer que la marcha humana constituye una actividad natural que las personas realizan cada vez que se desplazan de un lugar a otro, implicando la coordinación de músculos, nervios y actividades cerebrales. Las articulaciones humanas desempeñan un papel fundamental en el movimiento del cuerpo, lo que hace necesario realizar un análisis de la marcha para comprender tanto su cinética como su cinemática [51, 57]. Estos aspectos son examinados minuciosamente por profesionales de la salud, como fisioterapeutas, ortopedistas y neurólogos, con el fin de analizar y evaluar el estado de los pacientes, definir tratamientos adecuados y llevar a cabo procesos de rehabilitación [48].

Tanto factores extrínsecos como intrínsecos, que pueden ser de naturaleza psicológica o física, influyen en las actividades diarias de las personas. Por lo tanto, determinar los parámetros normales de la marcha representa un desafío significativo [53]. Además, la importancia de este estudio se refleja en su amplia gama de aplicaciones en diversos campos, como la neurología, donde se emplea para realizar un seguimiento de síntomas neurológicos [20], así como en la rehabilitación y fisioterapia, donde es esencial para detectar y tratar trastornos relacionados con la marcha [11, 31].

La investigación asociada con la marcha humana se conoce como análisis de la marcha. Es una técnica sistemática para reconocer desviaciones negativas en el patrón de marcha y determinar su motivo y efectos. El análisis de la marcha es una forma de revelar los mecanismos del movimiento humano cuantificando los factores que rigen la funcionalidad de las extremidades inferiores. El análisis de la marcha humana tiene numerosos usos, como diagnóstico médico, seguridad, animación, industria y ciencias del deporte [47].

En el análisis de la marcha para la recuperación médica, los sistemas analizadores de movimiento ópticos se han utilizado ampliamente para monitorear la respuesta del paciente. La marcha disfuncional puede deberse a una lesión aguda o crónica o a una biomecánica inadecuada. Los fisioterapeutas y ortopedistas pueden monitorear y analizar las variables del movimiento de la marcha, es decir, longitud de la zancada, longitud del paso, cadencia, fase de postura y balanceo, etc. de dichos pacientes, para señalar si se ha producido una mejora [20].

2.1.1. Fases de la marcha

Un ciclo de marcha abarca las actividades que ocurren desde el punto de contacto inicial de una extremidad inferior (específicamente talón) hasta

el momento en que esa misma extremidad vuelve a hacer contacto con el suelo. Durante este proceso, se lleva a cabo la propulsión hacia adelante del centro de gravedad. De igual manera, la marcha es un proceso coordinado que involucra la extremidad inferior, la pelvis y la columna vertebral. Un ciclo completo de marcha implica dos pasos, uno realizado con el pie derecho y otro con el izquierdo, o viceversa.

Un ciclo de marcha único se conoce como zancada (*stride* en inglés) y también incluyen sus respectivas fases, junto con los intervalos esperados de dichas fases y subfases. Estos detalles pueden ser observados en la Figura 2.1. Este ciclo consta principalmente de dos fases: la fase de balanceo y la fase de apoyo. Normalmente, en un ciclo de marcha se producen tres eventos importantes, según se describió en un estudio previo [33]: el apoyo medio (MS - *Mid-Swing* en inglés), el golpe de talón (HS - *Heel-Strike* en inglés) y el despegue del dedo del pie (TO - *Toe-Off* en inglés).

El período durante el cual el pie permanece en contacto con el suelo, que va desde HS hasta TO, se conoce como la fase de apoyo, y representa aproximadamente el 60 % del ciclo normal de la marcha. Por otro lado, la fase de balanceo, que va desde TO hasta HS, comprende el 40 % restante del ciclo de la marcha.

La fase de postura y la fase de balanceo pueden dividirse en ocho segmentos, denominados incidentes críticos, que permiten a los examinadores especificar con mayor precisión los aspectos anormales de la marcha [48]. Las marchas disfuncionales pueden deberse a una lesión aguda o crónica o a una biomecánica inadecuada. Esto limita la capacidad normal de carga de peso en el bípedo y tiene un impacto en las tensiones ejercidas sobre las superficies articulares.

2.1.2. Medición de la marcha humana

En la literatura, se encuentran diversas metodologías para el reconocimiento y análisis de la marcha humana, que abarcan enfoques basados en procesamiento de imágenes, sensores colocados en el suelo o en diversas partes del cuerpo, entre otros que se puede observar en la Figura 2.2. Los dispositivos tecnológicos más empleados en la investigación se pueden clasificar según lo señalado por Muro-De-La-Herran et al. 39:

- Sensores no portátiles (Non-Wearable Sensor - NWS)
- Sensores portátiles (Wearable Sensor - WS)
- Sistemas híbridos

El uso de NWS (sensores no portátiles) implica la necesidad de contar con una sala equipada con sensores instalados para capturar la marcha mientras

¹<https://www.streifeneder.es/>




Figura 2.1: Fases de la marcha humana y Eventos [33]. Imagen extraída de la empresa Streifeneder ¹

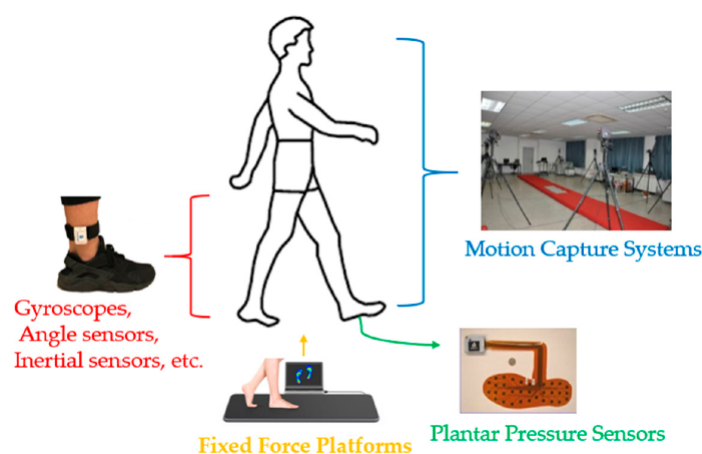


Figura 2.2: Técnicas de medición de movimiento de última generación utilizadas en sistemas de entrenamiento de la marcha. Imagen extraída de [28].

el individuo camina. Esto conlleva un costo más elevado en términos de instalación y equipamiento. Para la captura de la marcha, se han propuesto diversas técnicas, como se menciona en el trabajo de referencia [57, 30].

- Cámara triangular.
- Adquisición de video 3D mediante cámara en tiempo de vuelo (Time of flight - ToF).
- Luz de estructura.
- Cámaras termo-gráficas.

Los sensores portátiles, conocidos como *Wearable Sensors* (WS), se colocan en el cuerpo del individuo y no requieren de un laboratorio especializado. Esta técnica permite adquirir información de señales biométricas durante las actividades diarias personales. Un sistema WS emplea una variedad de sensores, como acelerómetros, giroscopios, magnetómetros, sensores de fuerza, extensómetros, goniómetros, marcadores activos y electromiografía. Utilizando estos sensores inerciales, se puede determinar con gran precisión la orientación, velocidad y aceleración, lo que permite calcular el ángulo de flexión/extensión de las articulaciones.

Además de los sensores mencionados, pueden incluir sensores de fuerza, acelerómetros, giroscopios, extensómetros, inclinómetros, goniómetros, marcadores activos, electromiografía, entre otros. Para optimizar las funcionalidades de estos sensores, como acelerómetros, giroscopios y magnetómetros, a menudo se fusionan en una única unidad llamada Unidades de Medición Inercial (IMUs), utilizando tecnologías de fusión de sensores multimodales.

Entre las ventajas de los WS se encuentra la capacidad de almacenar datos durante la marcha o carrera sin necesidad de realizar modificaciones en el entorno (como el uso de una cinta andadora que podría alterar la marcha normal). Sin embargo, es importante señalar que los WS también presentan algunas limitaciones o inconvenientes, tales como:

- Se necesita una cantidad significativa de experiencia y aportes humanos para procesar los datos, y, extraer características significativas para los análisis. Por lo tanto, puede ser ventajoso desarrollar enfoques avanzados de aprendizaje automático que no requieran una derivación a priori en las medidas de resultado [30].
- La instalación y la incomodidad por el número de sensores utilizados para el estudio de la marcha.
- Debido a la instalación con correas, puede provocar contener el funcionamiento de los músculos.
- El coste computacional aumenta por el tratamiento de datos y del número de sensores usados.
- Los atletas prefieren correr sin nada unido a ellos, por lo tanto, se han realizado investigaciones para estimar la marcha humana con el menor número de sensores posibles.

Los estudios sobre la marcha en seres humanos han desempeñado un papel crucial en la mejora de la salud y la seguridad de la comunidad. Estos estudios han impulsado la investigación en sistemas de marcha que integran tecnologías mecánicas, de detección, electrónicas y robóticas.

Los sensores inerciales portátiles han recibido una amplia atención en la investigación y han fomentado el desarrollo de novedosas aplicaciones para el reconocimiento de la actividad humana. Estas aplicaciones incluyen la rehabilitación de la e-salud, la vigilancia de seguridad, los servicios de emergencia, la asistencia al bienestar, las casas inteligentes y los sistemas de biofeedback [25]. Se han realizado estudios sobre el análisis de la marcha utilizando WS, donde algunos trabajos proponen algoritmos novedosos para estimar el ángulo de la rodilla [3] o utilizan potentes algoritmos de aprendizaje profundo, como se describe en [64]. Además, se han llevado a cabo investigaciones para examinar los efectos de estos sensores [18], así como la evaluación de la marcha en 3D [54]. También se han aplicado en pacientes para conocer la marcha utilizando el Internet de las cosas multimedia (Internet of Multimedia Things - IoMT) [76].

Por otro lado, las aplicaciones de uso de sensores inerciales abarcan el estudio de la simetría del movimiento [49], [12], así como para monitorear las actividades humanas, como se describe en [22] y [66]. Cada una de estas

aplicaciones requiere un monitoreo y seguimiento continuo, como se detalla en [13], y en trabajos posteriores [15] y [27], que expanden el concepto al uso de monitoreo en un ambiente de Internet de las Cosas Médicas, y el análisis de redes de sensores corporales inalámbricos, como se describe en el trabajo de Fortino et al. [23].

En la vanguardia de la investigación de sistemas inteligentes de entrenamiento de la marcha y métodos de evaluación, existen tres importantes problemas científico que deben resolverse según la investigación de Han et al. 28:

1. La medición de la marcha y predicción de la intención de movimiento.
2. La construcción de un modelo de evaluación de la capacidad de marcha basado en conocimientos clínicos y datos de movimiento de las extremidades inferiores, y
3. La formulación de una estrategia de entrenamiento de la marcha personalizada mediante el control colaborativo del sistema humano-máquina.

Por lo tanto, comprender y medir la marcha humana para su aplicación clínica y la prevención de futuras enfermedades se convierte en un aspecto esencial en este campo.

2.2. Algoritmos de Inteligencia Artificial

La Inteligencia Artificial (IA) se enfoca en adquirir, analizar y aplicar métodos de expresión del conocimiento para simular actividades intelectuales humanas. Este campo se basa en una amplia variedad de disciplinas, incluyendo informática, lógica, biología, psicología y filosofía, y emplea computadoras para simular comportamientos inteligentes humanos, dotándolas de la capacidad de aprender y tomar decisiones, entre otras habilidades [17, 74].

La IA desempeña un papel crucial en el desarrollo social, transformando la vida cotidiana y convirtiéndose en una estrategia de desarrollo global de gran importancia; además, ha producido avances revolucionarios al mejorar la eficiencia laboral, reducir costos laborales, optimizar la estructura de los recursos humanos y crear nuevas demandas en el mercado laboral [21].

Este desarrollo ha generado un impacto económico significativo y ha contribuido al progreso social. Con condiciones técnicas relativamente maduras, incluyendo datos, algoritmos y capacidades informáticas, la inteligencia artificial ha comenzado a abordar eficazmente problemas y a generar beneficios económicos reales. Desde una perspectiva de aplicaciones, las industrias, las finanzas, la atención médica, la automoción y el comercio, han desarrollado escenarios de aplicación de la inteligencia artificial relativamente maduros [75].

Los avances en inteligencia artificial han impulsado la investigación y desarrollo de diversos algoritmos de aprendizaje automático o machine learning inspirados en el aprendizaje infantil. Estos algoritmos permiten que las computadoras aprendan y analicen datos de forma automática, facilitando la toma de decisiones y la predicción de eventos del mundo real. Uno de los enfoques destacados en el ámbito del aprendizaje automático son las redes neuronales, las cuales han sido objeto de mejoras constantes para superar limitaciones y mejorar la precisión. Como resultado, se han desarrollado algoritmos más avanzados basados en redes neuronales, conocidos como aprendizaje profundo o deep learning.

2.2.1. Aprendizaje automático - Machine Learning

La idea fundamental del aprendizaje automático es utilizar algoritmos para aprender de los datos y resolver problemas. Además, los cuatro problemas más significativos que se abordan a través del aprendizaje automático son: la predicción, la agrupación, la clasificación y la reducción de dimensionalidad. Basándonos en estos problemas, el aprendizaje automático se puede clasificar en tres categorías.

- **Aprendizaje supervisado:** cuando se dispone de datos etiquetados con resultados y se desee predecir los resultados para el futuro. Este tipo de algoritmos son utilizados para predecir y clasificar.
- **Aprendizaje no supervisado:** utiliza algoritmos para analizar conjuntos de datos sin etiquetar y clasificarlos en grupos o clústeres. Identifica patrones ocultos sin intervención humana.
- **Aprendizaje por refuerzo:** Imitan el método de ensayo y error humano para lograr objetivos. Refuerzan las acciones que contribuyen al logro de su objetivo y desatienden las que se desvían. Siguen un patrón de recompensa y castigo al analizar los datos, aprendiendo de los resultados de cada acción para determinar las vías de procesamiento más eficaces.

Un algoritmo de aprendizaje automático se nutre de una colección de características cuantitativamente medidas de un objeto o evento que se busca que el algoritmo aprenda. Normalmente, representamos un ejemplo como un vector, denotado como $x \in \mathbb{R}^n$, en el que cada entrada, x_i , representa una característica distinta. Los distintos modelos de aprendizaje automático se centran principalmente en la resolución de problemas de clasificación y regresión, lo que permite abordar tareas que resultarían complejas de afrontar mediante soluciones desarrolladas por seres humanos. Son varias tareas que puede resolver el aprendizaje automático, entre los más comunes tenemos [26]:

- **Clasificación:** La clasificación es una tarea fundamental en la informática y el aprendizaje automático, en la que un programa informático se encarga de asignar una entrada específica a una de varias categorías posibles. Para lograr esto, se emplea una función que mapea las características de las entradas a códigos numéricos representativos de las distintas categorías. Este proceso es ampliamente utilizado en diversas aplicaciones, siendo el reconocimiento de objetos un ejemplo destacado. En el contexto del reconocimiento de objetos, la tarea implica clasificar una imagen en categorías específicas, lo que permite identificar los objetos presentes en una imagen o incluso reconocer rostros humanos en fotografías.
- **Clasificación con datos incompletos:** La clasificación con entradas incompletos plantea un desafío significativo en el campo del aprendizaje automático cuando no se dispone de todos los valores en un vector de entrada. En lugar de depender de una única función de clasificación, se requiere el desarrollo de múltiples funciones, cada una adaptada a un subconjunto particular de datos faltantes. Esta problemática es particularmente común en aplicaciones médicas costosas o invasivas, donde no es factible obtener todos los datos requeridos para una evaluación exhaustiva.

Una estrategia efectiva para afrontar esta situación implica el aprendizaje de una distribución de probabilidad que abarque todas las variables pertinentes y permita la clasificación, incluso cuando algunas variables falten. Esta aproximación proporciona un conjunto completo de funciones de clasificación sin necesidad de aprender una función separada para cada escenario de datos faltantes. Esto se traduce en una mayor eficiencia y utilidad del aprendizaje automático en una variedad de tareas, y destaca su versatilidad en la resolución de problemas en los que los datos de entrada son incompletos.

- **Regresión:** La regresión, como tipo de tarea en el aprendizaje automático, implica que un programa informático debe realizar predicciones de valores numéricos basándose en un conjunto de datos de entrada. Para resolver este tipo de tarea, se requiere que el algoritmo de aprendizaje genere una función $f : \mathbb{R}^n \rightarrow \mathbb{R}$, donde \mathbb{R} representa los números reales. Si bien la regresión comparte similitudes con la clasificación, la distinción clave radica en que en la regresión, la salida es de naturaleza numérica. La regresión, por lo tanto, se posiciona como una herramienta valiosa en la predicción de valores numéricos en una amplia gama de campos, y ejemplifica la versatilidad del aprendizaje automático en la resolución de problemas complejos de predicción.
- **Transcripción:** En esta categoría de tareas, se encomienda al sistema de aprendizaje automático la labor de observar representaciones de

datos relativamente no estructuradas y transformarlas en una forma textual y discreta. Un ejemplo destacado de esta tarea es el reconocimiento óptico de caracteres, donde imágenes de texto son convertidas en secuencias de caracteres, como en los formatos ASCII o Unicode. Estas aplicaciones ilustran la capacidad del aprendizaje automático para abordar la transcripción de datos no estructurados en formatos textuales, ofreciendo un potencial significativo en campos que van desde el procesamiento de imágenes hasta la conversión de voz en texto.

- **Traducción automática:** En el contexto de una tarea de traducción automática, la entrada se compone de una secuencia de símbolos en un idioma determinado, y se le encomienda al programa de computadora la labor de convertir esta secuencia en una secuencia de símbolos en otro idioma.
- **Salida estructurada:** Las tareas de salida estructurada abarcan aquellas en las que la salida se presenta en forma de un vector u otra estructura de datos con relaciones significativas entre sus elementos. Este tipo de tareas es diverso y engloba no solo la transcripción y la traducción, como mencionado previamente, sino también una variedad de otras actividades. Por ejemplo, el análisis sintáctico implica la conversión de una oración en un idioma natural en un árbol que describe su estructura gramatical, incluyendo la etiquetación de los nodos del árbol con categorías como verbos, sustantivos y adverbios, entre otras.
- **Detección de anomalías:** La detección de anomalías implica que un programa de computadora analiza un conjunto de eventos u objetos y identifica aquellos que son inusuales o atípicos. Un ejemplo relevante de esta tarea es la detección de eventos de la marcha humana para el estudio biomecánico de la caminata. Al modelar los eventos de caminata, se puede comparar patrones de comportamiento para medir, analizar y detectar diferentes alteraciones en la marcha. En consecuencia, estos resultados pueden ser utilizados en diferentes áreas de estudio.
- **Síntesis y muestreo:** En esta categoría de tareas, se requiere que el algoritmo de aprendizaje automático genere nuevos ejemplos que guarden similitud con los datos presentes en el conjunto de entrenamiento. La síntesis y el muestreo mediante el aprendizaje automático resultan particularmente valiosos en aplicaciones relacionadas con la salud humana, donde la generación manual de grandes volúmenes de contenido puede ser costosa o monótona, como por ejemplo, en datos médicos.
- **Imputación de valores faltantes:** En este tipo de tarea, se proporciona al algoritmo de aprendizaje automático un nuevo ejemplo $x \in \mathbb{R}^n$, pero con algunas de las entradas x_i de x faltantes. El algoritmo debe realizar una predicción de los valores de las entradas faltantes.

- **Eliminación de ruido:** En este tipo de tarea, se suministra al algoritmo de aprendizaje automático un ejemplo de entrada que ha sido corrompido, denotado como $\tilde{x} \in \mathbb{R}^n$, y que se ha obtenido a través de un proceso de corrupción desconocido a partir de un ejemplo original no corrompido, representado como $x \in \mathbb{R}^n$. El sistema debe predecir el ejemplo no corrompido x a partir de su versión corrompida \tilde{x} , o, en términos más generales, prever la distribución de probabilidad condicional $p(x|\tilde{x})$.
- **Estimación de densidad o estimación de función de masa de probabilidad:** En el problema de estimación de densidad, se pide al algoritmo de aprendizaje automático que aprenda una función $p_{modelo} : \mathbb{R}^n \rightarrow \mathbb{R}$, donde $p_{modelo}(x)$ puede interpretarse como una función de densidad de probabilidad (si x es continua) o una función de masa de probabilidad (si x es discreta) en el espacio del cual se extrajeron los ejemplos.

La habilidad de los modelos de aprendizaje automático para automatizar el proceso de toma de decisiones a partir de datos cuantitativos los convierte en herramientas poderosas en una amplia gama de campos de estudio y aplicación, entre los más utilizados se detallan a continuación.

2.2.1.1. Árboles de decisión

Se trata de modelos predictivos que clasifican categorías utilizando reglas binarias (Sí/No) asociadas a regiones del espacio de entrada. Los nodos internos dividen esta región en subregiones según cada fila del nodo, como se puede apreciar en la Figura 2.3. Cada nodo del árbol elegido puede ser nodo hijo izquierdo (0) o nodo hijo derecho (1), y se muestra con un identificador de cadena binaria correspondiente a su posición en el árbol. Este identificador se obtiene añadiendo un dígito a su identificador padre (0 para elegir a la izquierda o arriba, 1 para elegir a la derecha o abajo). Las opciones de parámetros incluyen la cantidad máxima de divisiones y el criterio de división (índice de diversidad de Gini, regla de Twoing, reducción máxima de desviación). Es un algoritmo de machine learning muy popular utilizados para tareas de regresión y clasificación.

2.2.1.2. Análisis Discriminante

El análisis discriminante (AD) es una técnica multivariante utilizada para dividir grupos de observaciones basados en variables medidas en cada muestra experimental, y para entender cómo cada parámetro afecta esta división. Además, permite predecir o asignar nuevas observaciones a grupos previamente definidos mediante funciones lineales o cuadráticas. Se basa en una función discriminante, que puede ser única o múltiple dependiendo del




Figura 2.3: Diagrama que describe cómo funciona un arboles de decisión[26].

número de grupos, y utiliza combinaciones lineales de variables predictoras para lograr la mejor discriminación entre los grupos. Una vez construidas estas funciones con una muestra conocida, pueden aplicarse a nuevos casos cuya pertenencia al grupo sea desconocida pero que contengan mediciones de las variables predictoras. Se presupone que diferentes clases generan datos basados en distribuciones Gaussianas. El optimizador tiene dos tipos de modelos: Discriminante Lineal (LDA) y Discriminante Cuadrático (QDA).

2.2.1.3. Bayes Ingenuo (Naive Bayes)

Es un algoritmo que estima la probabilidad de que un objeto pertenezca a cierta clase o grupo, basándose en sus características. Utiliza el teorema de Bayes de la ecuación 2.1 y la densidad de probabilidad de los predictores X dada la clase Y para estimar $P(X|y)$. Este enfoque lo convierte en un clasificador probabilístico, ampliamente utilizado para resolver problemas de clasificación.

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \quad (2.1)$$

donde:

- y y X son eventos (y es la clase) y $P(X) \neq 0$
- Con respecto a conjunto de datos y es una variable de clase y X es un vector de características dependientes (de tamaño n) o también se denomina evidencia.
- $P(y)$ es la probabilidad a priori de la clase.
- $P(X)$ es la probabilidad marginal (la probabilidad de la evidencia).
- $P(y|X)$ es la probabilidad a posteriori de la clase dado el predictor (X , atributos).

- $P(X|y)$ es la probabilidad de verosimilitud, es decir, la probabilidad del predictor dada la clase

En la Figura 2.4 se muestra cómo se utiliza el teorema de Bayes para encontrar la distribución posterior. Este teorema se basa en la probabilidad de verosimilitud $P(X|y)$, que indica la probabilidad de que una hipótesis sea cierta dadas las evidencias, así como en la probabilidad marginal $P(X)$ (la probabilidad de la evidencia) y la probabilidad a priori $P(y)$ del evento antes de observar la evidencia. Es importante destacar que la evidencia se refiere al valor de un atributo de una instancia desconocida, es decir, del evento X .

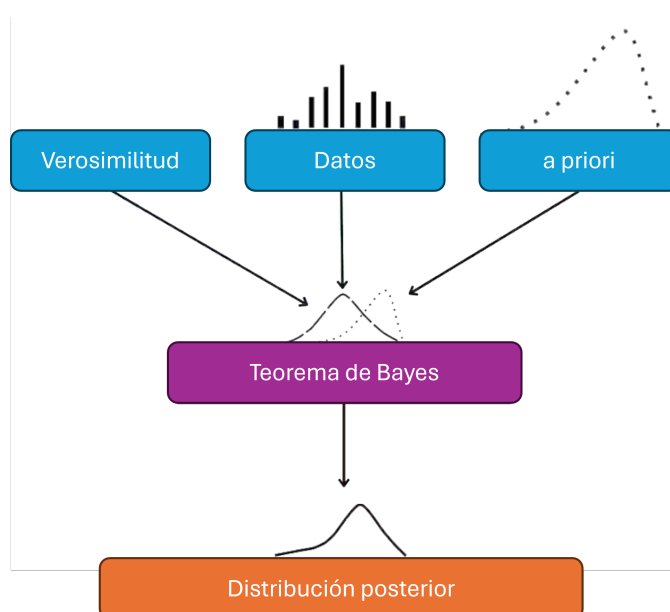


Figura 2.4: Diagrama que describe cómo funciona el algoritmo de Bayes. Imagen extraída de Turing ²

Se tiene cuatro tipos de modelo NB:

1. Naive Bayes Gaussiano: Este algoritmo se utiliza cuando los atributos son continuos y siguen una distribución gaussiana o normal. Aunque acelera significativamente la búsqueda, es importante tener en cuenta que, en condiciones más flexibles, el error puede ser hasta dos veces mayor que el del Naive Bayes Óptimo.
2. Naive Bayes Óptimo: Este algoritmo elige la clase con la mayor probabilidad posterior de acontecimiento, siendo su nombre indicativo de su característica óptima. Sin embargo, este proceso implica revisar todas las posibilidades, lo cual resulta en un proceso lento y que demanda mucho tiempo.

²<https://www.turing.com//>

3. Naive Bayes Bernoulli: Es un método adecuado para conjuntos de datos que contienen atributos binarios o booleanos, en los que los atributos pueden tomar valores de sí o no, útil o no, concedido o rechazado.
4. Naive Bayes Multinomial: Se aplica en la clasificación de documentos, donde las características requeridas son la frecuencia de las palabras obtenidas del texto del documento.

2.2.1.4. Máquina de Soporte Vectorial

Las Máquinas de Vectores de Soporte (SVM, por sus siglas en inglés) son un poderoso algoritmo supervisado que se destaca en la clasificación de conjuntos de datos pequeños pero complejos. Este algoritmo encuentra el hiperplano óptimo que separa las clases y clasifica los datos en función de su ubicación respecto a este hiperplano. SVM puede utilizar diferentes funciones de núcleo, como lineal, gaussiano, cuadrático y cúbico, y también cuenta con un parámetro de restricción de caja que controla la penalización máxima impuesta a las observaciones que violan el margen.

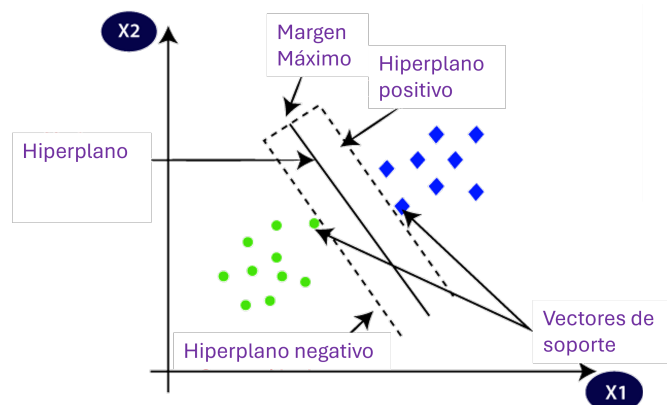


Figura 2.5: Funcionamiento del algoritmo SVM. Imagen extraída de Analytics Vidhya ³

La Figura 2.5 muestra las partes importantes del algoritmo SVM. Los Vectores de Soporte son los puntos más cercanos al hiperplano, del cual surgen las líneas separadoras definidas como hiperplanos positivo y negativo. El margen es la distancia entre los hiperplanos y los vectores de soporte. En SVM, un margen grande se considera óptimo, existiendo dos tipos de márgenes: el margen duro y el margen suave.

En SVM, se define en términos de los vectores de soporte, sin preocuparnos por otras observaciones como en otros algoritmos donde el clasificador se

³<https://www.analyticsvidhya.com//>

define en todos los puntos. En este método, el margen se construye utilizando los puntos que están más cerca del hiperplano (vectores de soporte).

Para entender el funcionamiento, supongamos que tenemos un conjunto de datos que tiene dos clases para clasificar (verde y azul como se puede apreciar en la Figura 2.5). Para clasificar estos puntos, podemos tener muchas fronteras de decisión clasificadas por una línea. Se debe tener en cuenta que si trazamos los puntos de datos en un gráfico bidimensional, llamamos a esta frontera de decisión una "línea recta", pero si tenemos más dimensiones, la llamamos un "hiperplano".

El propósito fundamental del algoritmo SVM es identificar el hiperplano óptimo, que es aquel que maximiza la distancia entre ambas clases. Para lograr esto, el algoritmo busca entre diferentes hiperplanos que clasifiquen las etiquetas de manera eficaz, seleccionando finalmente aquel que se encuentre más alejado de los puntos de datos o que disponga del margen máximo disponible.

2.2.1.5. k-Vecinos más cercanos

K-Vecinos más Cercanos (KNN, por sus siglas en inglés) es un modelo de clasificación que agrupa datos según su distancia. En lugar de aproximar globalmente la función objetivo $f(x) = y$, durante cada predicción, KNN aproxima la función objetivo localmente. Para hacer una predicción (etiqueta de clase u objetivo continuo), el algoritmo KNN encuentra los k vecinos más cercanos a un punto de consulta y calcula la etiqueta de clase (en clasificación) o el objetivo continuo (en regresión) basándose en los k puntos más similares.

K representa el número de vecinos más próximos que deben tenerse en cuenta al realizar la predicción y los k puntos de datos con las menores distancias al punto objetivo son los vecinos más próximos.

