



**UNIVERSIDAD PONTIFICIA BOLIVARIANA
ESCUELA DE INGENIERÍA
FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA**

**ESTIMACIÓN DE PARÁMETROS CARACTERÍSTICOS DEL CICLO DE
MARCHA UTILIZANDO TÉCNICAS DE APRENDIZAJE DE MÁQUINA**

MARIO EARLES OTERO ANDRADE

PROYECTO DE GRADO

**BUCARAMANGA
2020**



**UNIVERSIDAD PONTIFICIA BOLIVARIANA
ESCUELA DE INGENIERÍA
FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA**

**ESTIMACIÓN DE PARÁMETROS CARACTERÍSTICOS DEL CICLO DE
MARCHA UTILIZANDO TÉCNICAS DE APRENDIZAJE DE MÁQUINA**

MARIO EARLES OTERO ANDRADE

PROYECTO DE GRADO

Presentado ante la Universidad Pontificia Bolivariana
Como requisito para optar al título de

INGENIERO ELECTRÓNICO

Realizado con la asesoría de:

MSc. Silvia Alejandra Sotelo López

**BUCARAMANGA
2020**

DEDICATORIA

Este gran logro en mi vida es dedicado a mi padre, Mariano Earles Otero Benedetty, mi madre, Maria Victoria Andrade Niño, y mi hermano, Victor Manuel Otero Andrade. Gracias por su amor, su apoyo incondicional, la forma única en que saben animarme a seguir adelante sin importar los obstáculos y todo lo que me han enseñado, ustedes han aportado inmensamente a este logro. Definitivamente cada una de las mil y un risas que esta tesis nos ha sacado han valido totalmente la pena.

A Jelitza Castillo, por ser lo inimaginable en mi vida. Gracias por todo el amor y apoyo que me has brindado, por esas fuerzas para continuar cuando el camino se hace más difícil y ser luz en la oscuridad.

Mario Earles Otero Andrade

AGRADECIMIENTOS

A MSc. Silvia Sotelo, por el apoyo incondicional brindado en esta etapa tan importante, su paciencia y seguimiento durante el desarrollo de este trabajo sin importar las dificultades que surgieran permitió llevar a buen término este proyecto.

Al Dr. Miguel Altuve, por presentarme este mundo especial y único de la investigación, porque con su experiencia, su confianza, su apoyo y sus consejos me ayudó a crecer personal, académica y científicamente, obteniendo buenos resultados y momentos para no olvidar.

A todas las personas que han pasado por mi vida, esas que me han brindado infinidad de experiencias que me han permitido aprender a lo largo de estos años y formar el ser humano que soy.

A la Universidad Pontificia Bolivariana, Sede Central y todas sus seccionales, al programa nacional de formación de Líderes UPB, la experiencia vivida en estos años en mi universidad, recorriéndola por todo el país, aprendiendo y conociendo a muchas personas, queda indudablemente plasmado en mí su sello bolivariano.

Y mi familia, esa que siempre ha sido, es y será mi norte, infinitas gracias por tanto apoyo, porque sin todas sus enseñanzas y su amor incondicional no estaría donde me encuentro.

TABLA DE CONTENIDOS

	Pág.
Contenido	
INTRODUCCIÓN.....	1
1. PLANTEAMIENTO DEL PROBLEMA	4
1.1 Definición del problema.....	4
1.2 Antecedentes.....	7
1.3 Objetivos	11
1.3.1 Objetivo general.....	11
1.3.2 Objetivos específicos	11
1.4 Justificación.....	12
2. MARCO TEÓRICO.....	14
2.1 Cinética de la marcha humana.....	14
2.1.1 Ciclo de la marcha	14
2.1.2 Parámetros espaciotemporales de la marcha	18
2.1.3 Parámetros clínicos de la marcha y su importancia	23
2.1.4 Examen y análisis de la marcha.....	25
2.2 Dispositivos para la medición de la marcha	28
2.3 Dispositivos para la medición de parámetros de la marcha	32
2.3.1 Sistema IMU.....	32

2.3.2	Apple Watch.....	33
2.3.3	G-WALK.....	34
2.4	Aprendizaje de máquina.....	35
2.4.1	Regresión.....	38
2.4.2	Máquinas de vectores de soporte.....	39
2.4.3	Árboles de decisión.....	39
2.4.4	Bosques aleatorios	40
2.4.5	Redes neuronales	40
2.4.6	Aprendizaje profundo	41
2.4.7	Medidas de desempeño	42
2.5	Análisis exploratorio de datos	45
3.	METODOLOGÍA.....	47
3.1	Base de datos.....	48
3.2	Pre - Procesamiento de las señales y extracción de características	60
3.3	Desarrollo de un estimador de parámetros usando aprendizaje de máquina	76
3.3.1	Análisis exploratorio de datos	76
3.3.2	Diseño de los estimadores	83
4.	RESULTADOS.....	87
4.1	Regresión lineal simple	87
4.2	Regresión lineal múltiple	92
4.3	Árboles de decisión.....	103
4.4	Bosques aleatorios	114