En el subpanel izquierdo de la Figura 2.6, los ejemplos de entrenamiento se representan como puntos negros, mientras que un punto de consulta que se desea clasificar se muestra como un signo de interrogación. En el subpanel derecho de la Figura 2.6, las etiquetas de las clases y la línea punteada indican el punto más cercano a la consulta, según una métrica de distancia euclidiana. La métrica de distancia más utilizadas son:

- Distancia Euclideana
- Distancia Manhattan
- Distancia Minkowski

En el problema de clasificación, se determinan las etiquetas de clase a través de un proceso de votación mayoritaria, donde la clase que aparece con mayor frecuencia entre los vecinos se asigna como la clase predicha para el

punto de datos objetivo. En el problema de regresión, se calcula la etiqueta de clase tomando el promedio de los valores objetivo de los K vecinos más cercanos. Este promedio se utiliza como la salida predicha para el punto de datos objetivo.




Figura 2.6: Ilustración del algoritmo de clasificación del vecino más cercanos de dos características x_1 y x_2 [50]

2.2.1.6. Neural Network

Inspirados en la forma en que las neuronas se conectan en el cerebro humano, tienen la intención de simular las activaciones para clasificar muestras. La neurona biológica comúnmente se representa mediante un modelo matemático conocido como Perceptrón o neurona artificial, el cual se ilustra en la Figura 2.7. Cada neurona recibe señales de entrada procedentes de la capa superior, realiza el cálculo de la suma ponderada de dichas entradas y genera salidas destinadas a la capa siguiente a través de una función de activación. Se puede expresar con el siguiente modelo.

$$Y_j = \sum_{i=1}^n w_{ji}x_i + b_j \quad (2.2)$$

Donde $X = [x_1, x_2, \dots, x_n]$ es un conjunto de entradas de j th neuronas,




Figura 2.7: Representación de una red biológica en una neurona artificial[70].

$W_j = [w_{j1}, w_{j2}, \dots, w_{jn}]$ es el vector peso, b_j es el bias, y Y_j es la suma ponderada de entradas.

Las cantidades Y_j se denominan activaciones. Cada una de ellas se transforma mediante una función de activación diferenciable y no lineal $\varphi(\bullet)$ para obtener la salida

$$z_j = \varphi(Y_j) \quad (2.3)$$

Estas cantidades corresponden a las salidas de las funciones de base en ecuación 2.2, que, en el contexto de las redes neuronales, se llaman unidades ocultas (hidden units). Las funciones de activación no lineales $\varphi(\bullet)$ suelen ser funciones como: *sigmoide*, *tanh*, *ReLU* y *softmax*.

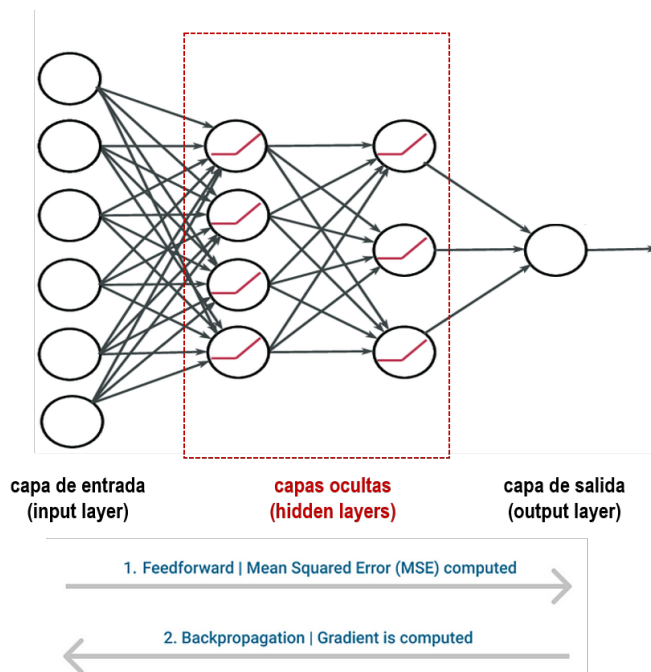


Figura 2.8: Perceptrón multicapa[10]

El perceptrón se concibe como el modelo de una única neurona y, en consecuencia, tiene limitaciones cuando se trata de abordar datos no lineales. Para superar esta restricción, se desarrolló el perceptrón multicapa o MLP, que consta de capas de entrada y salida, así como una o más capas ocultas que alojan múltiples neuronas interconectadas. Mientras que en el perceptrón tradicional se utiliza una función de activación que impone un umbral, como la función *ReLU* o la *sigmoide*, las neuronas en un perceptrón multicapa tienen la flexibilidad de emplear cualquier función de activación arbitraria.

En la Figura 2.8 se muestra la configuración de una red neuronal multicapa, también conocida como perceptrón multicapa. A modo de ejemplo, la

red de la Figura 2.8 consta de una capa de entrada con 6 nodos de entrada, seguida de una primera capa oculta con 4 nodos ocultos (4 perceptrones), luego una segunda capa oculta con 3 nodos ocultos (3 perceptrones) y, finalmente, una capa de salida con 1 nodo de salida.

El perceptrón multicapa, clasificado como un algoritmo de avance (feed-forward) ver Figura 2.8, se caracteriza por la propagación de las combinaciones lineales a través de las capas. Cada capa alimenta a la siguiente con sus resultados, incluyendo las capas ocultas, y culmina en la capa de salida. No obstante, para lograr un aprendizaje efectivo, es esencial que el algoritmo vaya más allá de simplemente calcular sumas ponderadas y propagar los resultados, ya que de lo contrario no sería capaz de aprender los pesos que minimizan la función de costos (MSE), ver ecuación 2.4. En este proceso, la retropropagación desempeña un papel crucial. La retropropagación, o *backpropagation* en inglés, es el mecanismo de aprendizaje que permite al perceptrón multicapa ajustar de forma iterativa los pesos en la red con el fin de minimizar la función de costo. Para que la retropropagación funcione correctamente, es esencial que las funciones utilizadas en las neuronas, como la suma ponderada y la función umbral (por ejemplo, ReLU), sean diferenciables y tengan derivadas acotadas, ya que el Descenso de Gradiente suele ser el método de optimización empleado en el Perceptrón Multicapa.

En cada iteración, después de que las sumas ponderadas se propaguen a través de todas las capas, se procede a calcular el gradiente del Error Cuadrático Medio (MSE), también conocido como función de costo o pérdida indicada en la ecuación 2.4, para todos los pares de entrada y salida. Esto nos permite evaluar qué tan bien se están prediciendo los valores objetivos.

$$Cost(J) = \frac{1}{2}(\hat{Y} - Y)^2 \quad (2.4)$$

donde, \hat{Y} es el valor estimado y Y es el valor real.

Luego, para retropropagar este gradiente, se actualizan los pesos de la primera capa oculta con su valor, permitiendo que los pesos se propaguen de vuelta al inicio de la red neuronal. Este proceso continúa hasta que el gradiente para cada par de entrada y salida haya convergido, lo que implica que el gradiente recién calculado no ha cambiado más allá de un umbral de convergencia especificado en comparación con la iteración anterior. La ecuación de la retropropagación esta definida de la siguiente manera:

$$\Delta_{w(t)} = -\alpha \frac{dJ}{dw(t)} + \Delta_{w(t-1)} \quad (2.5)$$

donde, $\Delta_w(t)$ es la iteración actual de gradiente, J es el costo, $dw(t)$ es el vector peso, α es la tasa de aprendizaje y, $\Delta_{w(t-1)}$ es la iteración anterior de gradiente.

2.2.2. Aprendizaje profundo - Deep Learning

El Aprendizaje Profundo, del inglés *Deep Learning* (DL) es una subdisciplina de Aprendizaje Automático (ML) que se fundamenta en redes neuronales (NN) que están siendo muy utilizadas en la actualidad. Desde sus inicios, DL ha provocado disrupciones cada vez más significativas, demostrando un éxito sobresaliente en casi todos los dominios de aplicaciones.

Cuando el volumen de datos se incrementa, las técnicas de ML, por más optimizadas que estén, tienden a volverse ineficientes en cuanto a su rendimiento y precisión, en contraste, el aprendizaje profundo demuestra un desempeño notablemente superior en tales situaciones. Además, en ML, las características o features se proporcionan manualmente, mientras que el aprendizaje profundo aprende características directamente de los datos. Es posible clasificar las redes neuronales de acuerdo con la arquitectura, como se detalla en la Figura 2.9.

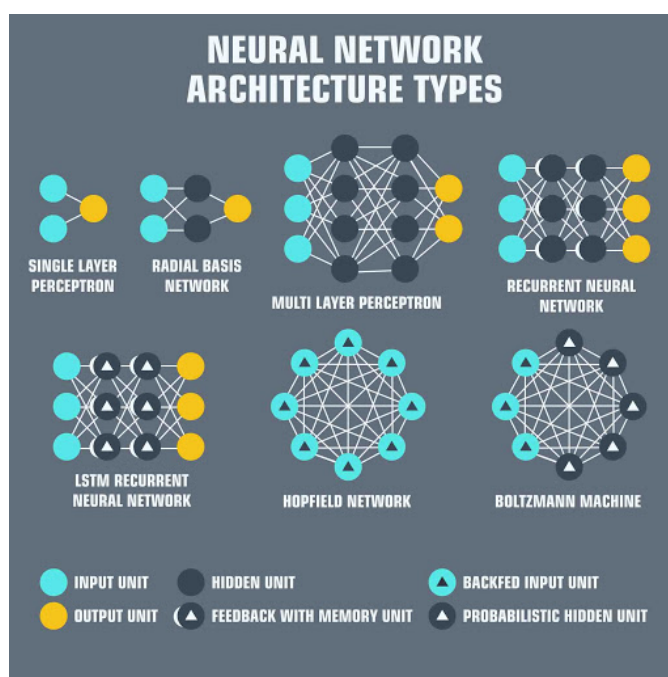


Figura 2.9: Tipo de arquitectura de las Redes Neuronales. Imagen extraída de aalerin ⁴

Los algoritmos de aprendizaje profundo más comunes detallados por [4] se describen a continuación.

⁴<https://www.aalerin.com/>

2.2.2.1. Red Neuronal Recurrente - Recurrent Neural Networks

La red neuronal recurrente (RNN) se caracteriza por realimentar su propia entrada para mejorar la predicción resultante, y su diseño se centra en la retención de la salida de una capa anterior. En general, comienza con una capa de retroalimentación, seguida de una capa de red neuronal recurrente, donde una función de memoria conserva parte de la información previamente procesada en pasos de tiempo anteriores como se puede apreciar en la Figura 2.10. En este contexto, se lleva a cabo una propagación hacia adelante con el propósito de almacenar datos relevantes para usos futuros. En caso de predicciones incorrectas, se recurre a la tasa de aprendizaje para realizar ajustes menores y, de esta manera, mejorar progresivamente la precisión durante el proceso de retropropagación [4].

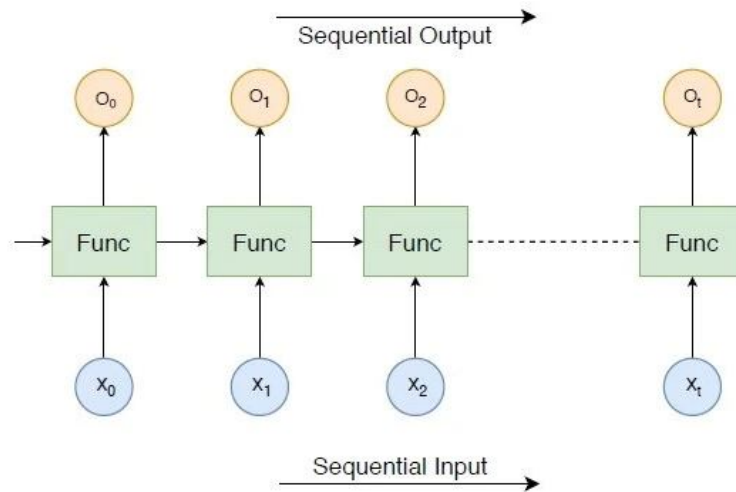


Figura 2.10: Red Neuronal Recurrente o conocido en inglés Recurrent Neural Networks - RNN . Imagen extraída de viso ⁵

Una de las ventajas de las redes neuronales recurrentes es su capacidad para modelar datos secuenciales, donde se presume que cada muestra depende de las muestras anteriores. En ocasiones, se utilizan junto con capas de convolución para mejorar la eficacia en el procesamiento de imágenes, especialmente en el análisis de píxeles. Sin embargo, las redes neuronales recurrentes presentan desafíos, como los problemas de explosión y desvanecimiento de gradientes, lo que puede hacer que el entrenamiento sea una tarea compleja. Además, resulta complicado procesar secuencias de datos largas cuando se emplea la función de activación ReLU.

Este tipo de redes neuronales se emplea ampliamente en una variedad de aplicaciones, incluyendo el procesamiento de texto para tareas como sugerir

⁵<https://www.viso.ai/>

cias automáticas, corrección gramatical, conversión de texto a voz, etiquetado de imágenes, análisis de sentimientos y traducción.

2.2.2.2. Redes LSTM (Memoria a Largo y Corto Plazo - Long Short-Term Memory)

Las redes LSTM constituyen una variante de las RNN, que incorpora unidades especiales además de las unidades convencionales. Las unidades LSTM se destacan por su capacidad para mantener información en una “celda de memoria” durante largos intervalos de tiempo. Esto se logra mediante un conjunto de puertas que controlan el flujo de información hacia la memoria, su liberación y su eliminación. Estas puertas se dividen en tres categorías: la puerta de entrada, que determina cuánta información de la muestra previa se retiene en la memoria; la puerta de salida, que regula la cantidad de datos transmitidos a la siguiente capa; y las puertas de olvido, que gestionan la tasa de eliminación de la información almacenada. Gracias a esta arquitectura, las redes LSTM son capaces de aprender dependencias a largo plazo [4].

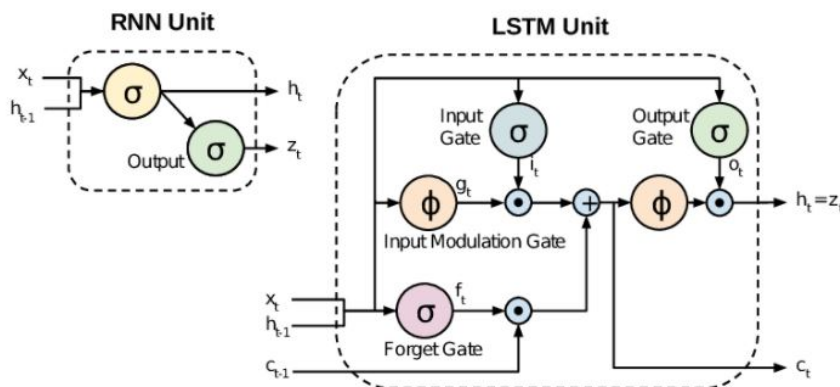


Figura 2.11: Redes LSTM (Memoria a Largo y Corto Plazo o su siglas en inglés que corresponden Long Short-Term Memory). Imagen extraída de mygreatlearning ⁶

2.2.2.3. Red Neuronal Convolutiva - Convolutional Neural Network

La Red Neuronal Convolutiva (CNN) presenta una disposición tridimensional de neuronas en lugar del convencional arreglo bidimensional. Su primera capa, denominada capa de convolución, procesa exclusivamente información de porciones reducidas del campo visual. Las características de

⁶<https://www.mygreatlearning.com/>

entrada se agrupan en lotes, similar a un filtro, y la red comprende las imágenes en fragmentos, ejecutando estas operaciones de manera iterativa hasta completar el procesamiento de la imagen completa [4]. Esta transformación implica la conversión de la imagen desde una escala de color RGB o HSI a escala de grises, lo que facilita la detección de bordes y permite la clasificación de las imágenes en diversas categorías.




Figura 2.12: Concepto de una red neuronal convolucional. Imagen extraída de viso ⁷

La propagación puede ser unidireccional, donde la CNN consta de una o más capas de convolución seguidas de capas de agrupación, o bidireccional, donde la salida de la capa de convolución se dirige hacia una red neuronal completamente conectada que clasifica las imágenes, tal como se ilustra en la Figura 2.12. En este proceso, se utilizan filtros para extraer características específicas de la imagen. En el caso de MLP, las entradas se ponderan y se envían a una función de activación. Mientras que la convolución emplea la función ReLU, MLP hace uso de una función de activación no lineal, seguida de softmax. Las redes neuronales convolucionales han demostrado su eficacia en el reconocimiento de imágenes y videos, el análisis semántico y la detección de paráfrasis.

La CNN se utiliza con frecuencia en el aprendizaje profundo debido a su capacidad para lograr un alto rendimiento con menos parámetros en comparación con las MLP. Sin embargo, su diseño y mantenimiento pueden resultar comparativamente más complejos, y su velocidad de entrenamiento puede ser más lenta, especialmente en función del número de capas ocultas.

2.2.2.4. Modelos de secuencia a secuencia - Sequence to sequence models

Un modelo secuencia a secuencia comprende dos Redes Neuronales Recurrentes. En este contexto, se incluye un proceso de codificación para la

⁷<https://www.viso.ai/>

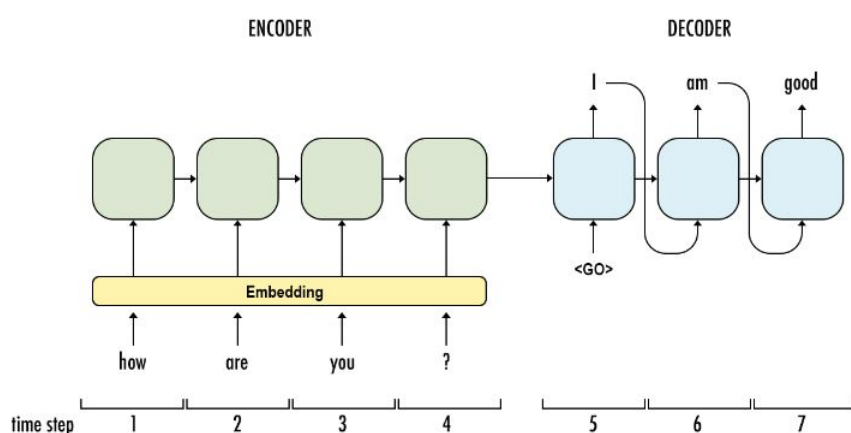


Figura 2.13: Modelos de secuencia a secuencia o en inglés Sequence to sequence models. Imagen extraída de mygreatlearning ⁸

entrada y un proceso de decodificación para la salida. Estos procesos de codificación y decodificación operan en paralelo, ya sea compartiendo los mismos parámetros o empleando conjuntos diferentes. A diferencia de las RNN convencionales, este modelo demuestra su eficacia especialmente en situaciones en las que la longitud de los datos de entrada es igual a la longitud de los datos de salida. A pesar de compartir similitudes en términos de ventajas y limitaciones con las RNN, estos modelos se aplican con mayor frecuencia en aplicaciones como chatbots, traducción automática y sistemas de respuesta a preguntas.

2.3. Evaluación del rendimiento.

Dado que existen numerosos algoritmos y enfoques diseñados para abordar un problema específico, se requiere un mecanismo de evaluación que permita compararlos de manera objetiva y determinar cuál es más efectivo que otro. Esta evaluación se basa en la comparación entre el rendimiento ideal y el rendimiento real de un algoritmo, y se logra mediante la utilización de medidas cuantitativas de desempeño y conjuntos de datos de prueba diversos. Estos recursos permiten valorar de manera objetiva los resultados obtenidos por cada algoritmo y determinar cuál es el más adecuado para resolver el problema en cuestión.

2.3.1. Medidas de rendimiento

Las métricas de rendimiento son esenciales en el aprendizaje automático, permiten evaluar el progreso y cuantificar el rendimiento de los modelos.

⁸<https://www.mygreatlearning.com/>

Cada tarea se puede clasificar en regresión o clasificación, y existen múltiples métricas para cada tipo. Su comprensión es crucial para evaluar de manera efectiva los modelos de aprendizaje automático.

2.3.1.1. Métricas de regresión

Los modelos de regresión generan una salida continua, lo que implica la necesidad de utilizar métricas que evalúen la discrepancia entre las predicciones y los valores reales. A continuación, se presentarán las métricas más utilizadas en el desarrollo de la tesis:

- **Error Cuadrático Medio - Mean Squared Error (MSE):** Es una métrica fundamental en la evaluación de modelos de regresión. Su función es medir la magnitud de las desviaciones entre las predicciones del modelo y los valores reales. Un valor más bajo de MSE indica un ajuste más preciso del modelo a los datos, lo que significa que las predicciones del modelo se acercan más a los valores reales.

$$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2 \quad (2.6)$$

donde: y_j es el valor verdadero, \hat{y}_j es el valor predicho y, N es el número de datos.

- **R^2 (R-Cuadrado):** El coeficiente de determinación R^2 indica la proporción de la varianza en la variable dependiente que es predecible a partir de la variable independiente(s), valores más altos de R^2 indican un mejor ajuste del modelo; es decir, un valor de R^2 más cercano a 1 indica un mejor ajuste del modelo a los datos.

Su importancia radica en proporcionar una medida intuitiva de cuán bien el modelo captura la estructura subyacente de los datos. R^2 es útil para comparar modelos en el mismo conjunto de datos y determinar cuál explica mejor la variación en la variable objetivo.

$$R^2 = 1 - \frac{MSE_{res}}{MSE_{tot}} \quad (2.7)$$

$$MSE_{res} = \sum_{j=1}^N (y_j - \hat{y}_j)^2 \quad MSE_{tot} = \sum_{j=1}^N (y_j - \bar{y}_j)^2 \quad (2.8)$$

donde: MSE_{res} es la suma de los cuadrados de las diferencias entre los valores observados y los valores predichos por el modelo, MSE_{tot} es la suma total de los cuadrados, que representa la suma de los cuadrados de las diferencias entre los valores observados y la media de los valores observados, \hat{y}_j es el valor predicho, \bar{y} es la media y, N es el número de datos.

2.3.1.2. Métricas de clasificación

Los problemas de clasificación son ampliamente estudiados y tienen aplicaciones en diversos sectores industriales. Estos modelos generan resultados discretos, lo que requiere métricas específicas para evaluar su desempeño. Las métricas de clasificación proporcionan una evaluación de cuán efectiva es la clasificación de un modelo, y existen varias métricas que evalúan el rendimiento de manera diferente. A continuación, se analizarán las siguientes métricas para evaluar modelos de clasificación.

- **Matriz de confusión - Confusion Matrix:** La Matriz de Confusión es una representación en forma de tabla que compara las etiquetas reales con las predicciones del modelo. Cada fila de esta matriz representa las instancias que el modelo predijo como pertenecientes a una determinada clase, mientras que cada columna representa las instancias reales de esa clase. Es importante destacar que la Matriz de Confusión no es en sí misma una métrica de rendimiento, pero proporciona una base fundamental sobre la cual otras métricas evalúan los resultados.



Figura 2.14: Representación de la matriz de confusión y sus detalles. Imagen extraída de [impulsatek](https://www.impulsatek.com/) ⁹

Cada celda de la matriz de confusión (Ver Figura 2.14) representa un factor de evaluación con sus respectivos conceptos:

- *Verdadero Positivo (TP)* significa cuántas muestras de la clase positiva tu modelo predijo correctamente.
- *Verdadero Negativo (TN)* significa cuántas muestras de la clase negativa tu modelo predijo correctamente.
- *Falso Positivo (FP)* significa cuántas muestras de la clase negativa tu modelo predijo incorrectamente. Este factor representa el error de Tipo I en la nomenclatura estadística. La posición de este error

⁹<https://www.impulsatek.com/>

en la matriz de confusión depende de la elección de la hipótesis nula.

- *Falso Negativo (FN)* significa cuántas muestras de la clase positiva tu modelo predijo incorrectamente. Este factor representa el error de Tipo II en la nomenclatura estadística. La posición de este error en la matriz de confusión también depende de la elección de la hipótesis nula.
- **Precisión (P):** La precisión es la proporción de verdaderos positivos y positivos totales predichos:

$$P = \frac{TP}{TP + FP} \quad (2.9)$$

- **Recall/Sensibilidad/Hit-Rate:** El Recall es, en esencia, la proporción de verdaderos positivos entre todos los positivos en la verdad terrenal. La sensibilidad también se lo conoce como Tasa de verdaderos positivos (TPR) y representa la probabilidad de obtener un resultado positivo en la prueba cuando el individuo es verdaderamente positivo.

$$R = \frac{TP}{TP + FN} \quad (2.10)$$

- **Especificidad/selectividad:** Es la tasa negativa verdadera y refleja la probabilidad de obtener un resultado negativo en la prueba cuando el individuo es verdaderamente negativo.

$$TNR = \frac{TN}{TN + FP} \quad (2.11)$$

- **F1-score:** La métrica F1-score utiliza una combinación de precisión y recall para mostrar la capacidad del modelo de equilibrar ambos aspectos en la clasificación de las clases positivas y negativas. En efecto, el puntaje F1 es la media armónica de ambas métricas. Un valor alto de F1-score indica un buen equilibrio entre precisión y recall.

$$F1 = \frac{2}{\frac{1}{P} + \frac{1}{R}} \quad (2.12)$$

2.4. Señales

Uno de los elementos fundamentales en la comprensión de estos conceptos relacionados con las señales consiste en el reconocimiento de los diversos tipos de señales que se encuentran en la teoría y en la práctica. A continuación, se

proporciona una explicación concisa de los conceptos asociados a las señales digitales, analógicas, señales de tiempo continuo y señales discretas.

- Señales de tiempo continuo: Las señales de tiempo continuo se caracterizan por tener un dominio definido en el conjunto de números reales, lo que implica que están especificadas para cada valor real de tiempo t . Esto significa que la amplitud de la señal varía de manera continua a lo largo del tiempo. Es relevante destacar que esta definición del dominio en el tiempo continuo se diferencia de la definición de señales de tiempo discreto, donde el dominio se establece en términos de números enteros. En este caso, la amplitud de la señal solo experimenta cambios en intervalos discretos de tiempo.
- Señales de tiempo discreto: Las señales de tiempo discreto se caracterizan por definir su dominio solamente en valores específicos y finitos de tiempo. En este contexto, la amplitud de la señal experimenta cambios en intervalos distintos de tiempo, a diferencia de las señales de tiempo continuo, en las que la amplitud varía de manera ininterrumpida a lo largo del tiempo.

Esta definición del dominio de tiempo discreto habilita la capacidad de trabajar con señales digitales en sistemas relacionados con la comunicación y el procesamiento de señales, ofreciendo aplicaciones prácticas significativas. Una técnica comúnmente empleada en este contexto es el muestreo de señales analógicas en intervalos regulares, lo que da lugar a muestras discretas de la señal que se pueden representar como señales de tiempo discreto. Este procedimiento es frecuente en el procesamiento de señales y en la transmisión de datos digitales, donde las señales analógicas requieren ser transformadas en señales digitales antes de ser procesadas o transmitidas.

- Señales analógicas: Las señales analógicas se caracterizan por su amplitud variable que puede tomar valores infinitos dentro de un intervalo de tiempo específico. Esto implica que la amplitud de una señal analógica varía de manera continua a lo largo del tiempo, lo que la capacita para representar con precisión una amplia gama de información, incluyendo voz, música e imágenes, entre otros. En sistemas de comunicación y procesamiento de señales, se emplean comúnmente señales analógicas en circuitos electrónicos que manipulan y transmiten señales de audio, video, radio y otras de baja frecuencia.

A menudo, la representación gráfica de una señal analógica se asemeja a una señal de tiempo continuo debido a similitudes visuales entre ambas. La distinción clave radica en que las señales de tiempo continuo hacen referencia al intervalo temporal, mientras que las señales analógicas se refieren al rango de amplitud.

No obstante, ambas modalidades permiten una representación precisa de una variedad de información, independientemente de si se trata de voz, música o imágenes. Por lo tanto, aunque existe una sutil diferencia entre señales de tiempo continuo y señales analógicas, la apariencia visual similar puede generar confusiones en algunos casos.

- Señales digitales: Las señales digitales son aquellas cuya amplitud se restringe a valores específicos en intervalos discretos de tiempo, a diferencia de las señales analógicas que experimentan una variación continua. Estos valores discretos se representan comúnmente en forma de números binarios, lo que simplifica su procesamiento y transmisión en comparación con las señales analógicas.

Las aplicaciones de las señales digitales abarcan una amplia variedad de campos, desde la transmisión de datos y las comunicaciones en redes hasta dispositivos de consumo cotidiano como la televisión digital y los teléfonos móviles. Además, se emplean en aplicaciones prácticas como la modulación por amplitud de pulso (PAM).

Es importante destacar que en situaciones del mundo real, las señales pueden depender no solo del tiempo, sino también del espacio o de variables eléctricas. Las señales de tiempo continuo y de tiempo discreto establecen la naturaleza de la señal a lo largo del tiempo, mientras que las señales analógicas y digitales se refieren a la naturaleza de la amplitud de la señal.

2.4.1. Análisis de frecuencia

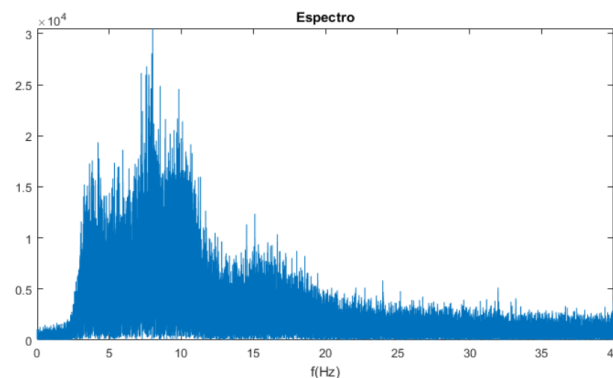


Figura 2.15: Ejemplo de un espectro de la señal de Electrocardiograma-EEG. Imagen extraída de microlab ¹⁰

¹⁰<https://www.microlab.ec/>

El análisis en el dominio de la frecuencia es una herramienta fundamental para descomponer una señal en sus componentes frecuenciales y determina la energía asociada a cada rango de frecuencias. Este análisis se lleva a cabo mediante la “Transformada de Fourier”, una operación matemática esencial que convierte una señal de su representación en el dominio en el tiempo a su representación en el dominio de la frecuencia.