4.5 Máquinas de soporte vectorial.....	126
5. DISCUSIÓN DE RESULTADOS	138
6. CONCLUSIONES Y RECOMENDACIONES	146
LISTA DE REFERENCIAS	152
BIBLIOGRAFÍA.....	163
ANEXO A. OPTIMIZACIÓN DE HIPERPARÁMETROS	168
A.1 Árboles de decisión.....	168
A.2 Bosques aleatorios	172
A.3 Máquinas de soporte vectorial	175
ANEXO B. TABLAS DE DESEMPEÑO	179
B.1 Regresión lineal múltiple.....	179
B.2 Árboles de decisión	180
B.3 Bosques aleatorios.....	181
B.4 Máquinas de soporte vectorial	182

LISTA DE TABLAS

Tabla 1. Fase de apoyo de la marcha y su división	16
Tabla 2. Fase de balanceo de la marcha y su división.....	17
Tabla 3. Síntesis de los parámetros de la marcha en aplicaciones clínicas y de acuerdo con el tipo de problema patológico	24
Tabla 4. Parámetros obtenidos de los diferentes dispositivos	52
Tabla 5. Magnitudes físicas obtenidas por los diferentes dispositivos.....	77
Tabla 6. Características extraídas de las señales de los dispositivos	77
Tabla 7. Características extraídas de las señales de los dispositivos y su respectivo coeficiente de Pearson con la Velocidad del Paso.....	79
Tabla 8. Características extraídas de las señales de los dispositivos y su respectivo coeficiente de Pearson con la Longitud de Zancada.....	80
Tabla 9. Características extraídas de las señales de los dispositivos y su respectivo coeficiente de Pearson con la Velocidad del Paso.....	81
Tabla 10. Diseño de los estimadores	83
Tabla 11. Grupos de las características extraídas del GWALK.....	84
Tabla 12. Grupos de las características extraídas del sistema IMU	84
Tabla 13. Grupos de las características extraídas del sistema Apple Watch	85
Tabla 14. Características de los hiperparámetros.....	86
Tabla 15. Mejores desempeños de la regresión lineal para el GWALK	88
Tabla 16. Descripción de las características extraídas del GWALK	88
Tabla 17. Mejores desempeños de la regresión lineal para el sistema IMU.....	89

Tabla 18. Descripción de las características extraídas del sistema IMU	90
Tabla 19. Mejores desempeños de la regresión lineal para el sistema Apple Watch.....	91
Tabla 20. Descripción de las características extraídas del sistema Apple Watch.....	91
Tabla 21. Mejores desempeños de la regresión lineal múltiple para el GWALK	93
Tabla 22. Mejores desempeños de la regresión lineal múltiple para el sistema IMU.....	96
Tabla 23. Mejores desempeños de la regresión lineal múltiple para el sistema Apple Watch.....	100
Tabla 24. Mejores desempeños de los árboles de decisión para el GWALK.....	104
Tabla 25. Mejores desempeños de los árboles de decisión para el sistema IMU	108
Tabla 26. Mejores desempeños de los árboles de decisión para el sistema Apple Watch	111
Tabla 27. Mejores desempeños de los bosques aleatorios para el GWALK.....	116
Tabla 28. Mejores desempeños de los bosques aleatorios para el sistema IMU	120
Tabla 29. Mejores desempeños de los bosques aleatorios para el sistema Apple Watch	123
Tabla 30. Mejores desempeños de las máquinas de soporte vectorial para el GWALK	128
Tabla 31. Mejores desempeños de las máquinas de soporte vectorial para el sistema IMU	131
Tabla 32. Mejores desempeños de las máquinas de soporte vectorial para el sistema Apple Watch.....	135
Tabla 33. Desempeños obtenidos con el coeficiente de determinación R^2 en la estimación	138
Tabla 34. Precisión encontrada en la medición del GWALK.....	141