La Transformada de Fourier permite realizar el análisis espectral, una metodología que descompone las señales en componentes sinusoidales con frecuencias y amplitudes específicas. Esto facilita la comprensión de la información en el dominio de la frecuencia y permite revelar la contribución de cada componente de frecuencia en una señal. Como resultado de este análisis de Fourier, se obtiene un espectro de amplitud con unidades idénticas a las de la señal original en el dominio del tiempo (ver Figura 2.15).

En el contexto de este estudio, en el cual se emplearán señales digitales caracterizadas por su naturaleza discreta, se hace imperativo recurrir a la Transformada de Fourier Discreta (DFT, por sus siglas en inglés). La DFT es una herramienta esencial en la análisis y procesamiento de señales digitales, permitiendo descomponer una señal discreta en sus componentes de frecuencia y, de este modo, facilitando una comprensión más profunda de su contenido espectral. Su aplicación resulta fundamental para el logro de los objetivos de este trabajo en el ámbito de las señales digitales.

La Transformada Rápida de Fourier (FFT, por sus siglas en inglés) es una forma de implementar de manera computacionalmente rápida y eficiente la Transformada de Fourier Discreta (DFT) [56][32][1]. Esta transformación lineal permite extraer el contenido de frecuencia de una señal discreta. Su formulación se encuentra en la ecuación (2.13):

$$X(k) = \sum_{n=0}^{N-1} x_n \exp \left[-i2\pi \frac{nk}{N} \right] \quad (2.13)$$

donde: $X(k) = FFT(x)$, x_n es el n -th elemento de entrada de la señal, y N es la longitud a transformar o la longitud de la FFT .

Con el propósito de mejorar la eficiencia de la FFT, el algoritmo Cooley/-Tukey es muy utilizado. Investigaciones previas se enfocaron en la reducción del número de operaciones aritméticas, y el algoritmo mencionado logra disminuir la complejidad computacional de $O(N^2)$ a $O(N \log N)$ [32]. Esto se debe a que una estrategia fundamental en la construcción de algoritmos es la explotación de las simetrías inherentes a un problema.

En consecuencia, Cooley y Tukey divide el cálculo de la DFT en subproblemas más pequeños, aprovechando eficazmente estas simetrías, tal como se representa en la ecuación (2.13).

$$\begin{aligned}
X(k) &= \sum_{m=0}^{N/2-1} x_{2m} \cdot e^{-i2\pi k(2m)/N} \\
&+ \sum_{m=0}^{N/2-1} x_{2m+1} + 1 \cdot e^{-i2\pi k(2m+1)/N}
\end{aligned} \tag{2.14}$$

$$\begin{aligned}
&= \sum_{m=0}^{N/2-1} x_{2m} \cdot e^{-i2\pi km/(N/2)} + e^{-i2\pi k/N} \\
&+ \sum_{m=0}^{N/2-1} x_{2m+1} + 1 \cdot e^{-i2\pi km/(N/2)}
\end{aligned} \tag{2.15}$$

La ecuación 2.13 se descompone en una Transformada de Fourier Discreta más pequeña de dos términos, que se denota en la ecuación 2.15, representando una de longitud $N/2$, una en los valores con números impares y otra en los valores con números pares. Además, es factible descomponer una DFT de N puntos en dos DFT de $N/2$ puntos, seguidos por N multiplicaciones en la ecuación 2.15. Por ejemplo, si $N/2$ es múltiplo de 2, cada una de las dos DFT de $N/2$ puntos en la ecuación 2.15 puede descomponerse aún más en dos DFT de longitud $N/4$. La literatura explica que si N es una potencia de 2, estas descomposiciones pueden repetirse $\log_2 N$ veces hasta que nos queden DFT de dos puntos de $N/2$.

Este enfoque del algoritmo de descomponer una DFT grande en DFT más pequeñas tiene como objetivo acelerar el cálculo y reducir la complejidad computacional.

2.5. Conjunto de datos

Tras presentar las métricas de evaluación de métodos y su comparativa, se presenta un conjunto de datos de prueba utilizado como referencia. En el contexto de la marcha humana, se dispone de diversas y amplias fuentes de información disponibles para el público. A continuación, se describirá la base de datos utilizada en este trabajo.

2.5.1. Base de datos de la marcha humana - HuGaDB

Esta base de datos constituye una recopilación de información sobre la marcha humana [16], diseñada para su análisis y la identificación de actividades. Incluye grabaciones continuas de diversas actividades como caminar, correr, subir y bajar escaleras, sentarse en silla, sentarse en el piso, levantarse de una silla, y de una superficie, manejar una bicicleta, bajar y subir en

ascensor y sentarse en un auto. Los datos obtenidos han sido segmentados y anotados meticulosamente.

La recopilación de datos se efectuó a través de una red de sensores corporales que consta de seis sensores inerciales portátiles, que incorporan acelerómetros y giroscopios, situados en los muslos, espinillas y pies tanto derechos como izquierdos. Además, se emplearon dos sensores de electromiografía en los cuádriceps (la parte frontal de los muslos) para medir la actividad muscular.

Esta base de datos no solamente se utiliza para reconocer actividades, sino también para investigar la ejecución de dichas actividades y la relación de movimiento entre las distintas partes de las piernas. Por consiguiente, el autor sugiere que estos datos pueden aprovecharse para diversos propósitos, como:

- Para realizar estudios en el ámbito de la atención médica, como la rehabilitación de la marcha o la identificación de la enfermedad de Parkinson.
- Para aplicaciones de realidad virtual y videojuegos para simular el movimiento humanoide.
- En la robótica humanoides para modelar la marcha humana.

Este conjunto de datos es pionero en su género, al proporcionar información detallada sobre la marcha humana, y se encuentra disponible gratuitamente.

Se recolectaron datos de 18 pacientes sanos durante un período total de 10 horas. Para llevar a cabo esta tarea, se emplearon sensores inerciales del tipo MPU9250, junto con sensores EMG cuyas lecturas se canalizaron a través de un conversor ADC con una resolución de 8 bits y un rango de voltaje de 0 a 5 voltios. El microcontrolador utilizado logró adquirir un promedio de 56.35 muestras por segundo, presentando una desviación estándar de 3.2057. Los datos recopilados se transmitieron vía Bluetooth.

En la Figura 2.16 de esta tesis se puede observar la disposición de los sensores inerciales, los cuales recopilaron un total de 2,111,962 muestras a lo largo del proceso de recolección de datos.

2.6. Estado del arte

En esta sección, nos hemos centrado en una revisión exhaustiva de los estudios sobre la marcha humana que emplean la tecnología WS como herramienta de adquisición de datos, así como en las investigaciones sobre algoritmos inteligentes utilizados para abordar problemas de reconocimiento y análisis de la marcha humana.




Figura 2.16: Instalación de sensores en la extremidad inferior del cuerpo en el siguiente orden[16]: pie derecho (RF), caña derecha (RS), muslo derecho (RT), pié izquierdo (LT), caña izquierdo (LS), y muslo izquierdo (LT)

2.6.1. Métodos usados para reconocer actividades humanas

Los investigadores han aprovechado el potencial de la tecnología WS para descubrir métodos más eficientes para analizar la marcha humana, mejorar la comodidad general y extraer diversas características destinadas al entrenamiento de modelos de inteligencia artificial. Este estudio se adentra en la utilización de sensores IMU ubicados en diversas partes del cuerpo humano. Además, se investigan minuciosamente diversos aspectos cruciales para su comparación, como el número de participantes, tipos de características, variedad de actividades, ubicación de los sensores y la amplia variedad de tipos de clasificadores empleados. El objetivo principal radica en optimizar la extracción de características con el fin de mejorar la eficiencia computacional y la precisión de los clasificadores.

En [73], se propuso investigar las características de la transformada de Hilbert-Huang (HHT) para extraer múltiples características con el fin de mejorar la detección de actividades, incluyendo la amplitud e instantáneas de frecuencia mediante la introducción de una descomposición modal empírica (EMD), así como la densidad de energía instantánea (IE) y el espectro marginal (MS) derivados del análisis espectral de Hilbert. Este estudio involucró un conjunto de datos PAPAP2 en el que se llevaron a cabo 12 actividades. Finalmente, se utilizaron clasificadores como Naive Bayes, árbol de decisión, máquina de vectores de soporte (SVM) y vecinos más cercanos (KNN), logrando una precisión del 93.77

El estudio realizado por Badawi et al. [7] explicó la investigación sobre el

sistema de reconocimiento de actividades humanas y utilizó un número diferente de características para entrenar un modelo de clasificación. Por ejemplo, un trabajo involucró a 10 participantes en 7 actividades, y las señales se recopilaron de 2 acelerómetros, luego se usaron once características para el entrenamiento y se obtuvo una precisión del 97%. Otro trabajo se centró en la clasificación de 7 actividades de 10 sujetos, y se extrajeron 5 características de 3 acelerómetros para el entrenamiento, logrando una precisión del 78.2%. Del mismo modo, otro método utilizó 15 sujetos y 3 sensores con acelerómetros para lograr una precisión del 93.8% y se extrajeron 4 características para el entrenamiento del modelo; además, otra investigación alcanzó una precisión del 99.8% y 99.9% utilizando dos conjuntos de datos. El primer conjunto de datos utilizó un acelerómetro de 18 sujetos, con 9 características extraídas, y el segundo conjunto de datos consistió en 6 actividades de 30 sujetos, utilizando acelerómetros y giroscopios y extrayendo 24 características. Por lo tanto, en [7], se propuso un método novedoso para la identificación de actividades humanas utilizando la base de datos HuGaDB, que incluye 6 sensores IMU y 2 EMG. Este trabajo utiliza características estadísticas y basadas en el tiempo a partir de señales heterogéneas, logrando una precisión del 99.8% para 11 actividades; sin embargo, para entrenar el modelo, se utilizó un número total de 38 señales y 18 características, adoptando los siguientes métodos de selección de características:

1. Selección secuencial hacia atrás.
2. Selección secuencial hacia adelante.
3. Selección flotante hacia atrás secuencial.
4. Selección flotante hacia adelante secuencial.

Gochoo et al. [25], se desarrolló un sistema de monitoreo de la locomoción personal en tiempo real que utilizaba tres sensores inerciales en diferentes ubicaciones del cuerpo (muñeca, muslo y pecho). Luego, los datos se procesaron a través de filtros Gaussianos, de media móvil y de fase cero. Además, este estudio empleó una variedad de técnicas de extracción de características:

1. Características en el dominio del tiempo.
2. Características de ondícula.
3. Características en el dominio tiempo-frecuencia.

Debido a la alta dimensionalidad de las características, los investigadores utilizaron características extraídas con Descenso Estocástico del Gradiente (SGD), y se utilizó un algoritmo de perceptrón de núcleo deslizante de múltiples capas para optimizar los vectores de características, redes neuronales artificiales y máquinas de soporte vectorial. No obstante, se aplicó

una evaluación del rendimiento en los conjuntos de datos de Monitoreo de Actividad Física para Personas Mayores (PAMAP2) y la Base de Datos de Marcha Humana (HuGaDB), logrando tasas de precisión del 94.16 % y el 92.5 %. Además, el trabajo se monitoreó experimentalmente en tiempo real, logrando una precisión del 83.18 % en once actividades.

El estudio de Dostál et al. [20] propuso una técnica novedosa para extraer características que utilizó la transformada discreta de Fourier para estimar la potencia media en bandas de frecuencia seleccionadas para el reconocimiento de la marcha atáxica. Los datos acelerométricos fueron adquiridos por 31 sensores sincronizados en el tiempo (sistema Perception Neuron) ubicados en diferentes partes del cuerpo y se utilizaron métodos de máquina de vectores de soporte, Bayes, vecinos más cercanos y redes neuronales, logrando la mayor precisión del 98.5 %. Los datos se obtuvieron de 13 individuos normales y 12 individuos con ataxia, y todo el estudio se basó en la observación en un entorno clínico.

Por último, un método novedoso explicado en [40] utiliza un conjunto de datos (Evaluación del Riesgo de Caídas en Adultos Mayores - FARAO) de 293 adultos mayores para evaluar el riesgo de caídas en función de los datos de sensores inerciales. Los investigadores aplicaron los datos brutos del acelerómetro para derivar características sin realizar el paso de preprocesamiento. El método logró una reducción novedosa en el tiempo de entrenamiento al utilizar los datos de aceleración brutos como entrada para el clasificador LSTM. Para visualizar y medir el rendimiento, se utilizó el AUC (Área Bajo la Curva), y lograron obtener un AUC de 0.75.

La investigación explicó que varios sensores y las características extraídas de los datos aumentan la precisión en el algoritmo de clasificación por computadora. Sin embargo, existen desafíos, como:

1. La necesidad de utilizar varios sensores,
2. La instalación en el cuerpo humano, que puede resultar incómoda para el paciente (ergonomía).
3. Dificultades en la realización de actividades humanas.
4. El incremento de ruido en los datos.
5. El tiempo adicional necesario para la adquisición de datos, tanto antes como después del procesamiento.
6. El aumento del tiempo requerido por una computadora en un sistema con sensores inerciales para analizar las actividades en tiempo real.

Además, las características extraídas dependen de la técnica utilizada por la investigación, y el tiempo de entrenamiento es alto debido a la gran

cantidad de características y conjuntos de datos que requieren software sofisticado y herramientas computacionales potentes. Además, no será fácil de implementar en un sistema en tiempo real debido a la gran cantidad de datos necesarios para extraer y entrenar.

2.6.2. Método usados para reconocer eventos de la marcha humana.

Para aumentar la eficacia de las intervenciones, el estudio de Wang et al. [68] se enfoca en la identificación en tiempo real de los eventos de la marcha con el propósito de analizar el Tratamiento Neuro-Desarrollo (NDT), un método de rehabilitación altamente efectivo. Para estimar y detectar el inicio de la fase de apoyo (HS, por sus siglas en inglés), se emplea un sistema de captura de movimiento que incorpora unidades de medición inercial (IMUs) y se adhiere a la espinilla del sujeto en el plano sagital para recopilar datos cinemáticos. Además, el desarrollo del algoritmo se basa en la velocidad angular. La investigación lleva a cabo la estimación de eventos de la marcha mediante el establecimiento de umbrales y la medición del intervalo de tiempo entre el inicio del contacto con el suelo (MS-HS) y el inicio de la fase de despegue (HS-TO). El sistema también tiene la capacidad de ajustar parámetros según el usuario y calcular el tiempo promedio de zancada. En los experimentos, se involucraron pacientes que habían sufrido accidentes cerebrovasculares y se compararon los resultados con los obtenidos a través del sistema de captura de movimiento VZ4000, logrando una tasa de precisión del 95 % en la estimación del inicio de la fase de apoyo (HS).

En el ámbito de la investigación, se han llevado a cabo varios estudios que se enfocan en la combinación de sensores IMU (Unidades de Medición Inercial) y técnicas de inteligencia artificial con el propósito de reducir costos y abordar la detección de eventos en la marcha humana. Por ejemplo, Liu *et al.* [37] desarrollaron un zapato inteligente equipado con ocho sensores de resistencia sensible a la fuerza (FSR) y un sensor IMU. Cada FSR tiene un rango de medición de 10 kg con un tiempo de respuesta inferior a 1 ms. En este estudio, se empleó la transformada continua de ondículas para identificar eventos en la marcha, logrando una precisión general del 96

Por otro lado, Vadnerkar *et al.* [65] utilizaron un módulo de movimiento Shimmer 2r que incorpora un acelerómetro Freescale MMA7361 y un giroscopio InvenSense500. Este sistema se utilizó para distinguir entre la marcha de talón a punta y la marcha de arrastre, y se describió el algoritmo empleado para clasificar pasos buenos y malos, logrando una precisión del 84.1 %.

Lee *et al.* [35] optaron por emplear dos sensores IMU colocados en el muslo y el torso para medir ángulos globales, y se incorporó un sensor FSR debajo del zapato. Utilizaron una red neuronal de memoria a corto y largo plazo (LSTM) para estimar la fase de la marcha y detectar el impacto del talón. Debido a que el error relacionado con la discontinuidad es consi-

derablemente mayor que el error en otros puntos, la red neuronal tiende a identificar el inicio de la fase de apoyo. Esta metodología se sometió a pruebas en una cinta de correr con tres sujetos en cinco condiciones de velocidad de caminata (0.5, 1.0, 1.5 y 2 m/s), y el error en la fase de la marcha se mantuvo en 30 ms en el inicio de la fase de apoyo.

Adicionalmente, Soangra *et al.* [52] desarrollaron un método que se vale del aprendizaje automático y sensores corporales portátiles (cuatro sensores) para identificar el contacto inicial del pie (Heel Strike). Lograron clasificar la marcha de puntillas con una precisión del 92.92%.

Finalmente, Alharthi *et al.* [2] ofrecen una alternativa para clasificar a personas sanas y aquellas que padecen la enfermedad de Parkinson utilizando datos espacio-temporales de la marcha, técnicas de LSTM y análisis estadístico, lo que resultó en una clasificación adecuada del 95.5%. Estos estudios representan avances significativos en la detección de eventos de la marcha y demuestran el potencial de la inteligencia artificial en esta área.

Parte II

Eventos de la Marcha Humana



UNIVERSIDAD
DE MÁLAGA

Capítulo 3

Sistema de Adquisición de Datos

La mayoría de las ideas fundamentales de la ciencia son esencialmente sencillas, y por regla general pueden ser expresadas en un lenguaje comprensible para todos.

Albert Einstein

RESUMEN: Este capítulo presenta un estudio inicial sobre la adquisición de parámetros y datos de la marcha humana para obtener un modelo utilizando el aprendizaje automático. Se utiliza un sistema de adquisición portátil no invasivo, denominado Sistema de Adquisición de Datos (Data Acquisition System - DAS), que utiliza una propuesta de algoritmo recursivo en línea en un microcontrolador para procesar y filtrar las señales de los sensores portátiles. El DAS incluye un sensor de fuerza sensible (FSR) en el talón y dos sensores inerciales en el muslo y la pierna para medir el ángulo de la rodilla, calibrando automáticamente los sensores en cada experimento. La interfaz de usuario del DAS cuenta con algoritmos inteligentes para normalizar, interpolar y obtener la curva del modelo ajustando los datos que muestran las fases de la marcha. Los experimentos se llevaron a cabo en pacientes no patológicos de diferentes edades, cuyo patrón de marcha normal fue seleccionado por un fisioterapeuta. Se evaluó la fiabilidad del modelo cinemático al modificar la marcha de cada paciente mediante cambios en el suelo y el calzado.

3.1. Introducción

En la sección 2.1 se dió a conocer que los patrones de la marcha humana son el resultado de un esfuerzo concertado de los huesos, tendones y múscu-

los del cuerpo humano, dirigido por el cerebro. Además, el análisis de la marcha [48] implica el modelado cinemático y la caracterización de patrones normales y anormales en la marcha humana, y es utilizado por fisioterapeutas, ortopedistas y neurólogos para evaluar el estado de salud de los pacientes y seleccionar tratamientos médicos. Aunque el análisis de la marcha puede ser difícil de utilizar de forma eficaz [53], también es una herramienta de diagnóstico y evaluación muy importante en neurología, rehabilitación y fisioterapia para detectar trastornos y controlar afecciones neurológicas [11]. La disponibilidad de parámetros cuantitativos de la marcha normal es esencial para la detección de trastornos de la marcha, la evaluación de intervenciones médicas en la marcha y el desarrollo de la rehabilitación [57]. Hay factores físicos extrínsecos, intrínsecos, psicológicos y patológicos que influyen en la marcha normal, por lo que determinar parámetros de marcha normales es una tarea muy compleja, el diagnóstico de la marcha puede ser difícil [31].

Esta sección propone el desarrollo de un sistema destinado a obtener el modelo de la marcha humana (curva del modelo cinemático) mediante el uso de aprendizaje computacional aplicado a datos adquiridos de un sistema de adquisición portátil no invasivo, con enfoque en el ángulo de la articulación de la rodilla en la zona sagital. El dispositivo DAS, presentado en este documento, consta de un microcontrolador, dos sensores inerciales (IMU), un sensor de fuerza sensible (FSR), comunicación inalámbrica. Además, tiene la capacidad de ser programable según las necesidades específicas de cada estudio en este trabajo doctoral.

Para llevar a cabo el experimento, se seleccionaron pacientes con marcha normal y sin patologías. Posteriormente, después de obtener los datos para el modelo con marcha normal, se indujeron condiciones que modifican la marcha normal mientras los pacientes caminaban. Estos modelos se compararon utilizando redes neuronales para determinar la participación en la marcha, información crucial para el especialista en la evolución de una terapia.

3.2. Métodos para adquisición de Marcha Humana

Se ha observado un amplio espectro de metodologías empleadas en el análisis de la marcha humana, que van desde el procesamiento de imágenes hasta el uso de sensores colocados en diversas partes del cuerpo. Estos métodos han permitido una comprensión más profunda de los patrones de movimiento humano y han facilitado la detección de anomalías con mayor precisión que los enfoques convencionales.

Un gran número de metodologías publicadas (procesamiento de imágenes, sensores de piso y sensores colocados en cualquier parte del cuerpo). Los dispositivos tecnológicos utilizados en la investigación mencionada pueden clasificarse en tres enfoques diferentes: sensor no portátil - Nowearable Sensor (NWS), sensor portátil-Wearable Sensor (WS) y sistema híbrido como lo da

a conocer Gochoo et. al [25]. Los NWS requieren una habitación con sensores instalados para capturar la marcha mientras el sujeto camina, lo que implica un mayor costo de instalación y equipo. Los NWS pueden clasificarse en dos grupos: procesamiento de imágenes y sistemas basados en sensores de piso. Entre los métodos utilizados se encuentran: 1. Cámara triangular con un 70% de precisión que logra la investigación de Badawi et. al [7], 2. Video 3D adquirido por Time of Flight (ToF) con un error del 2.66% - 9.25% obtenido por [14], 3. Luz de estructura obtenida $<1\%$ (diferencia media) y 4. Termografía con precisión entre el 78% y el 91% con la investigación de [14].

WS son sensores instalados en el cuerpo, y no requiere un laboratorio para completar el experimento porque esta técnica adquirir la información de la marcha durante las actividades de la persona y puede almacenar datos durante la marcha o carrera [23] [3] y extraer características significativas para los análisis. Muchos métodos de WS que han investigados varios autores en esta área son: 1. Sensor inercial para obtener la orientación, velocidad y aceleración con mayor precisión determinó el ángulo de flexión / extensión de las articulaciones (CMC-coeficiente de correlación múltiple > 0.96) para todas las articulaciones [27] y Longitud de zancada error -0.8 ± 6.6 cm [64], 2. Goniómetro 0.999 con medidas tomadas con Goniómetro mecánico [15]. Sin embargo, sobre la base de [15], la investigación actual de análisis de la marcha uso 40% de NWS, 22.5% de WS y 37.5% de sólo sensor inercial (IS). El uso de IS ha aumentado en las nuevas investigaciones, además, hay investigaciones para estimar la marcha humana con el menor número posible de sensores y, por tanto, reducir el tiempo de computación.

3.2.1. Modelos de predicción

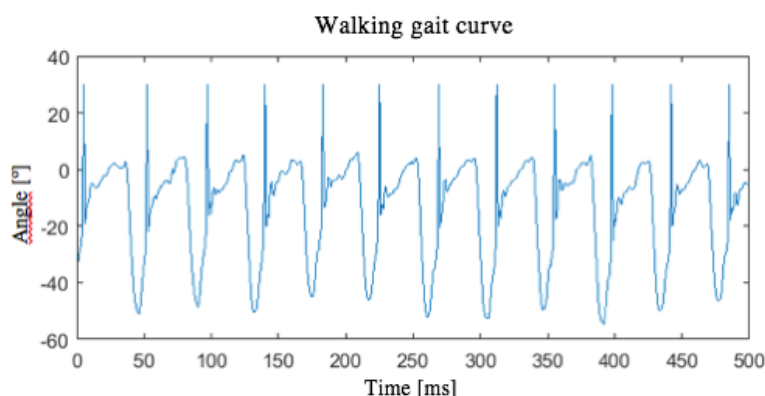


Figura 3.1: Marcha humana obtenidas mediante la tecnología inalámbrica DAS. El procesamiento de señales de acelerómetro y giroscopio en tiempo real se lleva a cabo dentro del propio DAS [57].

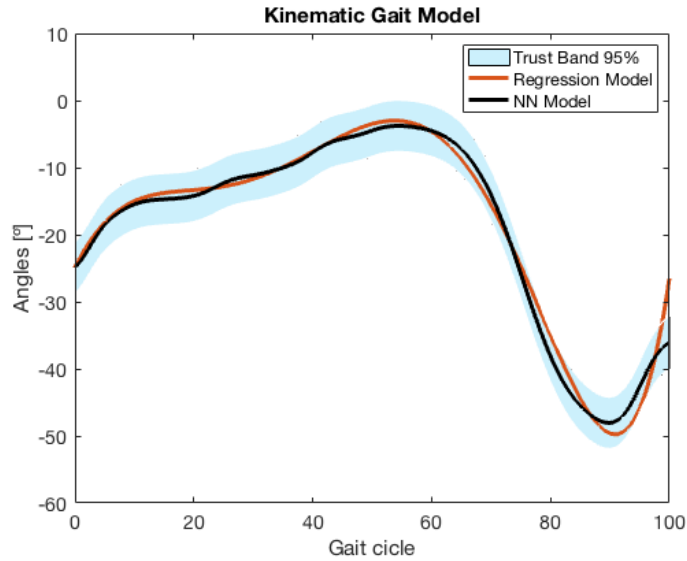


Figura 3.2: Modelo de curva cinemática una vez clasificada, normalizada e interpolada la Marcha Humana [57].

En el contexto expuesto en la sección anterior, resulta crucial poder cuantificar la confianza en el modelo de la marcha humana. Por ende, la información sobre la incertidumbre en las predicciones puede ser de suma importancia para los profesionales que emplean sistemas basados en inteligencia artificial para modelar la marcha humana. La evaluación de si un modelo de predicción está sobreajustado o subajustado puede mejorar significativamente el rendimiento y economizar tiempo y recursos [22]. En la Figura 3.1, se muestra el resultado de la marcha luego del procesamiento de la señal; además, se identifican pulsos que superan los 20° , los cuales son datos enviados por el sistema para reconocer el inicio y el final de la marcha. Esta información se almacena en un vector correspondiente a veinte pasos con velocidad normal. Dicho vector consta de aproximadamente 750 datos (si los pacientes caminan más despacio, el vector tendrá más de 750 datos), y estos se dividen aleatoriamente en tres grupos: muestras de entrenamiento, muestras de validación y muestras de prueba.

Para estimar y obtener el modelo, aplicamos el método de regresión y utilizamos modelos de redes neuronales para ajustar los datos. En la Figura 3.2, se presenta el resultado del modelo cinemático de la marcha humana en la zona sagital del paciente. Además, comparamos nuestros resultados con los obtenidos en otras investigaciones mencionadas en [22, 66].

Para modelar la cinemática de la marcha humana, se emplearon modelos de regresión no lineal y algoritmos de redes neuronales sobre los datos mostrados en la Figura 3.1. En cuanto a los modelos de regresión no lineal, se

utilizaron aquellos detallados en la Tabla 3.1, mientras que para los algoritmos de redes neuronales se emplearon los modelos especificados en la Tabla 3.2. Ambas tablas muestran los resultados estadísticos obtenidos.

3.2.2. Resultados

Para llevar a cabo los experimentos con el sistema DAS, se realizó la recolección de datos en un espacio amplio y libre de obstáculos, con una distancia mínima de caminata de 20 metros. Se seleccionaron caminos de tierra y pavimento adoquinado para comparar el grado de similitud del modelo cinemático de cada individuo. Se reclutaron treinta pacientes, cuya ubicación óptima de los tres sensores fue determinada por el especialista: el sensor de presión (FSR) se colocó en el talón (debajo de la plantilla del zapato) para marcar el inicio y fin de un ciclo de marcha; el primer sensor IMU se posicionó en el lado colateral externo de la pierna (en el vientre muscular del músculo gemelo externo, a 10 cm por debajo del borde inferior de la rótula, siguiendo un ángulo recto entre la tibia y el fémur); el segundo sensor IMU se ubicó en el lado colateral lateral del muslo (en el trayecto del músculo tensor de la fascia lata, a 10 cm del borde superior de la rótula, siguiendo un ángulo recto con respecto al fémur, la tibia y la cresta ilíaca).

La Tabla 3.1 detalla los ajustes estadísticos de los modelos que mejor se adaptaron a los datos recopilados: polinomial, gaussiano y de Fourier. Se descartó el modelo polinomial de grado 4 debido a sus grandes errores, de manera similar, los modelos de grados 6 a 8 ya no se consideraron únicamente en función de los resultados de la tabla, ya que mostraron signos de sobreajuste. Esto se observó también en el modelo gaussiano de término 4 y el modelo de Fourier de término 3.

Para mejorar la precisión en la predicción del valor y del modelo resultante, se empleó un modelo de red neuronal de aprendizaje profundo con capas ocultas, conocido por su capacidad para ofrecer resultados superiores. En nuestro estudio, se determinó que los modelos de Levenberg-Marquardt (LM), Regularización Bayesiana (BR) y Gradiente Conjugado (CG) con una sola capa oculta y 10 neuronas proporcionaban el mejor ajuste a los datos. Estos modelos se entrenaron utilizando el 75 % de los datos para el entrenamiento, el 15 % para la validación y el 15 % restante para la prueba. La selección del modelo predictivo óptimo se basó en el análisis de los valores de regresión (R) y del error cuadrático medio (MSE), como se muestra en la Tabla 3.2. Los resultados revelaron que el modelo Levenberg-Marquardt de la red neuronal fue el más adecuado para predecir los resultados. Además, la comparación con la regresión no lineal utilizada, como se observa en la Tabla 3.1, evidencia que los algoritmos de ajuste de red neuronal arrojaron resultados superiores. La Figura 3.2 presenta los modelos obtenidos, acompañados de su banda de confianza del 95 %.

Para ajustar y validar el modelo, cada paciente llevó a cabo dos cami-

Tabla 3.1: Resultado de ajuste de curvas de la marcha humana para obtener el modelo de la cinemática[57]

| Modelo de ajuste | SSE | R-2 | DFE | Adj R-sq | RMSE | # Coeff |
|----------------------|-------|--------|------|----------|------|---------|
| Polinomio - grado 4 | 38576 | 0.8064 | 1095 | 0.8057 | 5865 | 5 |
| Polinomio - grado 5 | 22021 | 0.8865 | 1094 | 0.8860 | 4285 | 6 |
| Polinomio - grado 6 | 21934 | 0.8970 | 1093 | 0.8964 | 4279 | 7 |
| Polinomio - grado 7 | 21282 | 0.8901 | 1092 | 0.8894 | 4195 | 8 |
| Polinomio - grado 8 | 20322 | 0.8948 | 1091 | 0.8940 | 4075 | 9 |
| Gaussian - Término 4 | 18460 | 0.8198 | 1088 | 0.8180 | 3054 | 12 |
| Gaussian - Término 5 | 53770 | 0.8967 | 1085 | 0.8954 | 1589 | 15 |
| Fourier - Término 3 | 21160 | 0.8907 | 1092 | 0.8900 | 4179 | 8 |
| Fourier - Término 4 | 20277 | 0.8950 | 1090 | 0.8941 | 4069 | 10 |

Tabla 3.2: Resultados obtenidos por los algoritmos de redes neuronales[57]

| Modelo | MSE | R |
|--------------------------|---------|--------|
| Levenberg-Marquardt | 16.5655 | 0.9512 |
| Regularización Bayesiana | 17.5710 | 0.9491 |
| Gradiente Conjugado | 18.7960 | 0.9463 |

natas en dos tipos de suelo diferentes: uno de tierra y otro de pavimento adoquinado. Durante la primera caminata, se registró el modelo de marcha del paciente. Posteriormente, en la segunda caminata, se comparó y visualizó la curva del modelo junto con la marcha modificada. Esta alteración se implementó con el fin de contrastar el modelo de ambas caminatas de cada uno de los treinta pacientes, de modo que la correlación entre la marcha normal y la modificada fuera prácticamente idéntica, dado que ambas pertenecían al mismo paciente. Como resultado de este experimento, se logró una correlación promedio de 0.9897 entre las marchas de los treinta pacientes utilizando el modelo Levenberg-Marquardt.

3.3. Conclusión

El análisis de la marcha biomecánica en la articulación de la rodilla ha proporcionado una comprensión detallada de los rangos de movimiento en el plano sagital, así como de los ángulos de flexión del fémur y la tibia durante la actividad de caminar. Este análisis se representa mediante la curva cinemática de la marcha. Además, el Sistema de Adquisición de Señales (DAS) puede emplearse de manera efectiva en ambas piernas, ya que los ejes de los sensores inerciales (IMU) se seleccionaron y configuraron para mantener la posición de instalación sin alteraciones.

Aunque en este estudio no se realizaron experimentos con pacientes que

presentaran patologías en la marcha, se considerará la inclusión de diferentes casos clínicos en investigaciones futuras para identificar y analizar posibles anomalías en la marcha. Es importante destacar que no es imprescindible utilizar una cinta de correr electrónica para controlar la velocidad y longitud de zancada durante el análisis de la marcha, ya que el procesamiento digital de señales (offline) cuenta con la capacidad de clasificar y normalizar los datos de cada paso, incluso cuando se realiza a diferentes ritmos.

La mejora del ajuste de la curva puede lograrse mediante el uso de características más refinadas para el modelado con redes neuronales. No obstante, es importante tener en cuenta que el modelo de la curva resultante puede diferir significativamente del modelo teórico, lo cual puede afectar la interpretación visual que requieren los especialistas. Por lo tanto, la visualización detallada de las características del modelo de la curva resultante es fundamental para comprender la afectación de la marcha en distintas áreas y para evaluar la evolución del proceso de rehabilitación en el modelo.



UNIVERSIDAD
DE MÁLAGA

Capítulo 4

Detección de evento de la marcha humana basado en aprendizaje profundo

Conforme la complejidad de un sistema aumenta, nuestra capacidad para ser precisos y construir instrucciones sobre su comportamiento disminuye hasta el umbral más allá del cual, la precisión y el significado son características excluyentes.

Lofti A. Zadeh

RESUMEN: Esta segunda parte de la tesis introduce un nuevo método para la detección de eventos durante la marcha, empleando aprendizaje profundo para modelar la cinemática. La configuración propuesta utiliza dos sensores IMU (Unidad de Medición Inercial) para calcular los ángulos del modelo cinemático, junto con un sensor FSR (Resistencia Sensible a la Fuerza) para identificar el evento de Heel Strike (HS). Estas señales son procesadas mediante el sistema DAS, el cual registra los datos de la marcha. En primer lugar, se generó un patrón de curva cinemática utilizando tres tipos de redes profundas. Posteriormente, este patrón fue aplicado para detectar los eventos de Heel Strike (HS) utilizando Dynamic Time Warping (DTW). Los resultados proporciona a los especialistas médicos una curva cinemática de la marcha y, con el fin de desarrollar herramientas para la detección automática de puntos críticos en los trastornos de la marcha.

4.1. Introducción

Los patrones de la marcha humana son el resultado de un esfuerzo concertado de los huesos, tendones y músculos del cuerpo humano, dirigido por el cerebro. El análisis de la marcha [48] implica el modelado cinemático y la caracterización de patrones normales y anormales en la marcha humana, y es utilizado por los médicos especialistas. Aunque el análisis de la marcha puede ser difícil de utilizar de forma eficaz [53], también es una herramienta de diagnóstico y evaluación muy importante en neurología, rehabilitación y fisioterapia para detectar trastornos y controlar afecciones neurológicas [11]. Las afecciones neurológicas, como las secuelas de un derrame cerebral, un accidente o la enfermedad de Parkinson, pueden provocar el deterioro de las habilidades motoras y una disminución de la capacidad para caminar, lo que repercute significativamente en el bienestar general y la salud de las personas [36]. En este contexto, existe la necesidad de ayudar a las personas mayores y los pacientes a superar los trastornos del movimiento y restaurar su capacidad para caminar, en última instancia, mejorar su vida cotidiana, y el análisis de la marcha puede desempeñar un papel clave en este sentido [69]

El ciclo de la marcha humana puede ser analizado según muchos parámetros como el rango y patrón de movimiento articular, las fuerzas de reacción del suelo, el momento del contacto pie/suelo, las velocidades de la marcha, las cadencias, las longitudes de zancada, las relaciones de fase de balanceo-apoyo, los ángulos articulares en reposo, los torques isométricos y las actividades musculares fásicas [19]. De estos, los parámetros de fase de balanceo-apoyo presentan tres eventos cruciales en cada ciclo de la marcha: los eventos de Medio Balanceo (Mid-Swing (MS)), Impacto del Talón (Heel-Strike (HS)) y Despegue del Dedo del Pie (Toe-Off (TO)). Los eventos en el ciclo de la marcha pueden ser registrados utilizando sensores no portátiles, sensores portátiles y sistemas híbridos [57]. De estos, los sensores portátiles son los más comúnmente utilizados, ya que son menos costosos y pueden ser utilizados fuera de entornos controlados. Los sensores portátiles típicamente utilizados incluyen acelerómetros, giroscopios, marcadores activos y Unidades de Medición Inercial (IMUs, por sus siglas en inglés).

Para mejorar la efectividad de la intervención, Wang et al. [67] identifica eventos de la marcha en tiempo real para analizar el Tratamiento Neuro-Desarrollador (TND), un método efectivo de rehabilitación. Para estimar y detectar el Impacto del Talón (IT), se incorpora un sistema de captura de movimiento mediante unidades de medición inercial (IMU) que se colocan en la espinilla del sujeto en el plano sagital para obtener datos cinemáticos; además, el desarrollo del algoritmo utiliza la velocidad angular. La investigación estima el evento de la marcha utilizando un umbral y un intervalo de tiempo entre MS-HS y HS-TO. El sistema también actualiza parámetros para diferentes usuarios y calcula el tiempo promedio de zancada. Se invitaron

pacientes con accidente cerebrovascular a experimentos y se compararon con un sistema de captura de movimiento VZ4000, que logró una tasa del 95 % para estimar el IT.

Algunas investigaciones han abordado la combinación de sensores IMU e inteligencia artificial para reducir costos y resolver la detección de eventos de la marcha. Por ejemplo, Liu et al. [37] desarrollaron un zapato inteligente equipado con ocho resistencias sensibles a la fuerza y un sensor IMU, donde cada FSR tiene un rango de medición de 10 kg con un tiempo de respuesta de menos de 1 ms; además, aplicaron la transformada continua de wavelet para identificar el evento de la marcha con una precisión general del 96 %. Vadnerkar et al. [65] utilizaron un módulo de movimiento Shimmer 2r (incorpora el acelerómetro Freescale MMA7361 y el giroscopio InvenSense500) para distinguir entre la marcha de talón a dedo y la marcha arrastrada, y describen el algoritmo utilizado para clasificar pasos buenos y malos, obteniendo una precisión del 84.1 %. Lee et al. [35] emplearon dos sensores IMU (muslo y torso) para medir ángulos globales y un sensor FSR adjunto debajo del zapato. Se implementó el modelo LSTM para estimar la fase de la marcha y detectar el impacto del talón; la red encuentra preferentemente el IT. Esta metodología se experimentó en una cinta de correr con tres sujetos en cinco condiciones de velocidad de marcha (0.5, 1.0, 1.5 y 2 m/s) y se observó un error de fase de la marcha que ocurrió durante 30 ms en el IT. Además, Soangra et al. [52] diseñaron un método para identificar el contacto inicial del pie (Impacto del Talón) utilizando aprendizaje automático y un sensor corporal portátil con cuatro sensores; lograron clasificar la marcha de puntillas con una precisión del 92.92 %. Alharthi et al. [2] ofrecen una alternativa para clasificar la enfermedad de Parkinson utilizando datos de marcha espaciotemporales con LSTM y análisis estadístico, lo que resulta en una clasificación adecuada del 95.5 %.

Una metodología reciente desarrollada por Wang et al. [67] logró reconocer eventos de IT con una tasa alta del 98.84 % y un retraso de 0.028 segundos en comparación con otras investigaciones mencionadas en el estado del arte. En este estudio, se empleó un modelo LSTM para la construcción de la detección de eventos de la marcha, utilizando datos del sistema comercial APDM OPAL que contiene dos IMUs. Además, cada sujeto caminó por un pasillo de 20 metros en cuatro ocasiones. Los eventos de IT fueron marcados para entrenar el modelo y posteriormente se evaluaron.

En nuestro estudio previo [57], desarrollamos un sistema de adquisición de datos (DAS) que empleaba un sensor de fuerza (FSR) y dos sensores IMU para obtener un modelo de marcha. El presente trabajo presenta un enfoque innovador para detectar eventos de la marcha utilizando un modelo cinemático para el aprendizaje profundo, con el objetivo de proporcionar retroalimentación sobre la calidad de la marcha a los sujetos, al mismo tiempo que se reduce el número de sensores requeridos. En nuestros experimentos, los

sensores FSR se utilizaron únicamente para entrenar el modelo cinemático. Posteriormente, se emplearon solo dos sensores IMU para optimizar y detectar el Impacto del Talón (HS) mediante Dynamic Time Warping (DTW). Además, validamos la efectividad de este método comparándolo con el enfoque propuesto por Wang et al. [67]. Nuestro estudio incluyó la participación de tres grupos de individuos sanos: jóvenes, adolescentes y personas mayores. En contraste con la literatura existente, nuestro principal aporte radica en representar una amplia diversidad de individuos mediante el modelo cinemático propuesto, permitiendo identificar eventos de Impacto del Talón (HS) de manera general, sin distinción de género ni edad, y evitando la necesidad de crear modelos específicos para distintos grupos poblacionales. Nuestro método logró detectar con éxito el HS con una precisión del 96.64 % y una latencia media de detección de 20 ms.

4.2. Metodología

Esta sección se presenta el método propuesto para detectar eventos de marcha de HS. En cada sujeto, se instalaron dos sensores IMU en la espinilla y el muslo, y un FSR se instaló en el talón. A partir de las señales recopiladas de estos sensores, el DAS realiza operaciones matemáticas en línea y extrae el ángulo de la rodilla a través de un filtro recursivo. Los ángulos recopilados se agrupan en una matriz para construir un modelo cinemático de la rodilla utilizando técnicas de aprendizaje profundo. El modelo se almacena para realizar una DTW con los datos recién adquiridos para clasificar el evento de HS. Finalmente, evaluamos nuestra propuesta con otra metodología basada en redes neuronales recursivas. La Figura 4.1 ilustra el flujo de trabajo propuesto del método.

4.2.1. Sistema de Adquisición de Datos (DAS)

En este trabajo, se instalaron un total de tres sensores en diferentes partes (pies, espinillas y muslos) de las piernas. Los IMUs en la espinilla y el muslo contienen un acelerómetro de 3 ejes en X, Y y Z y un giroscopio de 3 ejes (un total de 12 señales). Además, las señales se recopilaron a una tasa de muestreo de 25 Hz (40 ms). Un microcontrolador Atmega328P procesa digitalmente en línea los datos crudos de los sensores para extraer el ángulo de la rodilla. La señal del acelerómetro se pasa a través de un filtro de Kalman y se convierte en un ángulo usando la ecuación 4.1 [62]. Por ejemplo, para un ángulo en el eje X:

$$A_{angleX} = \arctan \left(\sqrt{\frac{f_X^2}{f_Y^2 + f_Z^2}} \right) \quad (4.1)$$

donde f_X, f_Y, f_Z son las fuerzas de gravedad, es decir, las señales del

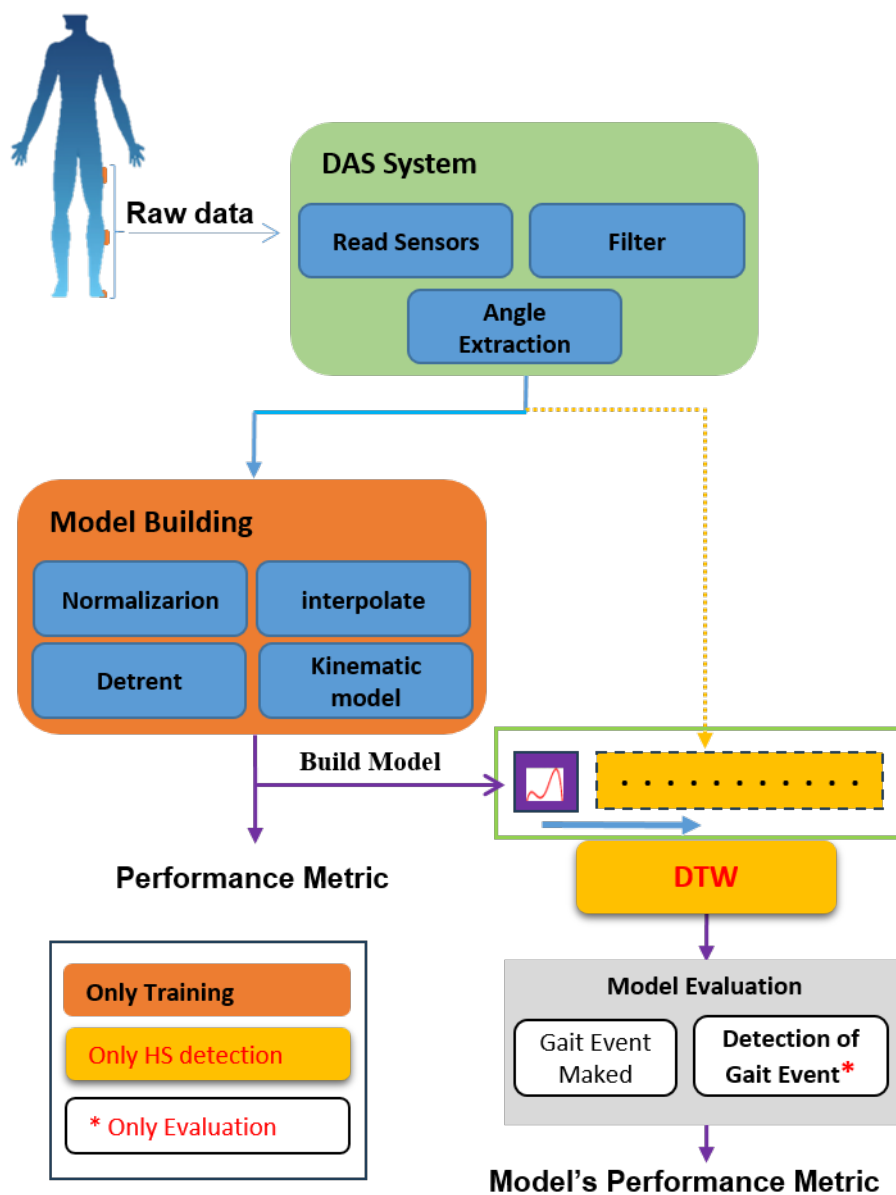


Figura 4.1: Arquitectura de flujo del modelo propuesto

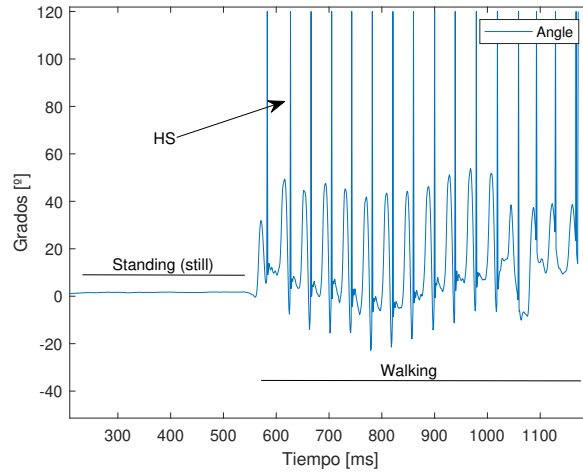


Figura 4.2: Señal angular adquirida mediante el sistema DAS. En este ejemplo, el paciente primero está quieto y luego empieza a caminar.

acelerómetro. f_X está en el numerador ya que la señal principal sería la del eje X.

La señal del giroscopio se integra para obtener el ángulo. La discretización puede convertir la integral en una ecuación diferencial. Por lo tanto, la integración se puede aproximar utilizando la integración trapezoidal [24]:

$$G_{angleX} = \int v_x(t)dt = \sum_{n=0}^N \left[\frac{V_x(n) + V_x(n-1)}{2} \right] T_s \quad (4.2)$$

donde v_x es la velocidad angular en el tiempo t , V_x es la muestra de la velocidad angular en el tiempo T_s .

Por último, un filtro complementario une los ángulos del acelerómetro y del giroscopio, y el FSR envía el evento HS. Para evitar contactos erróneos del talón, se utiliza un promedio del filtro FIR con una entrada previa de N. Un ejemplo de la señal adquirida se presenta en Figura 4.2.

4.2.2. Contrucción del Modelo

Existen métodos de regresión de modelos basados en el dominio del tiempo, la frecuencia y el tiempo-frecuencia, que se aplican habitualmente. Este trabajo propone un conjunto de pasos de procesamiento de señales para obtener un modelo cinemático que cumpla el objetivo.




Figura 4.3: Eliminación de tendencia de la señal.

4.2.2.1. Eliminación de la tendencia de los datos de series temporales

Es necesario aclarar que las caminatas no se realizaron en cintas eléctricas, por lo que variaba el tiempo de caminata. Además, los pacientes sanos caminaron en pendientes de manera intencional, lo que provocó una tendencia para evaluar la adaptabilidad de nuestro método.

La serie temporal se asume como una combinación aditiva de una tendencia y otros componentes [46].

$$X(t) = T(t) + S(t) \quad (4.3)$$

donde $X(t)$ es la serie temporal original, $T(t)$ es la tendencia y $S(t)$ es el residuo del componente estacional que también incluye ruido.

Para eliminar la tendencia de una serie temporal, primero debemos estimar y restar el componente de tendencia de los datos originales, dejando solo el componente estacional. Además, para seleccionar el mejor modelo de eliminación de tendencia (se probaron un modelo constante, un modelo lineal, un modelo Statsmodels y un modelo de media móvil), inspeccionamos visualmente los datos en cada modelo aplicado. Buscamos cualquier tendencia residual, oscilaciones o patrones que afectarían nuestros datos, y se seleccionó el modelo Statsmodels. En la Figura 4.3 se muestra una parte de la señal adquirida en el rango de tiempo (250-1250), y se puede observar la señal sin tendencia.

Tras aplicar el detrend, la serie temporal se normaliza en el intervalo

[0,100] de acuerdo con la siguiente fórmula [72]:

$$T_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (4.4)$$

donde T_i y x_i son el tiempo antes y después de la normalización, y x_{min} y x_{max} son los valores mínimo y máximo del tiempo seleccionado.

4.2.2.2. Construcción del Modelo

En el Capítulo 3 y en un trabajo previo realizada por Terán-Pineda *et al.* [57], el modelo se desarrolló utilizando técnicas de regresión y redes neuronales básicas. Durante la adquisición de datos, los parámetros de la marcha, como la longitud de zancada, la edad, el sexo, el género, factores externos, y la velocidad, variaron, lo que provocó una notable dispersión en algunas de las marchas y condujo a errores y sobreajustes en los modelos obtenidos en esa investigación previa.

Uno de los objetivos de este trabajo es desarrollar un modelo cinemático que precise representar una amplia variedad de individuos sin patologías y que se ajuste a la variabilidad de los datos recopilados. Esto tiene como fin evaluar la viabilidad de identificar el Impacto del Talón (Heel Strike-HS) de manera generalizada, evitando así la necesidad de crear modelos específicos para distintos grupos de personas, cuyos parámetros pueden variar y afectar la marcha.

Se crearon tres modelos de aprendizaje profundo y se experimentaron con diferentes hiperparámetros para conocer su rendimiento. El primer modelo de red neuronal utilizado fue una Red Neuronal Profunda (DNN). El modelo tiene cuatro capas ocultas: la primera con 200 unidades y una función de activación sigmoide; la segunda, tercera y cuarta con 100 unidades y una función de activación Relu; y finalmente, la capa de salida tiene una función de activación lineal. Aplicamos el error cuadrático medio como función de pérdida y la estimación del momento adaptativo como función de optimización. Finalmente, lo entrenamos durante 500 épocas. Los resultados pueden verse en la Figura 4.4.

Otro modelo utilizado fue una red neuronal recursiva (RNN) en la que proporcionamos datos de entrada $X \in \mathbb{R}^{800 \times 1}$. El modelo consta de 32 capas RNN con una función de activación sigmoidea y 16 capas ocultas con una función de activación ReLU. Se aplicó el error cuadrático medio como función de pérdida y la propagación cuadrática media como función de optimización. Finalmente, se entrenó durante 800 épocas. Los resultados pueden observarse en la Figura 4.5.

Por último, se utiliza LSTM; el modelo consta de 32 capas LSTM con una función de activación sigmoidea. El modelo tiene tres capas de ocultación: la primera y la segunda con ocho capas y una función de activación ReLU. Se aplicó el error cuadrático medio como función de pérdida y la propagación




Figura 4.4: Modelado de datos para la representación de la cinemática de la marcha humana mediante Redes Neuronales Profundas - DNN

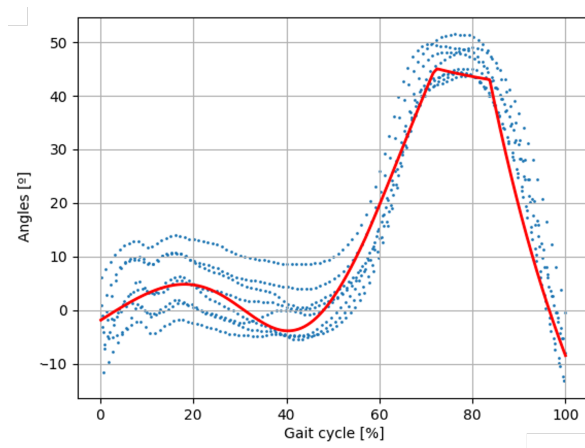


Figura 4.5: Modelado de datos para la representación de la cinemática de la marcha humana mediante Red Neuronal Recursiva - RNN




Figura 4.6: Modelado de datos para la representación de la cinemática de la marcha humana mediante LSTM

cuadrática media como función de optimización. Finalmente, lo entrenamos durante 1000 épocas. El resultado se encuentran en la Figura 4.6.

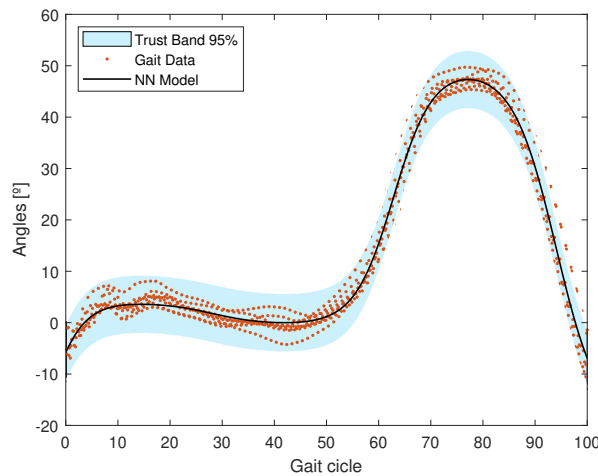


Figura 4.7: Modelo cinemático utilizando Red Neuronal Profunda - Deep Neural Network (DNN) con una Banda de Confianza del 95 %

La Tabla 4.1 muestra los resultados de los modelos desarrollados bajo diversas dispersiones. Como se mencionó anteriormente, un ajuste exitoso puede generar problemas como el sobreajuste o el subajuste. Por lo tanto, se realizó un análisis con especialistas y se eligió la red neuronal DNN en función de su comportamiento y resultados de ajuste en diferentes rangos de

Tabla 4.1: Tabla de diagrama de dispersión y R2 de los modelos obtenidos, organizados de mayor a menor dispersión.

| Dispersión | Algoritmo de Redes Neuronales | | |
|------------|-------------------------------|----------|----------|
| | DNN | RNN | LSTM |
| 17.98 | 0.927205 | 0.932 | 0.941 |
| 15.76 | 0.93265 | 0.93456 | 0.94863 |
| 13.25 | 0.93854 | 0.937654 | 0.950234 |
| 11.24 | 0.952001 | 0.940024 | 0.95354 |

dispersión. El modelo final se presenta detalladamente en la Figura 4.7 que corresponde al modelo con DNN con un nivel de confianza del 95 %.

4.2.2.3. Identificando señales similares

Suponiendo que los datos de la marcha recopilados se almacenan en un vector X , y el modelo cinemático seleccionado se guarda en un vector Q , este último se convierte en una consulta Q que se busca en X . Por lo tanto, la consulta Q se desliza sobre X ; es decir, Q se mueve una muestra hacia la derecha en cada punto de tiempo, mientras se calculan las medidas de error en cada intervalo.

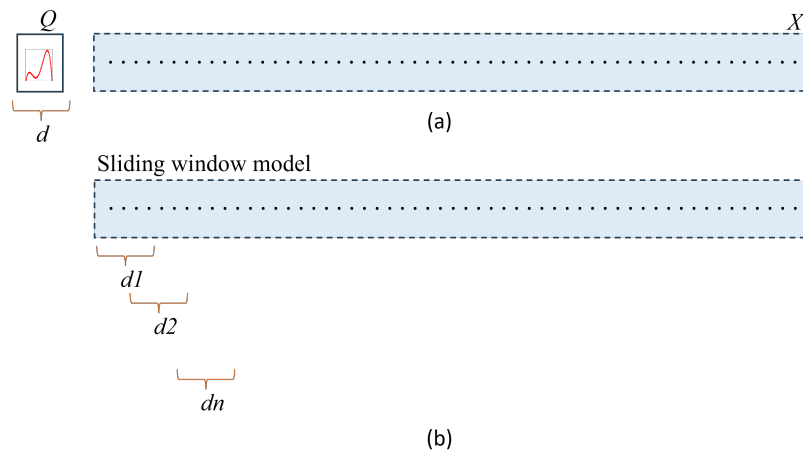


Figura 4.8: Ventanas deslizantes entre el vector de consulta Q y los datos recopilados X . a) Representación de datos en forma de vector, y b) modelo de ventanas deslizantes.

En la Figura 4.8a se presentan los vectores Q y X , junto con la representación del tamaño de la ventana (d) a deslizar. En la Figura 4.8b se muestra el cálculo de las medidas de error d_i entre Q y cada ventana del vector X deslizado, y cada resultado se almacena en un vector D indicado en la siguiente

Algorithm 1 Algoritmo de detección de eventos HS, $Q =$ consulta

Entrada: $X_t =$ Señal del ángulo adquirida desde DAS

Salida: Señales de detección de eventos HS

Método: HS_event

```

1: locate  $\leftarrow$  1
2: while slide=1,2,..., longitud(X) do
3:    $X_{iter} \leftarrow DTW(X_{subsequence}, Q)$ 
4:    $d_{slide} \leftarrow$  distancia( $X_{iter}, Q$ )
5:   if  $d_{slide}$  es correcto la distancia then
6:      $HS_{locate} \leftarrow$  Localizar y guardar el punto de evento
       de HS.
7:     locate  $\leftarrow$  locate + 1
8:   end if
9: end while
10: return: HS

```

ecuación.

$$D = [d_1, d_2, d_3, \dots, d_{n-m+1}] \quad (4.5)$$

donde n es la longitud de X , y m es la longitud de la consulta.

El algoritmo Dynamic Time Warping (DTW) nos permite estirar y alinear la similitud entre dos conjuntos de datos que pueden variar con el tiempo, como la subsecuencia de datos X elegida para las ventanas deslizantes y el modelo cinemático de consulta. DTW tiene la ventaja de comparar dos señales incluso si hay un ligero desplazamiento en el tiempo, a diferencia de otros métodos para calcular la distancia entre señales. Para medir la distancia entre dos conjuntos de datos se utiliza la Distancia Euclidiana.

$$d_{mn}(X, Y) = \sqrt{\sum_{k=1}^k (x_{k,m} - y_{k,n}) * (x_{k,m} - y_{k,n})} \quad (4.6)$$

Para identificar el evento HS, se utiliza el Algoritmo 1. En nuestro trabajo, se utiliza la normalización z para ambos datos, detallada en la siguiente ecuación para X .

$$\hat{x} = \frac{x_i - \mu_X}{\sigma_X} \quad (4.7)$$

donde μ es la media y, σ es la desviación estándar.

Al incluir la ecuación 4.7 en la ecuación 4.6, el error puede expresarse en una única ecuación que representa la distancia euclídea normalizada en z :

$$d_{mn}(X, Y) = \sqrt{\sum_{k=1}^k (\hat{x}_k - \hat{y}_k)^2} \quad (4.8)$$

donde d_{mn} describe la distancia entre las m -ésimas muestras de X y las n -ésimas muestras de Y , además, X y Y son señales k -dimensionales.

La Figura 4.9 presenta las trazas de datos y resalta cualquier instancia de señal identificada mientras la consulta se desliza sobre la señal. Dado que son vectores reales, la función muestra la relación basada en las muestras. Nótese que la última marcha en el rango $[450, 500]$ no fue identificada porque está fuera de la banda de confianza, lo que sugiere una diferencia en la señal. Además, se observa que la primera marcha fue identificada como una señal.




Figura 4.9: Búsqueda de señal con ventanas deslizantes entre el vector de consulta y los datos recopilados.

La Figura 4.10 presenta los eventos HS detectados, donde los primeros y últimos pasos quedan sin reconocer debido a la discrepancia entre la señal y la señal de referencia (consulta). De acuerdo con la literatura revisada, se ha observado que algunos individuos establecen un patrón de marcha consistente después del tercer o segundo paso, y se considera que el último paso marca la conclusión del acto de caminar.

Por otro lado, la Figura 4.11 proporciona una vista ampliada de la Figura 4.10, permitiendo apreciar con detalle la detección del evento Heel Strike (HS). En ella, el numeral (1) representa el ciclo completo de la marcha, desde el evento detectado hasta su conclusión. El numeral (2) indica el tiempo de error en la detección del evento, con un retraso promedio de 40 ms.

4.3. Resultados

Para evaluar la eficacia de nuestra metodología, proponemos una comparación con un estudio realizado por Wang et al. [67] del Departamento de Ingeniería Mecánica de la Universidad Nacional de Taiwán. En su investigación, Wang et al. desarrollaron un modelo utilizando una red LSTM para detectar eventos de HS en la marcha humana con dos IMUs colocadas en

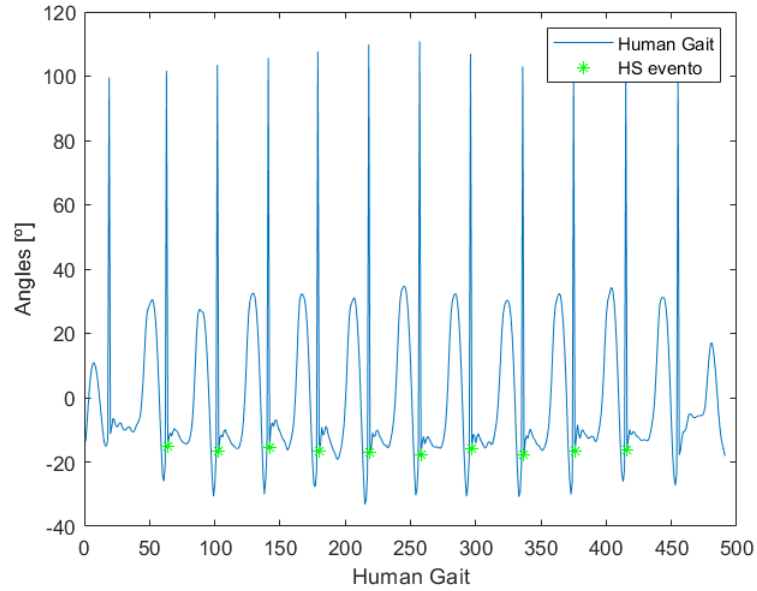


Figura 4.10: Evento HS detectado en el conjunto de marcha.

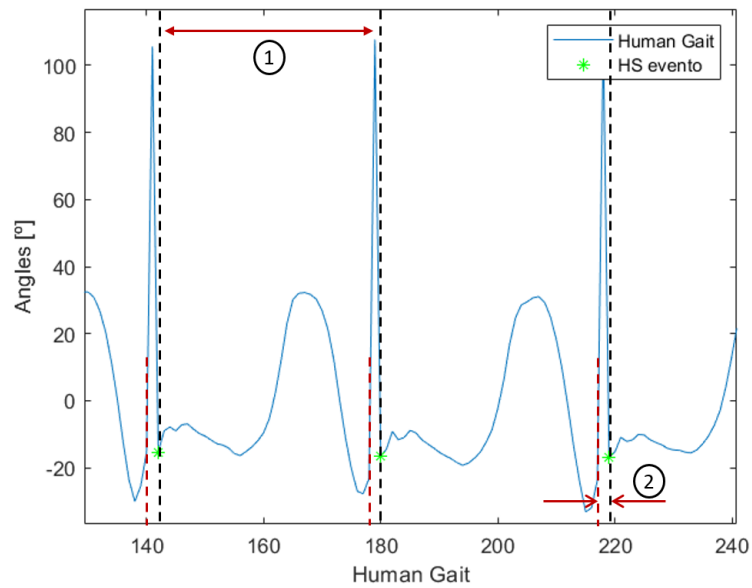


Figura 4.11: Detección automática de eventos HS a) Detección en todos los conjuntos de datos y b) Vista ampliada para apreciar la detección del evento.

la pierna, cada una capturando tres aceleraciones axiales y tres velocidades angulares axiales. Durante la fase de entrenamiento, los datos adquiridos de

las IMU se etiquetaron manualmente con los eventos de HS. Se utilizó la segmentación de datos para todos los entrenamientos, con ventanas deslizantes de 50 muestras de los datos de los sensores. La entrada del modelo al LSTM se representó como $X_{in} \in \mathbf{R}^{50 \times 6}$. La salida de la LSTM se alimentó a una capa totalmente conectada con una activación sigmoidea para generar una salida $P \in \mathbf{R}^{50 \times 1}$, de modo que cada valor de salida debía ser 1 en eventos HS y 0 en caso contrario. Wang et al. aplicaron la entropía cruzada binaria como función de pérdida para entrenar su modelo con los eventos HS etiquetados manualmente, utilizando Rmsprop como optimizador. Todos los entrenamientos se ejecutaron durante 60 épocas con un tamaño de lote de 500, y una probabilidad de 0.2 en las capas de abandono; para la validación se utilizó la validación cruzada Leave-One-Out (LOOCV).

4.3.1. Dataset

Diez sujetos seleccionados por un especialista médico se sometieron a un examen físico que verificó que tenían una marcha normal sin ninguna alteración, una actitud positiva y ninguna lesión visible o interna en las extremidades inferiores, con articulaciones en buen estado y sin ninguna alteración o afección. Se probó a cada paciente para asegurarse de que su marcha no fuera inusual de ninguna manera en las tres fases de la marcha.

La velocidad de la marcha medida en los sujetos estaba dentro de un rango de 0,9 a 1,4 metros por segundo. En individuos mayores, la disminución en la longitud del paso tuvo un impacto significativo en la reducción de la velocidad que los cambios en la cadencia (en acuerdo con la literatura clínica de Pirker [45]), así como un aumento en el tiempo pasado en la fase de doble apoyo. Estos cambios en la marcha pueden atribuirse al proceso normal de envejecimiento. Sin embargo, es esencial destacar que la velocidad de la marcha en adultos mayores es un indicador relevante de su salud general y su supervivencia.

La Tabla 4.2 presenta las características de los sujetos seleccionados. Según la Organización Mundial de la Salud (OMS), los sujetos se clasifican en las siguientes categorías: “niños” para individuos de 0 a 17 años, “adultos jóvenes” para aquellos entre 18 y 65 años, “adultos de mediana edad” para individuos de 66 a 79 años, “ancianos” para aquellos entre 80 y 99 años, y “ancianos más ancianos” para individuos mayores de 100 años [6].

4.3.2. Preparación de datos

En la configuración original de Wang et al., se utilizaron todos los datos de las IMU, pero nuestro DAS solo proporciona un punto de datos por paso de tiempo, correspondiente al ángulo de la rodilla. Por lo tanto, es crucial preparar adecuadamente nuestros datos (ver Figura 4.12). En primer lugar, se eliminan los datos del sensor FSR (Figura 4.13). Luego, los eventos de

Tabla 4.2: Características de los sujetos. En el experimento participaron cuatro sujetos de sexo masculino y seis de sexo femenino.

| Sujeto ID | Sexo | Edad | Altura | Peso |
|-----------|------|------|--------|------|
| 1 | F | 50 | 1.6 | 67.3 |
| 2 | M | 49 | 1.74 | 76.2 |
| 3 | M | 80 | 1.69 | 71.4 |
| 4 | M | 68 | 1.71 | 72.4 |
| 5 | F | 45 | 1.58 | 65.9 |
| 6 | F | 22 | 1.64 | 70 |
| 7 | M | 36 | 1.6 | 60 |
| 8 | M | 70 | 1.7 | 65.3 |
| 9 | M | 49 | 1.71 | 69.3 |
| 10 | F | 38 | 1.68 | 68.6 |

HS se marcan manualmente en cada paso temporal en el que se puede inferir un evento de HS a partir del pico del sensor FSR (Figura 4.14); esta es la verdad básica para la salida del modelo, utilizada para el entrenamiento y la validación.

En la Figura 4.15, se presenta un ejemplo de la aplicación del método de Wang a nuestros datos. A veces, el modelo predice erróneamente dos eventos de HS en rápida sucesión (Figura 4.16 y 4.17), lo que resulta en falsos positivos adicionales. Este problema se abordó eliminando los vecinos más cercanos del pulso principal. Esto condujo a una mejora en las predicciones, logrando un retraso medio de detección de 48 ms como se puede apreciar en la Figura 4.18




Figura 4.12: Señal adquirida de DAS, con impulsos FSR.

Flujo de datos para entrenar un modelo LSTM para predecir eventos de HS, utilizando nuestra metodología. Primero, se adquiere una señal del DAS (a), que incluye eventos de HS detectados por el FSR, visibles como picos. Los picos se eliminan de la señal original (b) y se procesan manualmente en pulsos de 0-1, señalando los eventos de HS (c). El LSTM aprende a predecir




Figura 4.13: Datos sin impulsos FSR.




Figura 4.14: Eventos HS generados manualmente a partir de los pulsos del FSR.




Figura 4.15: Predicción de eventos HS

los eventos de HS (d).

4.3.3. Evaluación del rendimiento

Siguiendo a Wang et al. [67], medimos el rendimiento del modelo utilizando el Valor Predictivo Positivo (VPP):




Figura 4.16: predicción (primer pulso naranja) y predicciones dobles (otros dos pulsos naranjas)




Figura 4.17: Eventos detectados en la marcha humana




Figura 4.18: Corrección de sucesos duplicados mediante la eliminación de vecinos cercanos

$$PPV(\%) = \frac{n}{N} \times 100(\%) \tag{4.9}$$

Donde N es el número total de pasos en la entrada y n representa el número de eventos HS detectados correctamente por el modelo.

En un primer experimento, los datos de la marcha se separaron en dos




Figura 4.19: Entrenamiento con el subconjunto de mujeres: PPV para nuestro modelo (PPV-Nuestro) y el de Wang (PPV-W) en mujeres.




Figura 4.20: Entrenamiento con el subconjunto de hombres: PPV para nuestro modelo (PPV-Nuestro) y el de Wang (PPV-W) en hombres.

subconjuntos, uno para hombres y otro para mujeres. Para cada subconjunto se entrenaron dos modelos, uno utilizando nuestra metodología, y el otro utilizando la metodología de Wang et al. De esta manera, podemos comparar el rendimiento de ambos modelos para predecir eventos de HS. Los resultados se muestran en las Figuras 4.19 y 4.20 para los subconjuntos de mujeres y hombres, respectivamente. En ambas figuras, PPV-W y PPV-Our representan los resultados de rendimiento del modelo de Wang et al. y el nuestro, respectivamente. Además, en ambas figuras, los valores de rendimiento se agrupan por sujeto, sexo y pierna izquierda/derecha. Por ejemplo, la etiqueta 6FL en la Figura 4.19 marca los valores de rendimiento de ambos modelos para la pierna izquierda del sexto sujeto (de la Tabla 4.2), y 6FR para la pierna derecha del mismo sujeto.




Figura 4.21: Entrenamiento con todos los datos: PPV para nuestro modelo (PPV-Nuestro) y el de Wang (PPV-W) en mujeres.




Figura 4.22: Entrenamiento con todos los datos: PPV para nuestro modelo (PPV-Nuestro) y el de Wang (PPV-W) en hombres.

Tanto en la Figura 4.19 como en la 4.20, los resultados del modelo de Wang et al. son muy buenos, detectando todos los eventos de HS de la pierna izquierda de todos los sujetos, pero se observan tasas de detección más bajas para la pierna derecha en muchos casos; esto coincide con la sugerencia de utilizar un modelo diferente para cada pierna de Wang et al. Cuantitativamente, el modelo de Wang et al. alcanza una tasa de detección de eventos de HS del 90.34 % en mujeres y del 76.44 % en hombres, mientras que nuestro método alcanza el 97.61 % y el 94.39 %, respectivamente.

En un segundo experimento, se agruparon todos los datos de la marcha de mujeres y hombres en un único conjunto de datos para entrenar nuestro modelo y el modelo de Wang et al, y los resultados (Figura 4.21 y 4.22) se probaron de nuevo por separado para mujeres y hombres. Para los hombres,

ambos modelos generan casi los mismos resultados que en el experimento anterior (entrenando modelos diferentes para mujeres y hombres), con Wang et al. logrando buenos resultados para las piernas izquierdas pero no para las derechas (detectando el 76.44 % de los eventos de HS), y nuestro modelo funcionando para todas las piernas (detectando el 95.23 % de los eventos de HS). En el caso de las mujeres, sin embargo, nuestro modelo detecta el 98.75 % de todos los eventos de HS, frente al 77.39 % de Wang et al., por lo que nuestro modelo supera significativamente a Wang et al. para este caso de este experimento.

4.4. Conclusiones

Este trabajo ha desarrollado un modelo cinemático mediante el uso de algoritmos de Aprendizaje Profundo (DP) para detectar el evento HS. La identificación de este evento implica una reducción en la dependencia de sensores, ya que en nuestro caso hemos eliminado la necesidad del sensor FSR, el cual anteriormente contribuía a predecir el evento HS y formaba parte de nuestro sistema DAS junto con dos sensores IMU. Es importante destacar que los experimentos se llevaron a cabo en terreno plano y sin obstáculos, con el propósito de obtener un modelo más representativo de situaciones cotidianas.

La adquisición del modelo de marcha de un paciente puede ser crucial para los especialistas, ya que facilita la cuantificación mediante la comparación con un modelo cinemático estándar, permitiendo así evaluar las alteraciones en las fases de la marcha y medir el progreso durante el proceso de rehabilitación. Nuestro enfoque ha aplicado métodos de Aprendizaje Profundo, como las Redes Neuronales Profundas, RNN y LSTM, siendo las DNN las que han demostrado proporcionar los resultados más sólidos.

Este modelo ha logrado detectar eventos tanto en la marcha de hombres como de mujeres, abarcando un rango de edad de 18 a 80 años y utilizando un único modelo. Al comparar nuestro método con otros estudios de investigación, hemos obtenido una tasa de detección promedio del 96.64 %, con un retraso promedio de detección de aproximadamente 20 ms. En contraste, la investigación que utilizó otro método implementado en nuestros datos presentó una tasa de detección promedio del 78.82 %, con un retraso promedio de detección de aproximadamente 40 ms.



UNIVERSIDAD
DE MÁLAGA

Parte III

Modelado de la Marcha Humana



UNIVERSIDAD
DE MÁLAGA

Capítulo 5

Modelado para reconocimiento de actividades

Inteligencia es la habilidad de adaptarse a los cambios.

Stephen Hawking

RESUMEN: El monitoreo remoto de la salud juega un papel significativo en áreas de investigación relacionadas con la medicina, la neurología, la rehabilitación y los sistemas robóticos. Estas aplicaciones incluyen el Reconocimiento de Actividad Humana (HAR) utilizando sensores portátiles, procesamiento de señales, métodos matemáticos y aprendizaje automático para mejorar la precisión de los sistemas de monitoreo remoto de la salud. Para mejorar la detección y precisión del reconocimiento de actividad humana, creamos un método novedoso para reducir las complejidades de la extracción de características utilizando el conjunto de datos HuGaDB. Nuestro modelo extrae espectros de potencia; debido a la alta dimensionalidad de las características, se utilizan técnicas de ventanas deslizantes para determinar automáticamente el ancho de banda de frecuencia, donde un algoritmo QRS mejorado selecciona la primera amplitud del espectro dominante. Además, el algoritmo de ancho de banda se ha utilizado para reducir la dimensionalidad de los datos, eliminar dimensiones redundantes y mejorar la extracción de características. Hemos considerado clasificadores de aprendizaje automático ampliamente utilizados. Nuestro método propuesto fue evaluado utilizando el espectro de ángulos del acelerómetro instalado en seis partes del cuerpo y luego reduciendo el ancho de banda para conocer la evolución.

5.1. Introducción

En secciones anteriores se ha resaltado la importancia de la marcha humana. Dado que las articulaciones humanas desempeñan un papel fundamental en este proceso, el análisis de la marcha se vuelve crucial para estudiar tanto la cinética como la cinemática [51, 57]. Además, la marcha tiene una amplia variedad de aplicaciones en diversos campos, incluyendo la neurología para el monitoreo de síntomas neurológicos [20], así como en la rehabilitación, el seguimiento y la fisioterapia para la detección de trastornos de la marcha [11, 31].

El seguimiento de la actividad física mediante dispositivos portátiles ha experimentado un aumento significativo en los últimos tiempos, gracias al avance de las tecnologías de sensores, incluyendo los sensores de fusión multimodal. Estos dispositivos son especialmente beneficiosos para personas vulnerables, ya que les ayudan a mantener o mejorar su calidad de vida individual y social mediante el seguimiento de su actividad física [25]. El desarrollo de sistemas automáticos de información y métodos mejorados para analizar biosignos con inteligencia artificial en este campo representa una forma de contribuir a una atención médica más eficiente.

Los dispositivos utilizados para la adquisición de señales corporales se pueden clasificar en tres enfoques principales: sensores no portátiles (NWS), sensores portátiles (WS) y sistemas híbridos [57]. Sin embargo, los sensores portátiles son los más comúnmente utilizados, debido a su bajo costo, tamaño reducido y alta precisión. Estos sensores se colocan en el cuerpo para recopilar información biosenal durante las actividades diarias. Entre los sensores portátiles se incluyen los de fuerza, acelerómetros, giróscopos, extensómetros, inclinómetros, goniómetros, marcadores activos, electromiografía, entre otros. Para optimizar las funcionalidades de tales sensores, como los acelerómetros, giróscopos y magnetómetros, se fusionan en una sola unidad conocida como Unidades de Medición Inercial (IMUs) con tecnologías de sensores de fusión multimodal.

Las investigaciones exhaustivas han empleado sensores inerciales portátiles y han contribuido significativamente al desarrollo de aplicaciones originales de Reconocimiento de Actividad Humana (HAR). Estas aplicaciones abarcan una amplia gama de áreas, desde la rehabilitación de la salud hasta la asistencia al bienestar, tal como lo describe Nait et al. [40]. También incluyen aplicaciones en hogares inteligentes y sistemas de retroalimentación biológica, según la investigación de Gochoo et al. [25]. Además, se han explorado aspectos como el análisis de la marcha por Allseits y Zilani et al. [3, 76], el estudio de la simetría del movimiento por Proch et al. [49], y el monitoreo de actividades humanas por Ebara et al. [22, 66]. Todas estas aplicaciones requieren un monitoreo y seguimiento continuo, como se ha detallado en investigaciones previas realizadas por Castillejo, Chatterjee, Gravina, Uddin y

Fortino et al. [13, 15, 27, 64, 23].

Los algoritmos de extracción y selección de características tienen como objetivo clasificar las características pertinentes o suprimir la información redundante para aumentar el reconocimiento de la actividad de manera precisa y eficiente. Estas características relevantes se basan comúnmente en análisis de dominio de tiempo, ondículas y estadísticas, utilizando varios sensores IMU instalados en el cuerpo [7].

El espectro de frecuencia de los acelerómetros ha sido útil para los investigadores en diversas aplicaciones, como la predicción de vibraciones en estructuras de edificios, como se ilustra en el estudio de Beltrán et al. [9], o en el caso de aplicaciones relacionadas con turbinas, como se menciona en el trabajo de Kuo et al. [34]. Además, este análisis ha permitido reconocer patrones en la ruta de carrera de los perros, tal como se evidencia en la investigación de Hayati et al. [29].

Se requieren técnicas de selección para identificar las características más relevantes en los conjuntos de datos, con el objetivo de simplificar los modelos aprendidos, reducir la complejidad computacional y mejorar la eficiencia del modelo en tareas de reconocimiento. El empleo de sensores IMU industriales costosos y la extracción de características más complejas, como la entropía, como se utiliza en los estudios de Guyen et al. [41, 44], o medidas de frecuencia, como se describe en las investigaciones de Caliandro y Uddin et al. [12, 64], han mostrado resultados prometedores.

En esta sección, proponemos una nueva metodología basada en el dominio de la frecuencia y la reducción del ancho de banda de las señales de acelerómetros IMU para aplicaciones de Reconocimiento de Actividad Humana (HAR). Nuestro objetivo principal es analizar la cantidad mínima de características necesarias para lograr un buen rendimiento en el entrenamiento del modelo, al mismo tiempo que se reduce el tiempo computacional del procesamiento de señales y la clasificación. Con este propósito, presentamos una nueva metodología de preprocesamiento de señales basada en el análisis del dominio de la frecuencia e incorporamos transformadas funcionales para reducir la complejidad computacional debido a la alta dimensionalidad de las características. Nos enfocamos exclusivamente en las señales de acelerómetros, dado que son la característica más relevante para distinguir entre actividades. Sin embargo, también buscamos demostrar la eficacia de nuestra propuesta con menos información, lo cual podría ser útil en tratamientos donde se requiere la implantación de sensores simples. Nuestro método propuesto se aplica con éxito a un conjunto de datos de referencia público llamado Base de Datos de Marcha Humana (HuGaDB) para su evaluación de rendimiento y además en nuestros datos que fueron adquiridos por el sistema DAS.

5.2. Trabajos relacionados

Los sensores portátiles (WS) se han vuelto comunes en avances recientes, ya que los investigadores han logrado implementar dispositivos portátiles con éxito para monitorear los comportamientos de locomoción personal y reconocer la actividad humana. El WS más comúnmente utilizado incorpora un acelerómetro y un giroscopio en una unidad móvil inercial portátil (IMU). Otro tipo de WS, basado en la corriente eléctrica asociada con acciones musculares, también se emplea en combinación con IMUs para HAR [7]. Estos WS, conocidos como electromiografía (EMG), registran las señales mioeléctricas generadas por acciones musculares, lo que resalta su importancia en el reconocimiento de actividad. Un estudio sobre la fusión de sensores EMG e IMU para HAR se presenta en [7], mostrando el potencial de incorporar señales EMG en el reconocimiento de actividad.

En [25], se presenta un sistema de seguimiento de la locomoción personal en tiempo real, utilizando tres sensores inerciales ubicados en diferentes partes del cuerpo (muñeca, muslo y pecho). Los datos fueron procesados utilizando filtros gaussianos y de fase cero. Además, se implementó una técnica jerárquica basada en características para extraer características utilizando métodos de optimización de descenso de gradiente estocástico, logrando una tasa de precisión del 92.50 % en sus experimentos utilizando el conjunto de datos HuGaDB. Por otro lado, en [20], se propone una técnica para extraer características utilizando Transformadas Discretas de Fourier para estimar la potencia media en bandas de frecuencia seleccionadas para el reconocimiento de la marcha atáxica. Los datos acelerométricos fueron adquiridos por 31 sensores sincronizados en el tiempo (sistema de percepción neuronal) ubicados en diferentes partes del cuerpo. Se emplearon diversos clasificadores para la evaluación, como máquinas de vectores de soporte, Bayesianos, vecinos más cercanos y métodos de redes neuronales, obteniendo la mayor precisión del 98.5 %. El estudio involucró a 13 individuos normales y 12 con ataxia, y se realizó en un entorno clínico. Además, se aplicaron técnicas de Aprendizaje Profundo para predecir caídas en adultos mayores [40]. Se recopiló información sobre factores de riesgo de caídas en personas mayores utilizando WS (acelerómetros), cuestionarios y pruebas físicas. El conjunto de datos consistía en 296 adultos mayores que llevaban un acelerómetro triaxial en la parte baja de la espalda durante una semana y los siguientes seis meses, durante los cuales se obtuvieron incidencias y descripciones de caídas. Los investigadores utilizaron los datos brutos del acelerómetro (sin realizar el paso de preprocesamiento) como entrada a un clasificador LSTM, logrando una reducción del tiempo y un AUC (Área Bajo la Curva) de 0.75.

La precisión y eficiencia en el reconocimiento de actividades requieren seleccionar las características más relevantes o eliminar la información redundante, siendo este el propósito de los algoritmos de extracción y selección de

características. Estas características relevantes se extraen utilizando múltiples sensores corporales IMU y luego se procesan en función de las ondículas, el dominio temporal y el análisis estadístico [7]. El espectro de frecuencia de los acelerómetros ha ayudado a los investigadores a predecir vibraciones en turbinas [34] o estructuras de construcción [9]. Además, las técnicas de selección deben aplicarse a conjuntos de datos para identificar las características más relevantes y, por lo tanto, simplificar los modelos aprendidos [59], mejorar la eficiencia del modelo, reducir la complejidad computacional en aplicaciones reales y mejorar las precisiones de reconocimiento. Otros estudios muestran resultados prometedores al utilizar sensores más costosos y extraer características más complejas basadas en medidas de frecuencia [12, 64, 60] y entropía [41, 44].

En resumen, la mayoría de los trabajos concluyen que cuantos más sensores y características extraídas de los datos, mayor es la precisión del algoritmo de clasificación computacional. Sin embargo, los sensores instalados en el cuerpo humano producen menos comodidad para el paciente (ergonomía), dificultan más la realización de actividades humanas, aumentan el ruido y requieren más tiempo para procesar (pre/post) los datos y para analizar las actividades en tiempo real [5].

5.3. Modelado para reconocimiento de actividades

Esta sección presenta las técnicas matemáticas que proponemos para clasificar las señales de marcha humana. La Figura 5.1 ilustra el flujo de trabajo del método propuesto. El primer paso es recopilar los datos brutos para preprocesarlos, eliminando el ruido y las señales no deseadas, luego extraer características relevantes y, finalmente, entrenar y probar un clasificador de actividad humana.

Se ha propuesto la utilización de la señal cruda del acelerómetro. Este enfoque ha sido empleado en otros estudios, como el de Nait et al. [40], donde se obtuvieron resultados satisfactorios en términos de tiempo de procesamiento, o en la investigación realizada por Tunca et al. [63], donde podría existir la posibilidad de perder matices involuntariamente al extraer los parámetros de las características crudas. Nuestro objetivo es desarrollar un clasificador utilizando menos datos y reduciendo el tiempo de procesamiento. Por ejemplo, la Figura 5.2a ilustra una señal cruda que contiene dos actividades, mientras que la Figura 5.2b muestra únicamente la señal correspondiente a la actividad de caminar desde la espinilla derecha. Al igual que en el estudio de Nait et al. [40], utilizamos directamente los datos de aceleración crudos como entrada para analizar y transformar la señal.

La extracción de características es una técnica comúnmente utilizada para limpiar los datos y enfocarse solo en las características relevantes al redu-

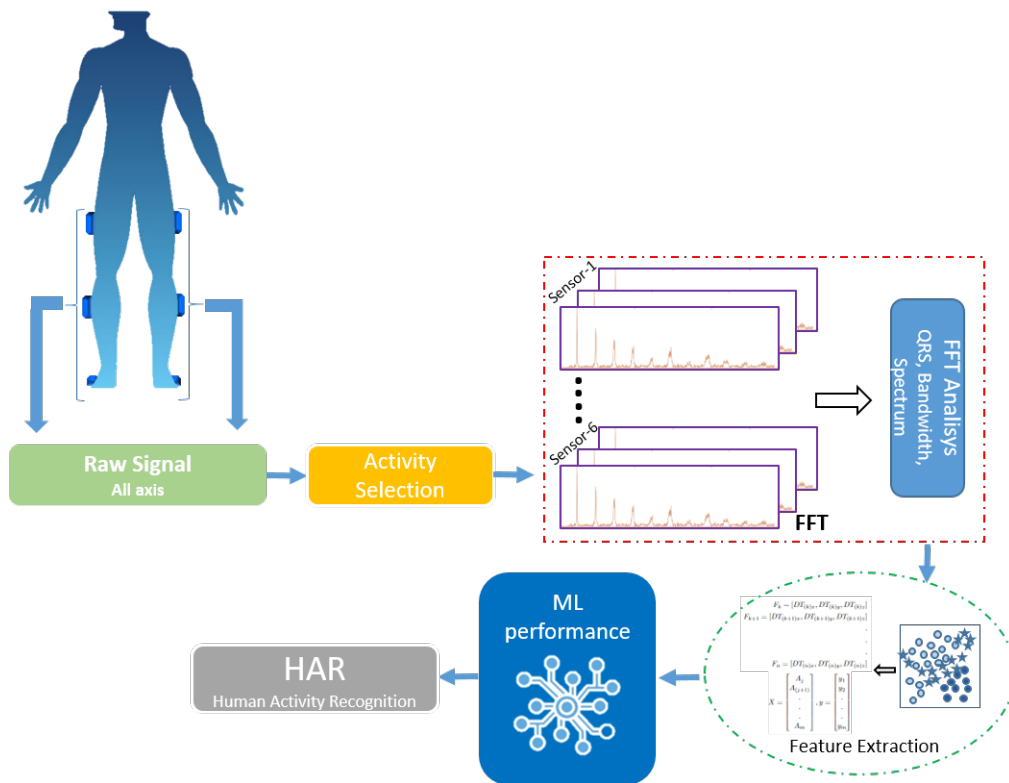


Figura 5.1: Diagrama de flujo de la metodología propuesta para detectar actividades humanas.[60]

cir la dimensionalidad. Varios métodos propuestos en la literatura se centran en extraer características de la señal, como aquellos basados en el dominio tiempo-frecuencia, y muchas otras técnicas que permiten la reducción de la dimensionalidad de los datos [60].

En este trabajo, se instalaron un total de seis sensores en diferentes partes (pies, espinillas y muslos) de las piernas, cada uno conteniendo un acelerómetro de 3 ejes X, Y y Z (18 señales en total). Toda la información de las señales se convierte al dominio de la frecuencia utilizando la Transformada Rápida de Fourier (FFT) para reducir el tamaño, eliminar datos inútiles y facilitar el proceso de entrenamiento de los clasificadores.

5.3.1. Procesamiento de señal

Existen métodos para la extracción de características basados en el tiempo, la frecuencia y el dominio tiempo-frecuencia, que suelen aplicarse a los datos crudos. En este trabajo, proponemos un conjunto de pasos de procesamiento de señales para obtener características relevantes, que se resumen en el Algoritmo 2.




Figura 5.2: Señal bruta del acelerómetro del eje X de la tibia derecha: a) datos brutos completos, b) submuestra de marcha [60].

Algorithm 2 Extracción de características de la señal del acelerómetro

Input: acc = datos del acelerómetro (x,y,z) para cada parte del cuerpo,

f_{c2} = máxima frecuencia de ancho de banda

Salida: Vector de características del ancho de banda de frecuencias seleccionado

Method: $IMU_features(x,y,x)$

```

1: raw_data ← acc
2: while iteration=1,2,...,Npatients do
3:   filtered_data ← Highpass_filter(raw_data)
4:   angle_data ← Resultant_angle(filtered_data)
5:   fft_data ← ExtractFFT(angle_data)
6:   norm_data ← Normalize(fft_data)
7:   extrap_data ← Freq_norm(norm_data)
8:   fc1 ← QRS(extrap_data)
9:   feature_vector ← get(extrap_data,fc1,fc2)
10: end while
11: return: feature_vector

```

5.3.1.1. Filtrado de ruido

En primer lugar, el filtro Chebyshev pasaaltos se encarga de filtrar el ruido de corriente continua (CC). La aproximación de la respuesta de ganancia en función de la frecuencia angular w se especifica en la ecuación (5.1). Se im-

plementa un filtro pasaaltos (Highpass) de octavo orden, con una frecuencia de corte de 0.4 Hz y una atenuación de 80.

$$G_n(\omega) = \frac{1}{\sqrt{1 + \frac{1}{\varepsilon^2 T_n^2(\omega_0/\omega)}}} \quad (5.1)$$

donde ε es el factor de ondulación, ω_0 es la frecuencia de corte y T_n es un polinomio de Chebyshev de orden n .

Como ejemplo, en la Figura 5.3a, podemos ver el espectro de la señal con un pulso en 0Hz (ruido de corriente continua), y el filtro pasa alto elimina el ruido (Figura 5.3b).

5.3.1.2. Ángulo Resultante

La determinación del número de características es una etapa crucial en la selección de características, ya que la información contenida en la matriz de características influirá en la capacidad de discriminación de las características profundas. Si la señal es considerablemente extensa, entonces una técnica de reducción de datos resulta útil para simplificar la entrada, al tiempo que se preservan las propiedades de la señal. En estos casos, además de enfrentarse a un análisis de datos complicado, el método propuesto puede resultar incompatible con el conjunto de datos, y el clasificador propuesto puede tener dificultades para generalizarse a un conjunto de datos limitado.

Como se mencionó al principio de la sección, contamos con 18 señales, correspondientes a los 3 ejes de cada uno de los 6 sensores. Una práctica común es crear el vector de características F^k , que contiene la señal filtrada para los 3 ejes:

$$F^k = [f_X^k, f_Y^k, f_Z^k], \quad k = 1, \dots, 6. \quad (5.2)$$

No obstante, existe una gran cantidad de información redundante que ralentiza el entrenamiento del modelo de clasificación. Por esta razón, calculamos el ángulo resultante de las fuerzas específicas del acelerómetro como lo realiza la investigación de Tjhai et. al. [62]:

$$Angle_X = \arctan \left(\sqrt{\frac{f_X^2}{f_Y^2 + f_Z^2}} \right) \quad (5.3)$$

Donde f_X, f_Y, f_Z son las fuerzas de la gravedad, es decir, las señales del acelerómetro. f_X es en el numerador la señal del eje X .

Aplicando la ecuación (5.3) a nuestras señales filtradas y aplicando la ecuación (5.2), reducimos el tamaño del vector de características de cada acelerómetro corporal.

$$F^k = Angle_X^k \quad (5.4)$$

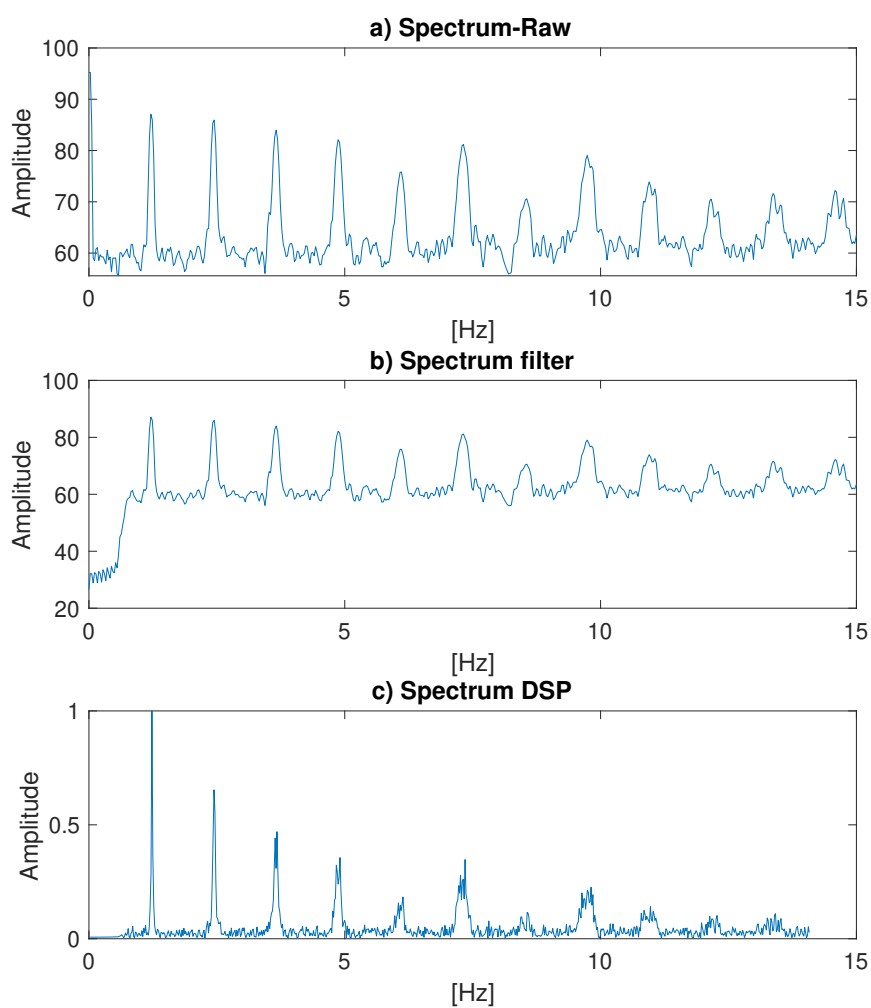


Figura 5.3: Representación de la señal en el dominio de la frecuencia del acelerómetro del eje X en el pie derecho durante la actividad de caminar. a) Datos en bruto. b) Espectro después del filtro de paso de banda. c) Espectro después de la transformada de Fourier y normalización[60].

5.3.1.3. Análisis del dominio de frecuencia

En esta propuesta, se emplea la Transformada Rápida de Fourier (FFT) para convertir las señales recibidas al dominio de la frecuencia. En particular, se aplica la Transformada Discreta de Fourier (DFT), la cual fue utilizada por Taylan, Kang y Addamek et. al [56, 32, 1] para mejorar la complejidad computacional. El contenido de frecuencia de la señal de entrada x se extrae mediante la siguiente transformación:

$$X(k) = \sum_{n=0}^{N-1} x_n \exp \left[-i2\pi \frac{nk}{N} \right] \quad (5.5)$$

donde $X = FFT(x)$, x_n es el n elemento de la señal de entrada, k es la frecuencia de muestreo, y N es la longitud de la transformación.

El rendimiento de la FFT depende de la longitud de la señal, y para mejorar su velocidad, se emplea el algoritmo de Cooley/Tukey a través de la función `fft` de Matlab, que aprovecha las simetrías para descomponer una DFT grande en DFT más pequeñas. Este proceso ayuda a reducir la complejidad computacional de $O(N^2)$ a $O(N \log N)$, mejorando la velocidad comenta Kang et. al. [32]. En nuestra investigación, se utilizó la señal IMU completa para la operación de FFT y se transformó por separado para cada paciente.

5.3.1.4. Normalización del Espectro de Potencia y Ancho de Banda

Después de aplicar la FFT, la señal se normaliza en el rango $[0,1]$ aplicando la ecuación 5.6. La Figura 5.3c muestra la señal resultante.

$$X_{power_norm} = \frac{|X_{fft}|}{\max(|X_{fft}|)} \quad (5.6)$$

De igual manera, la señal se normalizó en el espectro de potencia y es conveniente igualar la señal en el eje de frecuencia. De esta manera, todas las muestras caen en el espectro de potencia, lo que ayuda al clasificador a tener un entrenamiento homogéneo. Para lograr esto, se determina la frecuencia máxima para todas las muestras de datos y luego se calcula la extrapolación lineal:

$$\begin{aligned} \mathcal{F}_{MAX} &= \max(\{\mathcal{F}_j, \quad j = 1, \dots, M\}) \\ X_{freq_norm} &= \text{linear_extrap}(X_{power_norm}, \mathcal{F}_{MAX}) \end{aligned} \quad (5.7)$$

donde \mathcal{F} representa el conjunto de valores de frecuencia de una muestra, y M el número total de muestras.

Las figuras 5.4, 5.5 y 5.6 presentan un análisis espectral detallado, mostrando la evolución de las componentes espectrales, es decir, la potencia




Figura 5.4: Espectro del pie derecho [60].




Figura 5.5: Espectro de la tibia derecha [60].




Figura 5.6: Espectro del muslo derecho [60].

relativa a lo largo de la frecuencia de cada eje del acelerómetro correspondiente a cada sensor instalado en las partes inferiores de la pierna derecha. De manera similar, se puede observar el análisis espectral correspondiente a las partes de la pierna izquierda en las Figuras 5.7, 5.8 y 5.9.

5.3.1.5. Detección de la Potencia Relativa Media del Complejo QRS

Como se expuso en [56], las amplitudes de frecuencia dominante primera y segunda contienen la mayor parte de la información sobre la señal, por lo que proponemos un método para extraer esas amplitudes basadas en complejos QRS y usarlas como entradas de los modelos de clasificación.

El elemento clave para extraer estas amplitudes de frecuencia es establecer un umbral de tolerancia apropiado, que es utilizado por el algoritmo QRS [43]. Esta técnica se utiliza en el análisis espectral para reconocer complejos QRS, reduciendo las detecciones falsas causadas por interferencias en las señales de ECG. En la Figura 5.10 se muestra un ejemplo de la detección de QRS, donde R es el pico del espectro principal, Q es el inicio de la señal de pico, y S es el final de la señal de pico, que será innecesario para nuestra aplicación, como se explica más adelante.

Sin embargo, la detección de picos es un paso muy crítico ya que se puede perder información si no se establece correctamente un umbral adecuado. Por




Figura 5.7: Espectro del pie izquierdo [60].




Figura 5.8: Espectro de la tibia izquierda [60].




Figura 5.9: Espectro del muslo izquierdo [60].




Figura 5.10: Ejemplo del cálculo del complejo QRS en el primer espectro [60].

ejemplo, en [38], se presenta una versión modificada del algoritmo QRS con un umbral adaptativo, definiendo dos tipos de picos: señal y ruido. Si el valor de un pico es mayor que el umbral, se marca como un complejo QRS, y luego se actualiza el pico de la señal.

Esta solución tiene un problema con el ruido, ya que detecta algunos espectros como ruido y la amplitud de la señal no es constante como en la señal de ECG. Por ejemplo, un umbral de 0.257, cuando se calcula con los datos en la Figura 5.11, pierde información de otros espectros.

El algoritmo de Pan y Tompkins inspira nuestra propuesta para detectar el complejo QRS [43]. Primero, una diferenciación proporciona información de pendiente compleja, y luego se aplica una función de cuadratura de amplitud y un integrador de ventana móvil. Los siguientes párrafos describirán el proceso en detalle:

1. Diferenciación. Tras el filtrado y la normalización, la señal se diferencia del siguiente modo:

$$y(nT) = \frac{1}{8}[-x(nT-2T)-2x(nT-T)+2x(nT+T)+x(nT+2T)] \quad (5.8)$$

donde T es el período de muestreo.

2. Cuadratura. Amplifica la pendiente de la respuesta en frecuencia.

$$y(nT) = [x(nT)]^2 \quad (5.9)$$

3. Integración de ventanas móviles. Para obtener información sobre las características de la forma de onda:

$$y(nT) = \frac{1}{N}[x(nT-(N-1)T)+x(nT-(N-2)T)+\dots+x(nT)] \quad (5.10)$$

Después de eso, la señal de Potencia Relativa Media se utiliza para inicializar el umbral. Esta medida tiene como objetivo variar el ancho de banda de nuestra señal espectral, de modo que solo se considere la información de señal deseada. La ecuación (5.11) calcula la potencia media en una ventana seleccionada por las frecuencias deseadas:

$$P_w = \int_{-f}^f |X(f)|^2 df \quad (5.11)$$

Como se muestra en [20], cada una de las características espectrales seleccionadas de un segmento de señal de N muestras se evalúa y se divide por la primera mitad de la señal ($N/2$ muestras) para mantener la información más significativa. La ecuación (5.12) calcula la Potencia Relativa Media discreta en una banda de frecuencia especificada:

$$MP_{rel} = \frac{\sum_{k \in \phi} |X(k)|^2}{\sum_{k=0}^{N/2} |X(k)|^2} \quad (5.12)$$

donde ϕ es el conjunto de índices para los cuales los valores de frecuencia $f_k = \frac{k}{N} f_s \in [f_{c1}, f_{c2}]$. En el caso dado, estudiamos las características espectrales del acelerómetro en el rango de [0 %, 100 %].

Por lo tanto, se utiliza MP_{rel} como picos de señal en lugar de utilizar tanto el pico de la forma de onda de integración como el pico de señal filtrada de ruido para la inicialización del umbral, como en [43].

$$\begin{aligned} M_{VAL} &= MP_{rel}(signal) \\ SPKI &= 0,13 * M_{VAL} \\ THRESHOLD &= 0,25 * SPKI + 0,75 * NPKI \end{aligned} \quad (5.13)$$

donde *signal* se refiere a la forma de onda de integración y la señal filtrada, respectivamente; *SPKI* es la estimación del pico de señal, *NPKI* es el pico de ruido, y *THRESHOLD* es el umbral aplicado.

El resto del procedimiento de detección sigue el algoritmo QRS original. Una vez que se detectan los picos, se establece la frecuencia inicial f_{c1} y el resto del ancho de banda es la señal extraída para ser utilizada en el siguiente paso:

$$f_{c1} = Q \quad (5.14)$$

donde Q es el elemento Q del complejo QRS del primer pico. Como ejemplo, en la Figura 5.10, el punto Q se encuentra automáticamente mediante la metodología propuesta y se establece el valor de f_{c1} . Por otro lado, f_{c2} definirá el último punto de la frecuencia de ancho de banda. La Figura 5.11 muestra un f_{c2} alcanzando un ancho de banda del 100 %.

5.3.2. Análisis de ancho de banda deslizante

El rango de frecuencias seleccionado se varía para reducir el número de características y sensores. El ancho de banda se sitúa dentro del intervalo f_{c1} a f_{c2} de cada análisis de frecuencia, como se muestra en la Figura 5.11 y estos conjuntos se expresan en la ecuación (5.15):

$$BW = f_{c2} - f_{c1} \quad for \quad f_{c1} \leq f_{c2} \leq 100\% \quad (5.15)$$

Por lo tanto, los espectros de potencia analizados varían en función de la longitud de BW :

$$PS = [X(k)]_{\theta} \quad (5.16)$$

donde $\theta \in [f_{c1}, f_{c2}]$ es el conjunto de índices para los cuales los valores de frecuencia varían dentro del ancho de banda.




Figura 5.11: Ejemplo del ancho de banda seleccionado, donde $f_{c1} = Q$ y $f_{c2} = 100\%$ [60].

5.4. Resultados

5.4.1. Descripción de la Base de Datos

La Base de Datos de Marcha Humana [16] se utiliza comúnmente en la investigación de reconocimiento de actividad humana (HAR), reconocimiento de gestos (GR) y análisis de marcha (GA). Este conjunto de datos ha sido utilizado en muchos trabajos porque representan el movimiento inercial de una persona y ayudan a desarrollar modelos antes de instalarlos en sistemas de sensores portátiles. El conjunto de datos comprende 18 participantes sanos que se dividieron en dos grupos: 15 participantes para crear y validar el modelo y 3 participantes para probar el modelo. De esta manera, la información que los modelos de clasificación prueban será completamente independiente de la utilizada para el entrenamiento, asegurando una comparación justa.

En total, se colocaron seis sensores inerciales (IMU) (cada sensor IMU tiene un acelerómetro de tres ejes y un giroscopio de tres ejes) y sensores de electromiografía (sEMG) en los muslos, espinillas y pies derechos e izquierdos. El número total de señales recopiladas es de 38: 36 del sensor IMU y

dos del sensor sEMG. Esta base de datos contiene doce actividades: Caminar con ID (1), Correr con ID (2), Subir con ID (3), Bajar con ID (4), Sentarse con ID (5), Sentarse con ID (6), Levantarse con ID (7), Pararse con ID (8), Andar en bicicleta con ID (9), Subir en ascensor con ID (10), Bajar en ascensor con ID (11) y Sentarse en el coche con ID (12).

5.4.2. Experimento utilizado algoritmos clasificadores

El método propuesto se aplicó a los datos acelerométricos en bruto del conjunto de datos HuGaDB. Después del preprocesamiento espectral inicial, establecimos la frecuencia f_{c2} al 100 % para verificar el rendimiento de los clasificadores con el ancho de banda total. Para los experimentos, se emplearon modelos de clasificación de Análisis Discriminante (DA), Máquina de Vectores de Soporte (SVM) y Redes Neuronales (NN). El código se escribió en Matlab (R2021b). El método se aplicó en cada eje, recibiendo señales de las piernas derecha e izquierda.

Como se ha mencionado, el conjunto de datos contiene información sobre 6 sensores diferentes, resumidos en Tabla 5.1.

Tabla 5.1: Acelerómetros utilizado en el cuerpo [60].

| | Izquierda | | | Derecha | | |
|------|-----------|---------|-------|---------|---------|-------|
| Dato | Pier | Canilla | Muslo | Pie | Canilla | Muslo |
| k | 1 | 2 | 3 | 4 | 5 | 6 |

Para realizar los experimentos de clasificación, todas las señales de acelerómetro preprocesadas se concatenan en un vector de actividad.

$$A_j = \{F^k\}_j, \quad k = 1, \dots, 6. \quad (5.17)$$

donde j representa el número de actividades de muestra, los datos de entrenamiento comprenden un conjunto de señales para $N = 15$ personas que realizaron varias actividades. Estas actividades se identifican previamente en el conjunto de la señal y se separan en diferentes M muestras. El conjunto de muestras $\{A_j\}_{j=1, \dots, M}$ y sus respectivas etiquetas de clase verdaderas formarán los datos de entrenamiento. Tras el preprocesamiento del conjunto de datos, el número total de muestras de entrenamiento es de 152, de las que $M = 122$ (de 15 participantes) se utilizarán para el entrenamiento y 30 para las pruebas (de 3 participantes).

Primero, se comparó el rendimiento alcanzado utilizando el ancho de banda máximo. Se realizó una validación cruzada de 10 pliegues para entrenar los modelos y realizar una selección preliminar entre varios clasificadores, utilizando el 75 % de los datos para entrenamiento y el 25 % para pruebas (de 15 participantes, como se indica en la Sección 5.4.1). Después de eso, el conjunto de prueba no visto (de 3 participantes) se utilizó para calcular el

rendimiento real. Cada instancia está representada por el paciente, para un total de 18 pacientes dentro de cada actividad, lo que significa que cada clase mantiene la misma cantidad de instancias de clase tanto para los conjuntos de entrenamiento como para los de prueba.

Los resultados de los diferentes clasificadores se comparan en la Tabla 5.2. Además, comparamos nuestro rendimiento con un método de vanguardia que utilizó una configuración de sensor y datos similar a nuestros experimentos [25] para tener una comparación justa. No comparamos nuestro enfoque con otros trabajos publicados sobre una combinación de señales de sensor. Por lo tanto, nuestra metodología produjo una precisión del 95,10 % utilizando NN y del 91 % utilizando SVM, en comparación con el 5 % y el 4 % menos de precisión, respectivamente, obtenida por el método competidor. Además, nuestro método se aplicó con un clasificador de Análisis Discriminante, logrando una precisión del 95,5 %, siendo elegido como el mejor para nuestra propuesta. La metodología propuesta en [25] sigue siendo peor con una precisión del 92,5 %.

Tabla 5.2: Tabla de precisión de Experimentos utilizando HuGaDB y características de frecuencia[60]

| Método | DA (%) | SVM (%) | NN (%) |
|-----------------------|--------|---------|--------|
| Gochoo, M. et al [25] | - | 85,68 | 91,23 |
| Propuesto | 95,50 | 91,00 | 95,10 |

El resto de los experimentos se centrarán en modificar el ancho de banda para analizar el impacto de aplicar el método propuesto con menos información.

5.4.3. Análisis de Ancho de Banda

El objetivo de este análisis es reducir los datos de muestra (8022 características por muestra) utilizados para entrenar los clasificadores. Cada actividad contiene 56,35 muestras por segundo, y el tiempo de adquisición varía. Se estudia la potencia acelerométrica espectral en $[f_{c1}, f_{c2}]$, donde f_{c1} se detecta automáticamente y f_{c2} variará para el entrenamiento. Se ha estudiado la extensión del ancho de banda en estos tres clasificadores reduciendo el ancho de banda en un 10 % cada vez, partiendo del punto final del espectro, $f_{c2} = 100$ %.

Figura 5.12 resume la precisión obtenida para cada ancho de banda. Puede observarse que la precisión del clasificador DA no varía hasta un ancho de banda del 70 %. Además, se puede observar que el clasificador NN tiene una buena precisión en el rango de 90 % a 50 %, aunque disminuye lentamente cuando se acorta el ancho de banda. Por último, el clasificador SVM




Figura 5.12: Evolución de la precisión en diferentes anchos de banda[60].

presenta el peor rendimiento global, aunque es bastante robusto a la reducción de los datos de entrenamiento, teniendo incluso mejor rendimiento con sólo un 30 %-50 % del ancho de banda. De estos resultados podemos extraer que utilizar el 70 % del ancho de banda con el clasificador DA produce la misma precisión que si se utiliza el 100 % del ancho de banda. Por tanto, los datos pueden reducirse a 5615 características para mejorar el tiempo de entrenamiento de los clasificadores obteniendo los mismos resultados.

Las Figuras 5.13, 5.14 y 5.15 representan el comportamiento de los clasificadores al cambiar el ancho de banda para cada tipo de actividad. Cada uno de los clasificadores ha obtenido excelentes rendimientos para la mayoría de las actividades. Por ejemplo, caminar, subir las escaleras y subir con el ascensor sólo necesitaron un espectro primario en la ventana de 20 % de ancho de banda, independientemente del clasificador; sin embargo, otras actividades necesitan un ancho de banda más amplio para ser reconocidas. Sin embargo, para obtener un rendimiento general excelente, se necesitan más datos. El clasificador DA, mostrado en la Figura 5.13, puede reconocer perfectamente hasta 9 actividades con un ancho de banda del 70 %. SVM y NN (Figuras 5.14 y 5.15) reflejan rendimientos similares, excepto en el caso del ascensor y de bajar las escaleras. Sin embargo, mejoran el reconocimiento de la actividad de sentarse en el coche, alcanzando un 100 % de precisión con un 40 % y un 50 % de ancho de banda, respectivamente.

Centrándonos en el tipo de actividad, el ascensor es la más crítica. Es interesante ver que para la SVM es necesario el 60 % del ancho de banda




Figura 5.13: Análisis Discriminante para Clasificación (DA)[60].

para alcanzar el 80 % de precisión, pero para la NN es necesario el 70 % de los datos. El DA no puede detectar correctamente esta actividad, pero la acción de sentarse tiene una detección perfecta con sólo el 30 % del ancho de banda. Por otra parte, la carrera y la bicicleta son mejor clasificadas por la NN, lo que significa que funciona mejor con señales complejas.

5.4.4. Estudio de ablación con menos sensores

El objetivo de este análisis es reducir el número de características para entrenar el modelo clasificador. Cada actividad recopila 56.35 muestras por segundo y tiene un tiempo diferente para adquirir una señal. La precisión y la exactitud se estudian al reducir el número de sensores instalados en el cuerpo y al determinar qué parte del cuerpo es más significativa para detectar la actividad.

5.4.4.1. Experimento con pocos sensores

En este experimento, se evalúa el rendimiento del clasificador al disminuir el número de sensores instalados en el cuerpo. Inicialmente, tenemos seis sensores instalados en el pie derecho (RF), la tibia derecha (RS), el muslo derecho (RT), el pie izquierdo (LT), la tibia izquierda (LS) y el muslo izquierdo (LT). La Figura 5.16 indica la evolución de la precisión cuando eliminamos sensores, realizando el experimento de acuerdo con la siguiente configuración:

- Seis sensores (6s) = RF, RS, RT, LT, LS, LF.



Figura 5.14: Clasificación mediante Máquinas de Vectores de Soporte (SVM)[60].




Figura 5.15: Clasificación mediante Redes Neuronales (NN)[60].




Figura 5.16: Evolución de la precisión disminuyendo sensores [61]

- Cinco sensores (5s) = RS, RT, LT, LS, LF.
- Cuatro sensores (4s) = RT, LT, LS, LF.
- Tres sensores (3s) = LT, LS, LF.
- Dos sensores (2s) = LS, LF.

La precisión disminuye en un 1.7% si se entrena en una red neuronal con cuatro sensores (4s), lo que corresponde a reducir las características del conjunto de datos en aproximadamente un 40%. Si utilizamos el clasificador SVM con 4s; tiene una precisión del 88.5%; sin embargo, este clasificador con este número de sensores tiene excelentes precisiones si el investigador pretende utilizarlo para determinadas actividades.

Además, la precisión HAR para cada actividad se presenta en la Figura 5.17, 5.18, 5.19, 5.20, y 5.21. Además, los rendimientos específicos se evalúan disminuyendo el número de sensores en cada actividad. Las actividades mejor reconocidas son Caminar, Correr, Subir, Bajar, Estar de pie y Bicicleta, independientemente del número de sensores utilizados. Esto significa que la mitad de las 12 actividades son aptas para ser reconocidas con sólo 2 sensores. Por otro lado, las actividades que se ven más afectadas por la eliminación de sensores son las dos de Ascensor, seguidas de Sentado. No obstante, con 4 sensores la precisión sigue siendo suficientemente buena.

5.4.4.2. Impacto de la precisión al estudiar la posición de los sensores

La comparación entre la ubicación de los acelerómetros de los sensores en diferentes partes del cuerpo para HAR no ha recibido aún una atención




Figura 5.17: Precisión de actividades: Seis sensores [61]




Figura 5.18: Precisión de actividades: Cinco sensores [61]




Figura 5.19: Precisión de actividades: Cuatro sensores [61]




Figura 5.20: Precisión de actividades: Tres sensores [61]




Figura 5.21: Precisión de actividades: Dos sensores [61]

significativa en la literatura de investigación. Por lo tanto, en esta sección, proponemos estudiar el rendimiento de cada acelerómetro. La Tabla 5.3 indica las actividades del ID, y la Figura 5.22 muestra la ubicación de los sensores. Para los siguientes experimentos se utilizan tres modelos de clasificación: DA, SVM y NN.

Tabla 5.3: Identificación de actividades de los 18 participantes.

| ID | Activity |
|----|---|
| 1 | Caminar (Walking) |
| 2 | Correr (Running) |
| 3 | Subir (Going up) |
| 4 | Bajar (Going down) |
| 5 | Sentado (Sitting) |
| 6 | Sentarse (Sitting down) |
| 7 | Pararse (Standing up) |
| 8 | Parado (Standing) |
| 9 | Manejar Bicicleta (Bicycling) |
| 10 | Subir en el elevador (Up by elevator) |
| 11 | Bajar en el elevador (Down by elevator) |
| 12 | Sentado en el auto (Sitting in the car) |

En primer lugar, se comparan los sensores entre LT-LS y RT-RS (Figura 5.23, 5.24 y 5.25). La precisión media alcanza el 66.4% frente al 66.4% con




Figura 5.22: Ubicación de los sensores en las extremidades inferiores del cuerpo en el siguiente orden: pie derecho (PD), tibia derecha (ED), muslo derecho (MD), pie izquierdo (PI), tibia izquierda (EI) y muslo izquierdo (MI) [61]




Figura 5.23: Comparación de precisión utilizando el clasificador DA con los sensores instalados en la espinilla y el muslo en ambas piernas: LT-LS con RT-RS [61]

DA, el 78.7% frente al 68.9% con SVM y el 71.3% frente al 73.8% con NN. Como era de esperar, este experimento pretendía encontrar la similitud de precisión utilizando el mismo número de sensores en ambas piernas. El resultado obtenido tiene un error de 0%, 12% y 4%, respectivamente, para DA, SVM y NN; puede ser que cada persona tenga una pierna dominante diferente. Sin embargo, el desarrollo de nuestro método funcionaría para predecir una actividad utilizando una sola pierna.

Además, podemos apreciar la precisión para cada actividad en las Figuras 5.26, 5.27 y 5.28, donde se muestra la precisión de cada actividad en cada pierna. En este segundo experimento se comparan los sensores entre LT y LS y entre RT y RS. Este experimento se realiza para conocer la pata más significativa y también, para conocer el sensor que aporta más información.




Figura 5.24: Comparación de precisión utilizando el clasificador SVM con los sensores instalados en la espinilla y el muslo en ambas piernas: LT-LS con RT-RS [61]




Figura 5.25: Comparación de precisión utilizando el clasificador NN con los sensores instalados en la espinilla y el muslo en ambas piernas: LT-LS con RT-RS [61]

De igual manera estas figuras indica la comparación del sensor LT frente al LS, y la precisión LT para DA, SVM y NN es del 74.6 %, 82.0 % y 82.8 %. Además, la precisión LS es del 67.2 %, 70.5 % y 73 % para los clasificadores. Este resultado presenta que el sensor LT es más significativo.

Las Figuras 5.29, 5.30 y 5.31 muestran que RT es más eficaz con una precisión del 65.6 %, 78.7 %, y 71.3 % en comparación con el 63.9 %, 72.1 % y 68.9 % utilizando el sensor RS.

El experimento muestra que la pierna derecha tiene un poco más de precisión, y el sensor LT es también el más significativo.




Figura 5.26: Comparación de precisión del sensor instalado en una pierna: LT con LS, experimento con clasificador DA [61]




Figura 5.27: Comparación de precisión del sensor instalado en una pierna: LT con LS, experimento con clasificador SVM [61]




Figura 5.28: Comparación de precisión del sensor instalado en una pierna: LT con LS, experimento con clasificador NN [61]




Figura 5.29: Comparación de precisión del sensor instalado en una pierna: RT con RS, experimento con clasificador DA [61]




Figura 5.30: Comparación de precisión del sensor instalado en una pierna: RT con RS, experimento con clasificador SVM [61]




Figura 5.31: Comparación de precisión del sensor instalado en una pierna: RT con RS, experimento con clasificador NN [61]

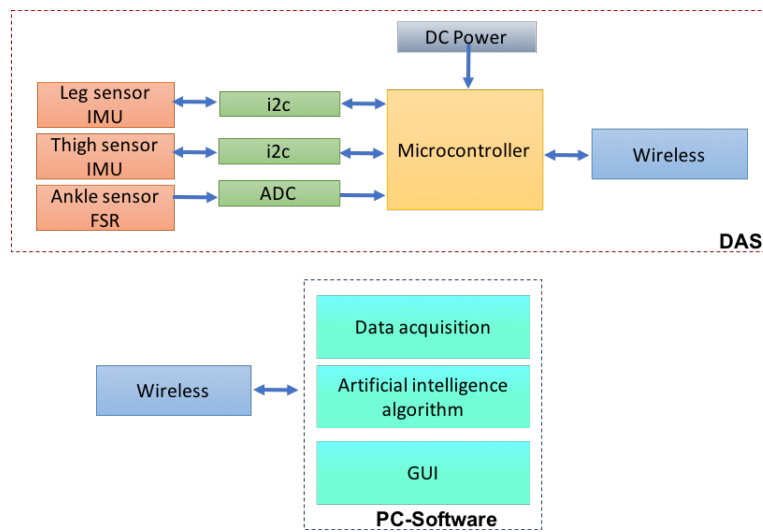


Figura 5.32: Diagrama de bloque del sistema DAS [61]

5.4.5. Experimento con el sistema DAS

Además de los experimentos anteriores, nuestro método se utiliza también en nuestra base de datos. El sistema DAS adquiere información de dos sensores IMU y un sensor de fuerza (FSR). El sensor IMU tiene comunicación i2c, y el FSR envía información ADC. Todos los datos se adquieren para el microcontrolador, que contiene un Arduino UNO, y se procesan digitalmente para ser transmitidos a través de comunicación inalámbrica desde un PC (Figura 5.32). El PC recibe toda la información de los datos.

El error de medición se resolvió mediante un algoritmo de estimación discreta; separa el ruido en función del espacio de estados y no requiere una frecuencia de corte. Este algoritmo se denomina Filtro de Kalman (KF). Este sistema fue desarrollado en secciones anteriores. Los dos sensores IMU se instalaron en la pierna y el muslo izquierdos; el FSR se instaló en el tobillo izquierdo.

Al estudiar el impacto con dos sensores, las actividades de excelente ren-

dimiento fueron caminar, correr, subir y estar de pie; las Figuras 5.26, 5.27 y 5.28 muestra los resultados. Por lo tanto, se seleccionaron caminar, subir, bajar, levantarse y estar de pie para capturar alrededor de 1 minuto a través del sistema DAS. Además, en este experimento se captura la señal filtrada en tiempo real de 10 sujetos.

En la Tabla 5.4, podemos observar la precisión y exactitud de reconocimiento de las actividades. La máquina de vectores soporte y la técnica de red neuronal se entrenaron con un CV de 10 veces. Los resultados mostraron un gran rendimiento de ambos clasificadores con una precisión media del 97.5 % y 96.2 %, respectivamente. Estos buenos resultados con un conjunto de datos diferente ayudaron a validar nuestra propuesta.

Tabla 5.4: Mediciones de métricas de evaluación del método propuesto utilizando el sistema DAS[61].

| Nuestros Datos | SVM | NN |
|-----------------------|-------------|-------------|
| Actividad | Precisión | Precisión |
| Caminar | 98.6 | 97.2 |
| Subir | 96.5 | 98.3 |
| Bajar | 97.3 | 85.2 |
| Levantarse | 95.2 | 98.6 |
| Estar de Pie | 100 | 97.2 |
| Accuracy | 97.5 | 96.2 |

5.5. Conclusiones

Este estudio se centra en el reconocimiento de actividades humanas diarias mediante el procesamiento de la señal cruda de sensores de acelerómetro en el dominio de la frecuencia y la optimización del número de características utilizando una versión modificada del algoritmo QRS. Se realizaron experimentos de clasificación utilizando la base de datos HuGaDB y diferentes clasificadores como Árboles de Decisión, Análisis Discriminante, Bayes Ingenuo, Máquina de Vectores de Soporte, K-vecinos más cercanos y Redes Neuronales. Además, se exploró cómo la variabilidad en los ejes del acelerómetro y el número de sensores instalados afecta el rendimiento de la clasificación.

El mejor resultado se obtuvo utilizando los espectros de potencia de todos los ejes del acelerómetro, con una precisión del 95.1 % mediante Análisis Discriminante y Redes Neuronales. Se logró mantener el 70.6 % de las características utilizando 6685 características, transformando la señal del acelerómetro al ángulo resultante. Además, se evaluó el impacto de reducir el número de sensores en la precisión de la clasificación, mostrando una disminución del 1.78 % utilizando cuatro sensores.

Utilizando la base de datos recopilada por el sistema DAS, se alcanzó

una precisión del 97.5 %. El sistema DAS puede utilizarse en ambas piernas y selecciona automáticamente los datos de aceleración para el análisis.

Parte IV

Conclusiones

Esta cuarta y última parte de la tesis muestra las conclusiones generales que se han obtenido tras la ejecución de los trabajos que se han llevado a cabo durante su desarrollo.



UNIVERSIDAD
DE MÁLAGA

Capítulo 6

Conclusiones y trabajos futuros

*Hay que luchar por todos
equitativamente, bonitamente,
honradamente y racionalmente.*

Mama Tránsito Amaguaña

En esta tesis doctoral, se abordaron los desafíos relacionados con la mejora de la precisión en el análisis de la marcha, explorando el procesamiento de datos, diseño de un sistema de adquisición de datos utilizando tecnología de Sensores Portátiles (WS en inglés) y el análisis de bases de datos públicas creadas por WS, con un enfoque específico en la base de datos Hu-GaDB. Se aplicó ingeniería de características en el dominio de la frecuencia para generar nuevas variables que mejoraran el desempeño de los modelos de aprendizaje automático, particularmente en el ámbito del Reconocimiento de Actividades Humanas (HAR). Estos resultados permitieron experimentar con la reducción de la cantidad de sensores y validar el sistema DAS System para abordar problemas de HAR. Además, se exploraron técnicas de aprendizaje profundo para mejorar la detección de eventos de inicio y fin de la marcha humana.

Partiendo de la investigación [57] la implementación del sistema DAS creado radica en que no se requiere la realización de experimentos en una cinta de correr para controlar la velocidad y la longitud de la zancada, ya que nuestro algoritmo es capaz de normalizar estos aspectos. Además, la versatilidad del eje seleccionado para el diseño del sistema de adquisición de datos permite su uso en cualquiera de las piernas del paciente sin alterar su funcionamiento. Por último, el empleo de redes neuronales ha resultado fundamental para obtener datos precisos sobre la cinemática de la marcha humana.

Considerando los desafíos relacionados con el mejoramiento del aprendizaje de algoritmos de inteligencia artificial y la reducción del número de sensores instalados en el cuerpo para el estudio de la marcha humana, el



estudio [58] presenta una metodología innovadora basada en el dominio de la frecuencia. Esta investigación emplea una versión modificada del algoritmo QRS para la identificación automática del primer pico del espectro de potencia y el inicio del ancho de banda correspondiente. Además, el trabajo [60] amplía este enfoque al reducir y optimizar la cantidad de características relevantes de los datos crudos de los acelerómetros de entrenamiento mediante el uso de ventanas deslizantes. Para los experimentos de clasificación, se empleó el conjunto de datos estándar HuGaDB y se evaluaron con los mejores clasificadores previamente identificados en la literatura en el contexto de problemas de reconocimiento de actividades humanas, como Análisis Discriminante (DA), Máquinas de Soporte Vectorial (SVM) y Redes Neuronales (NN). Destacando NN con un 95.10 % sobrepasando a los obtenidos previamente en la literatura para el reconocimiento de actividades usando la base de datos HuGaDB. A continuación, se analizó el rendimiento de nuestra propuesta para diferentes anchos de banda variando la ventana deslizante, observando que SVM se destaca incluso en condiciones de anchos de banda reducidos. En cuanto al reconocimiento de las diferentes actividades, las actividades de “Subida de Ascensor” y “Bajada de Ascensor” son las que tienen la peor precisión al disminuir datos de entrenamiento. En última instancia, el reconocimiento de actividades varía según el ancho de banda utilizado debido a dónde se encuentra la información más significativa en el espectro de frecuencias. Por ejemplo, las actividades de “Caminar” y “Correr” se reconocen fácilmente, incluso con un 20 % del ancho de banda, porque la información relevante de estas actividades se encuentra en el primer espectro de potencia.

Además, investigamos en [61] otra estrategia para comprender la optimización de las características, consistente en la reducción del número de sensores usados para identificar actividades. En este experimento, concluimos que al emplear solamente cuatro sensores se observa una ligera disminución en la precisión, un 1.78 %, al utilizar redes neuronales, al tiempo que se reduce el conjunto de características en un 40 %. Este experimento también nos proporcionó información sobre la cantidad de actividades que el sistema puede reconocer cuando solo se utilizan dos sensores. Mediante la base de datos recopilada por nuestro sistema DAS, logramos alcanzar una impresionante precisión del 97.5 %. Es importante destacar que el sistema de adquisición DAS puede ser utilizado en ambas piernas; en este experimento, se aplicó en la pierna dominante de cada paciente. Además, el sistema selecciona automáticamente los datos de aceleración para permitir el uso de nuestro método.

El estudio realizado en [59] plantea la detección del inicio de la fase de apoyo (HS) como alternativa a la utilización de sensores de fuerza que suelen ubicarse en las plantas de los pies para analizar las fases de la marcha y la cinemática correspondiente. Aunque nuestro modelo alcanza una precisión

del 97 % en la salud de las personas mayores y un 93 % para pacientes que han sufrido un accidente cerebrovascular, así como un 0.89 % para la enfermedad de Parkinson, los resultados de la matriz de confusión aún muestran falsos positivos en la detección de la fase de apoyo, lo que ocasiona predicciones incorrectas de HS en algunas ocasiones. Un sistema de IMU comercial ha desarrollado una base de datos conocida como el sistema OPAL IMU, lo que ha contribuido a mejorar la precisión del modelo al eliminar la necesidad de filtrar la señal. A raíz de este hallazgo, proponemos integrar esta metodología en nuestro sistema como reemplazo a los sensores de fuerza.

En conclusión, el trabajo de investigación llevado a cabo en esta tesis ha representado un hito significativo en el campo del reconocimiento de actividades humanas y eventos de la marcha, al ofrecer métodos más eficientes y precisos. Esto se refleja en la publicación de estos hallazgos en numerosas revistas de investigación de prestigio, indexadas en el primer cuartil de Journal Citation Reports (JCR), así como en la presentación en congresos internacionales.

Los proyectos futuros se centrarán en la inclusión de una variedad más amplia de señales como parte de los datos de entrada para el entrenamiento, desarrollando una metodología sólida para el preprocesamiento y la integración de estas señales con el objetivo de superar las metodologías actuales.

Además, se prevé llevar a cabo investigaciones para determinar cómo reducir el número de sensores necesarios, identificando las ubicaciones óptimas y la cantidad mínima de sensores necesaria para lograr una clasificación efectiva para poder encontrar más actividades.

El empleo del sistema de adquisición con solo dos sensores arrojó resultados prometedores. No obstante, se abren oportunidades para futuras investigaciones, como el desarrollo de un sistema que no solo adquiriera datos, sino que también sea capaz de identificar y registrar automáticamente los eventos de la marcha dentro de un sistema embebido. Este enfoque buscará optimizar el uso de recursos computacionales, lo que potenciará la eficiencia y practicidad de la tecnología en aplicaciones de monitoreo de la marcha.

En nuestro plan de trabajo futuro, se contempla la expansión de nuestra base de datos incorporando a un número más amplio de participantes. Esto nos permitirá comparar nuestros resultados con otros métodos y algoritmos de aprendizaje automático, lo que contribuirá a fortalecer la validez y aplicabilidad de nuestra metodología.



UNIVERSIDAD
DE MÁLAGA

Parte V

Apéndices

En esta parte se incluye información de interés sobre las publicaciones obtenidas en la comunidad científica gracias a la realización de los trabajos que forman la presente tesis.



UNIVERSIDAD
DE MÁLAGA

Apéndice A

Resumen de publicaciones obtenidas

RESUMEN:

En este apéndice, resumimos la información asociada con las publicaciones que respaldan esta tesis de doctorado. Para las revistas, se ha utilizado la clasificación del *Journal Citation Reports (JCR)*, mientras que para las conferencias, se han empleado la Clasificación de Conferencias *GII-GRIN-SCIE (GGS)* y la clasificación *CORE*.

La Tabla A.1 recopila la distribución de publicaciones desglosada por su tipo y clasificación. En general, durante esta tesis de doctorado, se han publicado 6 trabajos.

Tabla A.1: Publicaciones en apoyo de esta tesis doctoral

| Tipo de publicación | Rating | Publicaciones | Total |
|------------------------------|--------|---------------|-------|
| Revistas indexadas en el JCR | Q1 | 2 | 2 |
| | CORE B | 1 | |
| Conferencias Internacionales | Otros | 3 | 4 |

Las publicaciones que surgieron de esta tesis pueden organizarse de acuerdo a su tipo de publicación de la siguiente manera:

A.1. Revistas indexadas en el JCR

1. **Referencia:** [61].Teran-Pineda D., Thurnhofer-Hemsi K., Dominguez E., “*Human Gait Activity Recognition Using Multimodal Sensor*”. *International Journal of Neural Systems*, (2023), pp. 2350058-2350058, ISSN (print): 0129-0657, ISSN (online): 1793-6462.

- Factor de Impacto (2022): 8.0

- Categoría: COMPUTER SCIENCE, ARTIFICIAL INTELLIGENCE - SCIE (Q1)
 - DOI: DOI: 10.1142/S0129065723500582.
2. **Referencia:** [60]. Teran-Pineda D., Thurnhofer-Hemsi K., Dominguez E., “*Analysis and Recognition of Human Gait Activity Based on Multimodal Sensors*”. Mathematics, 11, 1538, ISSN: 2227-7390.
- Factor de Impacto (2022): 2.4
 - Categoría: MATHEMATICS-SCIE (Q1) (special issue: Mathematical Methods and Applications for Artificial Intelligence and Computer Vision).
 - DOI: DOI: 10.3390/math11061538.

A.2. Artículos publicados en congresos Internacionales

1. **Referencia:** [57]. P. Diego Teran and E. Dominguez, “*Human gait model based on a machine learning and filtering noisy signals with recursive algorithm*,”. 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), Seoul, Korea (South), 16-19 Dec., 2020, pp. 1142-1145.
- DOI: DOI: 10.1109/bibm49941.2020.9313447.
2. **Referencia:** [58]. D. Teran-Pineda and E. Dominguez, “*Monitoring Real-time Personal Activity and Recognition Based on Fusion and Complex Feature Extraction of Multimodal Sensors*”, Proceedings of the 4th International Conference on Advances in Signal Processing and Artificial Intelligence (ASPAI), Corfu, Greece, 19-21 Oct., 2022, pp. 12-13, e-ISBN: 978-84-09-45050-3.
3. **Referencia:** [59]. D. Teran-Pineda and E. Dominguez, “*Detection of the Start of the Gait Cycle by Artificial Intelligence*”, Proceedings of the 5th International Conference on Advances in Signal Processing and Artificial Intelligence (ASPAI), Tenerife (Canary Islands), Spain, 7-9 Jun., 2023, pp. 132-133, e-ISBN: 978-84-09-48561-1.
4. **Aceptado y pendiente de publicación:** Teran-Pineda D., Thurnhofer-Hemsi K., Fernandez-Rodriguez J., Dominguez E., “*Deep learning models for gait event prediction*”, In International Joint Conference on Neural Networks (IJCNN) 2024.

- GGS class: 2
- GGS Rating: A-
- CORE rating: B
- DOI: Accepted for publication



UNIVERSIDAD
DE MÁLAGA

Apéndice B

Publicaciones obtenidas

RESUMEN: En esta sección se encuentra la primera página de cada uno de los trabajos publicados.

Human Gait Activity Recognition Using Multimodal Sensors

Diego Teran-Pineda ^{*}, Karl Thurnhofer-Hemsi [†] and Enrique Domínguez [‡]

*Department of Computer Languages and Computer Science,
University of Málaga Bulevar Louis Pasteur
35, 29071, Málaga, Spain*

*Biomedical Research Institute of Málaga (IBIMA),
C/ Doctor Miguel Díaz Recio, 28, 29010, Málaga, Spain*

**dfteran@uma.es*

†karlkhader@uma.es

‡enriqued@uma.es

Received 26 March 2023

Accepted 25 August 2023

Published Online 30 September 2023

Human activity recognition is an application of machine learning with the aim of identifying activities from the gathered activity raw data acquired by different sensors. In medicine, human gait is commonly analyzed by doctors to detect abnormalities and determine possible treatments for the patient. Monitoring the patient's activity is paramount in evaluating the treatment's evolution. This type of classification is still not enough precise, which may lead to unfavorable reactions and responses. A novel methodology that reduces the complexity of extracting features from multimodal sensors is proposed to improve human activity classification based on accelerometer data. A sliding window technique is used to demarcate the first dominant spectral amplitude, decreasing dimensionality and improving feature extraction. In this work, we compared several state-of-art machine learning classifiers evaluated on the HuGaDB dataset and validated on our dataset. Several configurations to reduce features and training time were analyzed using multimodal sensors: all-axis spectrum, single-axis spectrum, and sensor reduction.

Keywords: Sensor classification; signal processing; computational intelligence; complex feature extraction; activity recognition.

1. Introduction

Human gait is considered one of the most popular natural activities that involving the combined effort of the brain, nerves, and muscles. Gait analysis is necessary to understand the movements (kinematics) and forces (kinetics) used in human joints,^{1,2} which is studied by physiotherapists, orthopedic surgeons, and neurologists to analyze and evaluate the status, treatment, and rehabilitation of patients.³ Determining normal gait parameters is a very complex task because multiple factors (extrinsic, intrinsic, psychological, and physiopathological) influence




everyday human activities.⁴ Applications are present in many areas of expertise, such as neurology, where neurological symptoms are monitored,⁵ or rehabilitation, where gait disorders are detected to carry out physical therapy.^{6,7}

Body-worn physical activity tracking has recently been enriched with sensor technologies (multimedia fusion sensors). They help vulnerable groups to maintain or improve their personal and social quality of life through activity monitoring.⁸ In this field, developing automated information systems and improving biosignal analysis methods

*Corresponding author.

Article

Analysis and Recognition of Human Gait Activity Based on Multimodal Sensors

Diego Teran-Pineda ^{1,*} , Karl Thurnhofer-Hemsi ^{1,2}  and Enrique Dominguez ¹ 

¹ Department of Computer Languages and Computer Science, University of Málaga, Bulevar Louis Pasteur, 35, 29071 Málaga, Spain

² Biomedical Research Institute of Málaga (IBIMA), C/ Doctor Miguel Díaz Recio, 28, 29010 Málaga, Spain

* Correspondence: dfteran@uma.es

Abstract: Remote health monitoring plays a significant role in research areas related to medicine, neurology, rehabilitation, and robotic systems. These applications include Human Activity Recognition (HAR) using wearable sensors, signal processing, mathematical methods, and machine learning to improve the accuracy of remote health monitoring systems. To improve the detection and accuracy of human activity recognition, we create a novel method to reduce the complexities of extracting features using the HuGaDB dataset. Our model extracts power spectra; due to the high dimensionality of features, sliding windows techniques are used to determine frequency bandwidth automatically, where an improved QRS algorithm selects the first dominant spectrum amplitude. In addition, the bandwidth algorithm has been used to reduce the dimensionality of data, remove redundant dimensions, and improve feature extraction. In this work, we have considered widely used machine learning classifiers. Our proposed method was evaluated using the accelerometer angles spectrum installed in six parts of the body and then reducing the bandwidth to know the evolution. Our approach attains an accuracy rate of 95.1% in the HuGaDB dataset with 70% of bandwidth, outperforming others in the human activity recognition accuracy.

Keywords: multimodal sensor; motion classification; computational intelligence; complex feature extraction; activity recognition; QRS algorithm

MSC: 68T10



Citation: Teran-Pineda, D.; Thurnhofer-Hemsi, K.; Dominguez, E. Analysis and Recognition of Human Gait Activity BASED on multimodal Sensors. *Mathematics* **2023**, *11*, 1538. <https://doi.org/10.3390/math11061538>

Academic Editor: Andreas Weinmann

Received: 20 February 2023

Revised: 17 March 2023

Accepted: 19 March 2023

Published: 22 March 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Human gait is a natural activity that people do every time to move from one point to another, involving muscles, nerves and brain activities. Human joints are a fundamental part of human movement, and therefore, a gait analysis is needed to study kinetics and kinematics [1,2], which are examined by physiotherapists, orthopedists, and neurologists to analyze and assess the status, treatment, and rehabilitation of patients [3]. Extrinsic and intrinsic factors (both psychological and physical) influence daily human activities; hence, determining normal gait parameters is very difficult [4]. In addition, there are a wide range of applications in different fields, such as neurology for monitoring neurological symptoms [5], or rehabilitation and physical therapy for the detection of gait disorders [6,7].

Physical activity monitoring via body-worn devices has recently been increased by sensor technologies (multimodal fusion sensors). They help vulnerable people maintain or increase the quality of individual and social lives through activity tracking [8]. The development of automatic information systems and improved methods to analyze biosignals with AI in this area is a way to contribute to more efficient health care.

The devices used to acquire body signals are classified into three approaches: non-wearable sensor (NWS), wearable sensor (WS), and hybrid system [2]. Nevertheless, WS is most commonly used due to its low cost, small dimensions, and high precision. These sensors are installed in the body to acquire the gait biosignal information during personal

Human gait model based on a machine learning and filtering noisy signals with recursive algorithm

1st Diego Teran P.
University of Malaga
Malaga, Spain
dfteran@uma.es

2nd Enrique Dominguez
Dept. of Computer Science
University of Malaga
Malaga, Spain
enrique@lcc.uma.es

Abstract—Gait analysis is widely used by doctors to detect anomalies and conclude possible treatments to patient. Conventionally, the gait analysis has been considered subjectively and now is use the technology to improve the data information. The sensors noises, however, causes errors in kinematic data to analyze any waveform, and this analysis requires a large amount of noiseless data for using artificial intelligent. In contrast, this paper presents an initial study about acquiring human gait parameters and data to get a model using computer learning. Therefore, we developed a portable acquisition system non-invasive using an online recursive algorithm in a micro-controller for processing and filtering signals of wearable sensors. The Data Acquisition Signal (DAS) system utilizes a Force Sensitive Resistor (FSR) on the heel and two inertial sensors, one in the thigh and one in the leg, to measure the knee angle; such system calibrates automatically the inertial sensors in each experiment. DAS system has a user-interface that includes intelligent algorithms to normalize, interpolate, and obtain the model curve with fitting of the data showing the gait phases. Our experiments were tested on non-pathology patients with different ages (young, adult and elder) with normal gait pattern selected by a physiotherapist. To know the reliability of the kinematic model, we altered the gait of each patient by shifting the floor and footwear. The results and the gait models seen by the physiotherapist were displayed on an interface.

Index Terms—Human gait analysis, Gait datasets, Kinematic model, Inertial sensor, Data acquisition.

I. INTRODUCTION

Human gait is considered one of the most common and natural activities which involves the combined effort of the brain, nerves, and muscles and is necessary to understand the movements of humans (kinematics) and the forces (kinetics) that are applied in human joints [2]. Physiotherapists, orthopedists and neurologists examine human movement to analyze and assess the status, treatment and rehabilitation of the patients [1] and need to have a perfect knowledge of the knee joint and has numerous traumas [2]. The identification of the normal gait pattern, medical diagnosis, geriatrics or elderly care, and sports control and tactics are part of the application based on gait analysis. The availability of quantitative parameters of normal gait is essential for the detection of gait disorders, the evaluation of medical gait interventions, and rehabilitation developments [1]. There are extrinsic, intrinsic, psychological and pathological physical factors that influence normal gait, so

determining normal gait parameters is a very complex task, the diagnosis of gait can be difficult [3].

In the United States, falling is the leading cause of death due to unintentional or untreated injuries in older adults (56.0% in 2014) [4]; in addition, the causes of falling due to gait problems in older adults is possible to confirm corroboratively in other countries such as [1]: 33% of Australians, 19.3% in Hong Kong, 21.6% in Bridgetown (Barbados), 29% in Havana (Cuba), 33% in Mexico City (Mexico) and 34% in Santiago (Chile). Older adults have experienced numerous traumas and pathologies when these have not been treated properly; therefore, is necessary know the kinematics model of the human march for rehabilitation and study.

A large number of methodology published (image processing, floor sensor and sensor placed in the any part on the body). The technological used devices in the mentioned research can be classified in three different approaches: non-wearable sensor (NWS), wearable sensor (WS), and hybrid system [5]. NWS require a room with sensors installed to capture the gait while the subject walk which implies a higher installation and equipment cost. NWS can be classified in two group: image processing and system based in floor sensors. Among the used method are: 1. Camera triangular with 70% of accuracy [6], 2. 3D video acquired by Time of Flight (ToF) with 2.66% - 9.25% of error [7] 3. Structure light obtained <1% (Mean diff) [6]. 4. Thermography with accuracy between 78%-91% [7].

WS are sensor installed in the body, and it does not require a laboratory in order to complete the experiment because this technique acquire the gait information during the person's activities and can store data during the march or race [11] [12] and extract significant characteristics for the analyzes. Many WS methods are: 1. Inertial sensor to obtain orientation, velocity and acceleration most accurately determined the flexion/extension joint angle (CMC-coefficient of multiple correlation > 0.96) for all joints [9] and Stride length error -0.8 ± 6.6 cm [10], 2. Goniometer 0.999 with measures taken with mechanical Goniometer [8]. Nevertheless, based on [8], actual gait analysis research use 40% of NWS, 22.5% of WS and 37.5% of only Inertial sensor (IS). The usage of IS have increased in the new researches, furthermore, there are investigations to estimate human gait with the least number of



(0362)

Monitoring Real-time Personal Activity and Recognition Based on Fusion and Complex Feature Extraction of Multimodal Sensors

D. Teran-Pineda and E. Dominguez

³³University of Málaga, Dept. of Computer Science, 29071, Malaga, Spain
E-mails: {dfteran, enriqued}@uma.es

Summary: Doctors widely use gait analysis to detect anomalies and conclude possible treatments for the patient. Despite the extensive applications, human activity classification and recognition remain inaccurate. To improve the detection and accuracy of human activity recognition, we create a novel model classification and system acquisition data with a recursive algorithm, reducing the complexities of extracting features. As a result, we created a dataset of fifteen participants wearing three inertial sensors and were selected by a specialist. Our model extracts a power spectre; due to the high dimensionality of features, the sliding windows techniques are used to determine frequency bandwidth automatically, where the QRS algorithm selects the first dominant spectrum amplitude. A feature selection algorithm and PCA has been used to improve feature extraction. We have considered widely used classifiers, which we evaluated in the HuGaDB dataset and validated in our dataset, achieving an accuracy rate of 100 % in both datasets.

Keywords: Multimodal sensor, Motion classification, Computational intelligence, Complex feature extraction, Activity recognition, QRS algorithm.

1. Introduction

Human gait is one of the most common and natural activities that involves the combined effort of the brain, nerves, and muscles. It is necessary to understand the movements of humans (kinematics). The forces (kinetics) that are applied in human joints [1], in addition, physiotherapists, orthopedists, and neurologists examine the human tendency to analyse and assess the status, treatment, and rehabilitation of patients. Various extrinsic, internal, psychological, and pathological physical elements influence normal gait in regular human activities, making identifying normal gait parameters a tough endeavour [2].

There has been a rising desire to improve community health and safety. In remote health monitoring and caregiving systems, reliable and timely recognition of daily human activities throughout the day is necessary [3]. For example, only cases of injuries in older individuals [1] indicate that unintentional or untreated falls are the top cause of death (56 % in 2014) in the United States [4], including 33 % of Australians, 19.3 % in Hong Kong, 21.6 % in Bridgetown (Barbados), 29 % in Havana (Cuba), and 33 % in Mexico City (Mexico) and 34 % in Santiago (Chile). When traumas and pathologies in older persons are not adequately treated, it is vital to have a reliable remote health monitoring system that recognises motion patterns and human activities, among other uses.

A large number of methodologies have been published about (1) acquiring body signals using sensors, (2) determining features, and (3) they have applied classification methods with Artificial or Computational Intelligence. Body-worn inertial sensors (multimodal sensor) have gained wide research attention and encouraged the development of novel Human Activity Recognition applications, these

applications include e-health rehabilitation, security surveillance, emergency services, wellness aid, smart homes and biofeedback systems, gait analysis, motion symmetry studies, or monitoring human activities [5], each of these applications require continuous monitoring. Nevertheless, accurate and efficient activity recognition requires selecting the most relevant features or removing redundant information.

A small number of research using frequency measures [6] and entropy have produced encouraging results when extracting more complicated features. [7] employed specific frequency power components as characteristics to distinguish normal and ataxic gait using a perceptive neuron system for data collecting with a maximum accuracy of 98.59 per cent, although it required several expensive sensors. There have also been studies that reduce sensors to reduce computing time; for example, in [8], the author directly used features from raw acceleration data as input to the classifier and did not extract features as a pre-processing step to save training time.

The main focus of this paper is to improve the detection and accuracy of human activity recognition (HAR); we create a novel model classification and system acquisition data with a recursive algorithm named DAS System, reducing the complexities of extracting features. As a result, we created a dataset of fifteen participants wearing three inertial sensors and were selected by a specialist. Our model extracts a power spectre; due to the high dimensionality of features, the sliding windows techniques are used to determine frequency bandwidth automatically, where the QRS algorithm selects the first dominant spectrum amplitude. For performance evaluation, we applied the proposed model to our Database, we also applied in a public benchmark dataset named Human Gait Database (HuGaDB) and compare it with another research.

(045)

Detection of the Start of the Gait Cycle by Artificial Intelligence

D. Teran-Pineda and E. Dominguez

University of Malaga, Department of Computer Languages and Computer Science,
Bulevar Louis Pasteur, 35, 29071 Málaga, Spain
E-mails: dfteran@uma.es, enriqued@uma.es

Summary: Human behavior plays an essential role in research health; thus, human information has been converted crucial to medicine, neurology, biomedical, and rehabilitation. Computer science, digital signal processing, and mathematics methods have helped improve the detection accuracy of these human activities acquired by different sensors. In this paper, a methodology with a neural network model was developed to detect the start and end of human gait. The output layer uses a sigmoid activation function; also, binary cross-entropy is applied as a loss function. A slider windows technique has been used to select part of the data to increase the accuracy of the Heel Strike event, which is the start and end of the gait cycle. Our proposed method was evaluated in an open database from the APDM OPAL system used by other researchers. Our approach attains an accuracy rate of 97.0 % in neural network classifiers using slider windows of 50 sizes.

Keywords: Human gait, Event gait, Neural network, Slide windows.

1. Introduction

One of the most common and natural activities in daily human life is walking; the ability to walk involves the concerted of the brain, jitters, and muscles and is necessary to understand the movements of humans (kinematics) and the forces(kinetics) that are applied in mortal joints [1], likewise, the tendency to assess the status, treatment, and recuperation of the cases are examined by physiotherapists, orthopedists, and neurologists [2]. In [3], human gait can be challenging to diagnose; also, the motion analysis is essential in neurology, rehabilitation, and physical therapy to detect disorders and monitor different neurological symptoms in gait human [4].

To study normal and abnormal human gait in [5] explain many parameters, which include the range and pattern of joint motion, floor reaction forces, timing of foot/floor contact, gait speeds, cadences, stride lengths, swing-to-stance phase relations, resting joint angles, isometric torques, and phasic muscular activities. Moreover, the swing-to-stance phase parameters have three important events in one gait cycle: the Mid-Swing (MS), Heel-Strike (HS), and Toe-Off (TO) events.

Gait human studies have helped to improve community health and safety and also have increased the survey in gait training systems, which integrates mechanical, sensing technology, electronic and robotic technologies; there are three crucial field research, (1) gait measurement and intention recognition, (2) gait evaluation, and (3) gait training control strategy [3]. Therefore, knowing and measuring the human gait for its clinical applications and preventing future diseases is essential.

Rehabilitation research has made WS sensors essential in quantifying gait rehabilitation evaluation. These results are often obtained using multiple sensors [6] or other research uses few sensors to improve ergonomics and noise reduction [7].

The main objective of this research is to design a model based on neural networks using inertial sensors so that the model automatically learns the detection of the start and end of walking – HS. In this work, the database of research [8] is used; in addition, to train the model, the start and end of the march were manually marked, and the slide windows method was used to enter the data into the model. The output layer uses a sigmoid activation function to obtain a binary output; also, binary cross-entropy is applied as a loss function to quantify the similarity between the output model and label events.

2. Methodology

2.1. Signal Feature

The database contains signals from two wearable IMUs sensors, and they were collected to signal to detect the kinematics at a sampling rate of 25 Hz. The sensors were implemented in their two legs, and each subject covered 20 m four times. In addition, each IMU provides three axial accelerometers and three axial angular velocities for each leg, forming a vector $N_s = 6$ for each sample and a binary label corresponding to the HS event (Y_s).

Consider a full sample collect of size N_t in N_s data snapshots; the data matrix of the range collected has $N_t \times N_s$ and the label vector $N_t \times L_s$. To a range r , the matrix $N_t \times N_s$ is then partitioned with sliding windows of size $M_t \times M_s$, where this results in $L_t L_s$ sub-matrices stacked into a Matrix T . The L_s parameter is given by the length N_s and $L_s = r + t$, t increase in each time.

$$T_j = \{F\}_j, \quad (1)$$

where F is the matrix transform in vector of size $1 \times (N_s \times r)$ in each partition and j represents the number of partitions with sliding windows of total samples.

Deep learning models for gait event prediction

Diego Terán-Pineda*, Karl Thurnhofer-Hemsi^{†‡}, José David Fernández-Rodríguez^{†‡} and Enrique Domínguez^{†‡}

*Department of Computer Languages and Computer Science
University of Málaga, Bulevar Louis Pasteur, 35, 29071 Málaga, Spain

[†]ITIS Software, Universidad de Málaga
Calle Arquitecto Francisco Penalosa, 18, 29010 Málaga, Spain

[‡]Instituto de Investigación Biomédica de Málaga y Plataforma en Nanomedicina-IBIMA Plataforma BIONAND
C/ Severo Ochoa, 35, Málaga TechPark, Campanillas, 29590, Málaga, Spain

Emails: dfteran@uma.es, {karlkhader,josedavid,enriqued}@lcc.uma.es

Abstract—Research in human gait has contributed to clinical applications in physiotherapy and preventative medicine by improving the understanding and measurement of human gait patterns. In this context, characterization of gait events and kinematic models are essential for medical intervention. This paper proposes a novel gait event detection method, using deep learning for the kinematic model. The setup uses two IMU sensors from which the angles of the kinematic model are computed, and a FSR sensor to detect the Heel Strike event (HS). A microcontroller digitally processed the signals from these sensors in real-time, and saved the gait data. We collected data from healthy subjects representing various age groups (young, adolescent, and elderly), selected by a medical specialist. Firstly, a kinematic curve pattern was created using three types of deep networks. Secondly, the pattern was subsequently applied to detect Heel Strike (HS) events using Dynamic Time Warping (DTW). A detection average of 96.64% was obtained using a single kinematic model, compared to 76.82% obtained in other studies for HS detection. Furthermore, our research provides medical specialists with a kinematic gait curve to develop tools to automatically detect critical points in gait impairments.

Index Terms—Healthcare system, Gait Events, IMU Sensors, Deep Learning, Dynamic Time Warping.

HUMAN gait patterns are the emergent result of a concerted effort by the bones, tendons and muscles of the human body, directed by the brain. Gait analysis [1] involves the kinematic modeling and characterization of normal and abnormal patterns in human gait, and is used by physiotherapists, orthopedists, and neurologists to assess the health status of patients and select medical treatments. While gait analysis can be challenging to use in an effective way [2], it is also a very important diagnostic and assessing tool in neurology, rehabilitation, and physical therapy to detect disorders and monitor neurological conditions [3]. Neurological conditions like the aftereffects of a stroke, accident, and Parkinson's disease can result in the deterioration of motor skills and a

decrease in the ability to walk, significantly impacting the overall well-being and health of individuals [4]. In this context, there is a need to assist elderly individuals and patients to overcome movement disorders and restoring their ability to walk, ultimately enhancing their daily lives, and gait analysis can play a key role in this regard [5].

The human gait cycle can be analysed according to many parameters such as the range and pattern of joint motion, floor reaction forces, timing of foot/floor contact, gait speeds, cadences, stride lengths, swing-to-stance phase relations, resting joint angles, isometric torques, and phasic muscular activities [6]. From these, the swing-to-stance phase parameters feature three crucial events in each gait cycle: the Mid-Swing (MS), Heel-Strike (HS), and Toe-Off (TO) events. The events in the gait cycle can be recorded using non-wearable sensors, wearable sensors, and hybrid systems [7]. Of these, wearable sensors are most commonly used, since they are less expensive and can be used outside controlled environments. Typically used wearable sensors include accelerometers, gyroscopes, active markers, and Inertial Measurement Units (IMUs).

Many different mathematical techniques can be applied to analyse gait patterns from sensor signals. For instance, Staab *et al.* [8] used spectral analysis to detect osteoarthritis, while Liu *et al.* [9] developed an intelligent shoe with multiple sensors, using the continuous wavelet transform to identify gait events. Machine learning techniques can be also used for this purpose [10], and also combined with frequency analysis in order to reduce the computational load [11]. Machine learning can also be used to detect redundancies in data in order to minimize training time and the number of required sensors for gait analysis [12]. More recent deep learning techniques can also be used, such as training a LSTM network to detect HS events [13] or detect Parkinson disease from spatiotemporal gait data [14], [15].

In this work, a Data Acquisition System (DAS) based on a Force-Sensing Resistor (FSR) and two IMUs is used to acquire a kinematic gait model, and a novel method that uses deep learning is proposed to detect gait events using a kinematic gait model, reducing the number of required sensors and providing feedback to users about gait quality. Data from the FSR sensor is used to train the kinematic model, and the

This work is partially supported by the Autonomous Government of Andalusia (Spain) under project UMA20-FEDERJA-108, and also by the Ministry of Science and Innovation of Spain, grant number PID2022-136764OA-I00. It includes funds from the European Regional Development Fund (ERDF). The authors acknowledge the funding from the Universidad de Málaga (UMA). It is also partially supported by the University of Málaga (Spain) under grants B1-2021_20, B4-2023_13 and B1-2022_14; and by the Fundación Unicaja under project PUNI-003_2023. The authors also gratefully acknowledge the support of NVIDIA Corporation with the donation of a RTX A6000 GPU with 48Gb.



UNIVERSIDAD
DE MÁLAGA

Bibliografía

*La mejor vida no es la más larga, sino la
más rica en buenas acciones.*

Marie Curie

- [1] ADÁMEK, K., NOVOTNÝ, J., THIYAGALINGAM, J. y ARMOUR, W. Efficiency near the edge: Increasing the energy efficiency of ffts on gpus for real-time edge computing. *IEEE Access*, vol. 9, páginas 18167–18182, 2021.
- [2] ALHARTHI, A. S., CASSON, A. J. y OZANYAN, K. B. Gait spatio-temporal signal analysis for parkinson’s disease detection and severity rating. *IEEE Sensors Journal*, vol. 21(2), páginas 1838–1848, 2021.
- [3] ALLSEITS, E., KIM, K. J., BENNETT, C., GAILEY, R., GAUNAURD, I. y AGRAWAL, V. A novel method for estimating knee angle using two leg-mounted gyroscopes for continuous monitoring with mobile health devices. *Sensors*, vol. 18(9), página 2759, 2018.
- [4] ALZUBAIDI, L., ZHANG, J., HUMAIDI, A. J., AL-DUJAILI, A., DUAN, Y., AL-SHAMMA, O., SANTAMARÍA, J., FADHEL, M. A., AL-AMIDIE, M. y FARHAN, L. Review of deep learning: Concepts, cnn architectures, challenges, applications, future directions. *Journal of big Data*, vol. 8, páginas 1–74, 2021.
- [5] ANTONIADES, A., SPYROU, L., MARTIN-LOPEZ, D., VALENTIN, A., ALARCON, G., SANEI, S. y TOOK, C. C. Detection of interictal discharges with convolutional neural networks using discrete ordered multichannel intracranial eeg. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25(12), páginas 2285–2294, 2017.
- [6] AUVINET, B., TOUZARD, C., MONTESTRUC, F., DELAFOND, A. y GOEB, V. Gait disorders in the elderly and dual task gait analysis: a new approach for identifying motor phenotypes. *Journal of neuroengineering and rehabilitation*, vol. 14, páginas 1–14, 2017.



- [7] BADAWI, A. A., AL-KABBANY, A. y SHABAN, H. A. Sensor type, axis, and position-based fusion and feature selection for multimodal human daily activity recognition in wearable body sensor networks. *Journal of Healthcare Engineering*, vol. 2020, 2020.
- [8] BALABAN, B. y TOK, F. Gait disturbances in patients with stroke. *Pm&r*, vol. 6(7), páginas 635–642, 2014.
- [9] BELTRAN-CARBAJAL, F., ABUNDIS-FONG, H. F., TRUJILLO-FRANCO, L. G., YAÑEZ-BADILLO, H., FAVELA-CONTRERAS, A. y CAMPOS-MERCADO, E. Online frequency estimation on a building-like structure using a nonlinear flexible dynamic vibration absorber. *Mathematics*, vol. 10(5), página 708, 2022.
- [10] BISHOP, C. M. Pattern recognition and machine learning. *Springer google schola*, vol. 2, páginas 5–43, 2006.
- [11] BUCKLEY, E., MAZZÀ, C. y MCNEILL, A. A systematic review of the gait characteristics associated with cerebellar ataxia. *Gait & posture*, vol. 60, páginas 154–163, 2018.
- [12] CALIANDRO, P., CONTE, C., IACOVELLI, C., TATARELLI, A., CASTIGLIA, S. F., REALE, G. y SERRAO, M. Exploring risk of falls and dynamic unbalance in cerebellar ataxia by inertial sensor assessment. *Sensors*, vol. 19(24), página 5571, 2019.
- [13] CASTILLEJO, P., MARTINEZ, J.-F., RODRIGUEZ-MOLINA, J. y CUERVA, A. Integration of wearable devices in a wireless sensor network for an e-health application. *IEEE Wireless Communications*, vol. 20(4), páginas 38–49, 2013.
- [14] CDC. Injury Prevention and Control. <https://www.cdc.gov/injury/wisqars/LeadingCauses.html>, 2022. [Online; accessed 25-January-2021].
- [15] CHATTERJEE, R., MAITRA, T., ISLAM, S. H., HASSAN, M. M., ALAMRI, A. y FORTINO, G. A novel machine learning based feature selection for motor imagery eeg signal classification in internet of medical things environment. *Future Generation Computer Systems*, vol. 98, páginas 419–434, 2019.
- [16] CHERESHNEV, R. y KERTÉSZ-FARKAS, A. Hugadb: Human gait database for activity recognition from wearable inertial sensor networks. En *International Conference on Analysis of Images, Social Networks and Texts*, páginas 131–141. Springer, 2018.

- [17] DA XU, L., LU, Y. y LI, L. Embedding blockchain technology into iot for security: A survey. *IEEE Internet of Things Journal*, vol. 8(13), páginas 10452–10473, 2021.
- [18] DEL DIN, S., HICKEY, A., HURWITZ, N., MATHERS, J. C., ROCHESTER, L. y GODFREY, A. Measuring gait with an accelerometer-based wearable: influence of device location, testing protocol and age. *Physiological measurement*, vol. 37(10), página 1785, 2016.
- [19] DONATH, M. *Human gait pattern recognition for evaluation, diagnosis and control*. Tesis Doctoral, Massachusetts Institute of Technology, 1978.
- [20] DOSTÁL, O., PROCHÁZKA, A., VYŠATA, O., ŤUPA, O., CEJNAR, P. y VALIŠ, M. Recognition of motion patterns using accelerometers for ataxic gait assessment. *Neural Computing and Applications*, vol. 33(7), páginas 2207–2215, 2021.
- [21] DUAN, N., LIU, L.-Z., YU, X.-J., LI, Q. y YEH, S.-C. Classification of multichannel surface-electromyography signals based on convolutional neural networks. *Journal of Industrial Information Integration*, vol. 15, páginas 201–206, 2019.
- [22] EBARA, T., AZUMA, R., SHOJI, N., MATSUKAWA, T., YAMADA, Y., AKIYAMA, T., KURIHARA, T. y YAMADA, S. Reliability of smartphone-based gait measurements for quantification of physical activity/inactivity levels. *Journal of occupational health*, páginas 17–0101, 2017.
- [23] FORTINO, G., GIANNANTONIO, R., GRAVINA, R., KURYLOSKI, P. y JAFARI, R. Enabling effective programming and flexible management of efficient body sensor network applications. *IEEE Transactions on Human-Machine Systems*, vol. 43(1), páginas 115–133, 2012.
- [24] GARCÍA, L. E. Control digital. teoría y práctica. *Editorial L. Vieco Ltda*, 2013.
- [25] GOCHOO, M., TAHIR, S. B. U. D., JALAL, A. y KIM, K. Monitoring real-time personal locomotion behaviors over smart indoor-outdoor environments via body-worn sensors. *IEEE Access*, vol. 9, páginas 70556–70570, 2021.
- [26] GOODFELLOW, I., BENGIO, Y. y COURVILLE, A. *Deep learning*. MIT press, 2016.
- [27] GRAVINA, R., ALINIA, P., GHASEMZADEH, H. y FORTINO, G. Multi-sensor fusion in body sensor networks: State-of-the-art and research challenges. *Information Fusion*, vol. 35, páginas 68–80, 2017.

- [28] HAN, Y., LIU, C., ZHANG, B., ZHANG, N., WANG, S., HAN, M., FERREIRA, J. P., LIU, T. y ZHANG, X. Measurement, evaluation, and control of active intelligent gait training systems—analysis of the current state of the art. *Electronics*, vol. 11(10), página 1633, 2022.
- [29] HAYATI, H., MAHDAVI, F. y EAGER, D. Analysis of agile canine gait characteristics using accelerometry. *Sensors*, vol. 19(20), página 4379, 2019.
- [30] HU, B., DIXON, P., JACOBS, J., DENNERLEIN, J. y SCHIFFMAN, J. Machine learning algorithms based on signals from a single wearable inertial sensor can detect surface-and age-related differences in walking. *Journal of biomechanics*, vol. 71, páginas 37–42, 2018.
- [31] JOUKOV, V., BONNET, V., KARG, M., VENTURE, G. y KULIĆ, D. Rhythmic extended kalman filter for gait rehabilitation motion estimation and segmentation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26(2), páginas 407–418, 2017.
- [32] KANG, H., LEE, J. y KIM, D. Hi-fft: Heterogeneous parallel in-place algorithm for large-scale 2d-fft. *IEEE Access*, vol. 9, páginas 120261–120273, 2021.
- [33] KOUR, N., ARORA, S. ET AL. Computer-vision based diagnosis of parkinson’s disease via gait: A survey. *IEEE Access*, vol. 7, páginas 156620–156645, 2019.
- [34] KUO, J.-Y., YOU, S.-Y., LIN, H.-C., HSU, C.-Y. y LEI, B. Constructing condition monitoring model of wind turbine blades. *Mathematics*, vol. 10(6), página 972, 2022.
- [35] LEE, J., HONG, W. y HUR, P. Continuous gait phase estimation using lstm for robotic transfemoral prosthesis across walking speeds. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 29, páginas 1470–1477, 2021.
- [36] LI, N., YANG, J., FENG, X., ZHANG, J., YANG, X. y ZHANG, Z. A summary of 30 years’research on risk factors of stroke mortality in china. *Chinese Journal of Behavioral Medicine and Brain Science*, páginas 765–768, 2017.
- [37] LIU, X., ZHANG, S., YAO, B., YU, Y., WANG, Y. y FAN, J. Gait phase detection based on inertial measurement unit and force-sensitive resistors embedded in a shoe. *Review of Scientific Instruments*, vol. 92(8), página 084708, 2021.
- [38] LU, X., PAN, M. y YU, Y. Qrs detection based on improved adaptive threshold. *Journal of healthcare engineering*, vol. 2018, 2018.

- [39] MURO-DE-LA-HERRAN, A., GARCIA-ZAPIRAIN, B. y MENDEZ-ZORRILLA, A. Gait analysis methods: An overview of wearable and non-wearable systems, highlighting clinical applications. *Sensors*, vol. 14(2), páginas 3362–3394, 2014.
- [40] NAIT AICHA, A., ENGLEBIENNE, G., VAN SCHOOTEN, K. S., PIJNAPPELS, M. y KRÖSE, B. Deep learning to predict falls in older adults based on daily-life trunk accelerometry. *Sensors*, vol. 18(5), página 1654, 2018.
- [41] NGUYEN, N., PHAN, D., PATHIRANA, P. N., HORNE, M., POWER, L. y SZMULEWICZ, D. Quantification of axial abnormality due to cerebellar ataxia with inertial measurements. *Sensors*, vol. 18(9), página 2791, 2018.
- [42] NUTT, J. G., MARSDEN, C. D. y THOMPSON, P. D. Human walking and higher-level gait disorders, particularly in the elderly. *Neurology*, vol. 43(2), páginas 268–268, 1993. ISSN 0028-3878.
- [43] PAN, J. y TOMPKINS, W. J. A real-time qrs detection algorithm. *IEEE Transactions on Biomedical Engineering*, vol. BME-32(3), páginas 230–236, 1985.
- [44] PHAN, D., NGUYEN, N., PATHIRANA, P. N., HORNE, M., POWER, L. y SZMULEWICZ, D. Quantitative assessment of ataxic gait using inertial sensing at different walking speeds. En *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, páginas 4600–4603. IEEE, 2019.
- [45] PIRKER, W. y KATZENSCHLAGER, R. Gait disorders in adults and the elderly: A clinical guide. *Wiener Klinische Wochenschrift*, vol. 129(3-4), páginas 81–95, 2017.
- [46] POLLOCK, D. S. G. Methodology for trend estimation. *Economic Modelling*, vol. 18(1), páginas 75–96, 2001.
- [47] PRAKASH, C., GUPTA, K., MITTAL, A., KUMAR, R. y LAXMI, V. Passive marker based optical system for gait kinematics for lower extremity. *Procedia Computer Science*, vol. 45, páginas 176–185, 2015.
- [48] PRAKASH, C., KUMAR, R. y MITTAL, N. Recent developments in human gait research: parameters, approaches, applications, machine learning techniques, datasets and challenges. *Artificial Intelligence Review*, vol. 49(1), páginas 1–40, 2018.
- [49] PROCHÁZKA, A., VYŠATA, O., CHARVÁTOVÁ, H. y VALIŠ, M. Motion symmetry evaluation using accelerometers and energy distribution. *Symmetry*, vol. 11(7), página 871, 2019.

- [50] RASCHKA, S. Stat 479: Machine learning lecture notes (2018). https://github.com/rasbt/stat479-machine-learning-fs18/blob/master/07_ensembles/07_ensembles_notes.pdf, 2018.
- [51] SENANAYAKE, C. y SENANAYAKE, S. Human assisted tools for gait analysis and intelligent gait phase detection. En *2009 Innovative Technologies in Intelligent Systems and Industrial Applications*, páginas 230–235. IEEE, 2009.
- [52] SOANGRA, R., WEN, Y., YANG, H. y GRANT-BEUTTLER, M. Classifying toe walking gait patterns among children diagnosed with idiopathic toe walking using wearable sensors and machine learning algorithms. *IEEE Access*, vol. 10, páginas 77054–77067, 2022.
- [53] SONG, Y., ZHANG, J., CAO, L. y SANGEUX, M. On discovering the correlated relationship between static and dynamic data in clinical gait analysis. En *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, páginas 563–578. Springer, 2013.
- [54] STAAB, W., HOTTOWITZ, R., SOHNS, C., SOHNS, J. M., GILBERT, F., MENKE, J., NIKLAS, A. y LOTZ, J. Accelerometer and gyroscope based gait analysis using spectral analysis of patients with osteoarthritis of the knee. *Journal of physical therapy science*, vol. 26(7), páginas 997–1002, 2014.
- [55] TARNIȚĂ, D. Wearable sensors used for human gait analysis. *Romanian journal of morphology and embryology = Revue roumaine de morphologie et embryologie*, vol. 57(2), página 373–382, 2016.
- [56] TAYLAN, O., SATTARI, M. A., ELHACHFI ESSOUSSI, I. y NAZEMI, E. Frequency domain feature extraction investigation to increase the accuracy of an intelligent nondestructive system for volume fraction and regime determination of gas-water-oil three-phase flows. *Mathematics*, vol. 9(17), página 2091, 2021.
- [57] TERAN, P. D. y DOMINGUEZ, E. Human gait model based on a machine learning and filtering noisy signals with recursive algorithm. En *2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, páginas 1142–1145. IEEE, 2020.
- [58] TERAN-PINEDA, D. y DOMIGUEZ, E. Monitoring real-time personal activity and recognition based on fusion and complex feature extraction of multimodal sensors. En *Proceedings of the 4th international conference on advances in Signal Processing and artificial intelligence* (editado por S. Y. Yurish), páginas 12–13. IFSA, Corfu, Greece, 2022.

- [59] TERAN-PINEDA, D. y DOMIGUEZ, E. Detection of the start of the gait cycle by artificial intelligence. En *Proceedings of the 5th international conference on advances in Signal Processing and artificial intelligence* (editado por S. Y. Yurish), páginas 132–133. IFSA, Tenerife(Canary Islands), Spain, 2023.
- [60] TERAN-PINEDA, D., THURNHOFER-HEMSI, K. y DOMINGUEZ, E. Analysis and recognition of human gait activity based on multimodal sensors. *Mathematics*, vol. 11(6), 2023. ISSN 2227-7390.
- [61] TERAN-PINEDA, D., THURNHOFER-HEMSI, K. y DOMÍNGUEZ, E. Human gait activity recognition using multimodal sensors. *International Journal of Neural Systems*, páginas 2350058–2350058, 2023.
- [62] TJHAI, C. y O’KEEFE, K. Using step size and lower limb segment orientation from multiple low-cost wearable inertial/magnetic sensors for pedestrian navigation. *Sensors*, vol. 19(14), página 3140, 2019.
- [63] TUNCA, C., SALUR, G. y ERSOY, C. Deep learning for fall risk assessment with inertial sensors: Utilizing domain knowledge in spatio-temporal gait parameters. *IEEE journal of biomedical and health informatics*, vol. 24(7), páginas 1994–2005, 2019.
- [64] UDDIN, M. Z. y HASSAN, M. M. Activity recognition for cognitive assistance using body sensors data and deep convolutional neural network. *IEEE Sensors Journal*, vol. 19(19), páginas 8413–8419, 2018.
- [65] VADNERKAR, A., FIGUEIREDO, S., MAYO, N. E. y KEARNEY, R. E. Design and validation of a biofeedback device to improve heel-to-toe gait in seniors. *IEEE journal of biomedical and health informatics*, vol. 22(1), páginas 140–146, 2018.
- [66] VOICU, R.-A., DOBRE, C., BAJENARU, L. y CIOBANU, R.-I. Human physical activity recognition using smartphone sensors. *Sensors*, vol. 19(3), página 458, 2019.
- [67] WANG, F.-C., LI, Y.-C., KUO, T.-Y., CHEN, S.-F. y LIN, C.-H. Real-time detection of gait events by recurrent neural networks. *IEEE Access*, vol. 9, páginas 134849–134857, 2021.
- [68] WANG, F.-C., LI, Y.-C., WU, K.-L., CHEN, P.-Y. y FU, L.-C. On-line gait detection with an automatic mobile trainer inspired by neuro-developmental treatment. *Sensors*, vol. 20(12), página 3389, 2020.
- [69] WANG, F.-C., LIN, Y.-Y. y YU, C.-H. Robust loop-shaping control design and implementation for an automatic neuro-developmental-treatment device. En *2018 European Control Conference (ECC)*, páginas 997–1002. IEEE, 2018.

- [70] WANG, X., LIU, Y. y XIN, H. Bond strength prediction of concrete-encased steel structures using hybrid machine learning method. En *Structures*, vol. 32, páginas 2279–2292. Elsevier, 2021.
- [71] WHITTLE, M. W. *Gait analysis: an introduction*. Butterworth-Heinemann, 2014.
- [72] XING, Z., GUO, H., DONG, S., FU, Q. y LI, J. Rbf neural network based on k-means algorithm with density parameter and its application to the rainfall forecasting. En *Computer and Computing Technologies in Agriculture VIII: 8th IFIP WG 5.14 International Conference, CCTA 2014, Beijing, China, September 16-19*, páginas 218–225. Springer, 2015.
- [73] XU, H., LIU, J., HU, H. y ZHANG, Y. Wearable sensor-based human activity recognition method with multi-features extracted from hilbert-huang transform. *Sensors*, vol. 16(12), página 2048, 2016.
- [74] ZHANG, C. y LU, Y. Study on artificial intelligence: The state of the art and future prospects. *Journal of Industrial Information Integration*, vol. 23, página 100224, 2021.
- [75] ZHANG, Z., CUI, P. y ZHU, W. Deep learning on graphs: A survey. *IEEE Transactions on Knowledge and Data Engineering*, vol. 34(1), páginas 249–270, 2020.
- [76] ZILANI, T. A., AL-TURJMAN, F., KHAN, M. B., ZHAO, N. y YANG, X. Monitoring movements of ataxia patient by using uwb technology. *Sensors*, vol. 20(3), página 931, 2020.