Tabla 35. Desempeños obtenidos con la raíz del error cuadrático medio en la estimación	143
Tabla 36. Desempeños obtenidos con el error cuadrático medio en la estimación	143
Tabla 37. Desempeños obtenidos con el error absoluto medio en la estimación	143
Tabla 38. Tiempos para la optimización de hiperparámetros	144
Tabla 39. Comparación de resultados obtenidos con otros autores	145
Tabla 40. Optimización de hiperparámetros para el GWALK	168
Tabla 41. Optimización de hiperparámetros para el sistema IMU.....	169
Tabla 42. Optimización de hiperparámetros para el sensor IMU izquierdo.....	169
Tabla 43. Optimización de hiperparámetros para el sensor IMU derecho	170
Tabla 44. Optimización de hiperparámetros para el sistema Apple Watch.....	170
Tabla 45. Optimización de hiperparámetros para el Apple Watch izquierdo.....	171
Tabla 46. Optimización de hiperparámetros para el Apple Watch derecho	171
Tabla 47. Optimización de hiperparámetros para el GWALK	172
Tabla 48. Optimización de hiperparámetros para el sistema IMU.....	172
Tabla 49. Optimización de hiperparámetros para el sensor IMU izquierdo.....	173
Tabla 50. Optimización de hiperparámetros para el sensor IMU derecho	173
Tabla 51. Optimización de hiperparámetros para el sistema Apple Watch.....	174
Tabla 52. Optimización de hiperparámetros para el Apple Watch izquierdo.....	174
Tabla 53. Optimización de hiperparámetros para el Apple Watch derecho	175
Tabla 54. Optimización de hiperparámetros para el GWALK	175
Tabla 55. Optimización de hiperparámetros para el sistema IMU.....	176

Tabla 56. Optimización de hiperparámetros para el sensor IMU izquierdo.....	176
Tabla 57. Optimización de hiperparámetros para el sensor IMU derecho	177
Tabla 58. Optimización de hiperparámetros para el sistema Apple Watch.....	177
Tabla 59. Optimización de hiperparámetros para el Apple Watch izquierdo.....	178
Tabla 60. Optimización de hiperparámetros para el Apple Watch derecho	178
Tabla 61. Desempeño del GWALK	179
Tabla 62. Desempeño del sistema IMU	179
Tabla 63. Desempeño del sistema Apple Watch.....	179
Tabla 64. Desempeño del GWALK	180
Tabla 65. Desempeño del sistema IMU	180
Tabla 66. Desempeño del sistema Apple Watch.....	180
Tabla 67. Desempeño del GWALK	181
Tabla 68. Desempeño del sistema IMU	181
Tabla 69. Desempeño del sistema Apple Watch.....	181
Tabla 70. Desempeño del GWALK	182
Tabla 71. Desempeño del sistema IMU	182
Tabla 72. Desempeño del sistema Apple Watch.....	182

LISTA DE FIGURAS

Figura 1. Representación de las principales componentes de la marcha.....	15
Figura 2. Fases del ciclo de la marcha durante el periodo de soporte.....	17
Figura 3. Fases del ciclo de la marcha durante el periodo de balanceo	18
Figura 4. Longitudes de paso largo o zancada y paso corto	21
Figura 5. Parámetros espaciales de la marcha	22
Figura 6. Enfoques y sistemas de medición de la marcha	32
Figura 7. Apple Watch Series 3	33
Figura 8. Kit del dispositivo G-WALK.....	34
Figura 9. Tipos de aprendizaje de máquina supervisado.....	36
Figura 10. Medidas de desempeño.....	45
Figura 11. Desarrollo del trabajo de grado	48
Figura 12. Protocolo experimental para la adquisición de la base de datos	49
Figura 13. Localización de los dispositivos utilizados en la adquisición de la base de datos en un sujeto con sus respectivos ejes.....	50
Figura 14. Señales adquiridas con el dispositivo IMU.....	54
Figura 15. Señales adquiridas con el dispositivo G-WALK.....	55
Figura 16. Señales adquiridas con el dispositivo Apple Watch.....	56
Figura 17. Representación de distribuciones de frecuencias correspondientes al género, edad y altura de los sujetos que conforman la base de datos	58

Figura 18. Representación de distribuciones de frecuencias correspondientes al peso, al índice de masa corporal (IMC) y a la clasificación del índice de masa corporal (IMC) de los sujetos que conforman la base de datos	59
Figura 19. Proceso realizado para el procesamiento de las señales de la base de datos ...	61
Figura 20. Señales originales del Sujeto 1 en la 1ra prueba realizada correspondientes a la Velocidad angular en el eje X de los diferentes dispositivos.....	63
Figura 21. Señales sincronizadas del Sujeto 1 en la 1ra prueba realizada correspondientes a la Velocidad angular en el eje X de los diferentes dispositivos	64
Figura 22. Señal original del Sujeto 1 en la 1ra prueba realizada correspondientes a la Velocidad angular en el eje X del dispositivo GWALK	65
Figura 23. Señal de referencia y señal a segmentar	66
Figura 24. Señal de referencia con su respectiva envolvente superior e inferior	67
Figura 25. Detección de picos en la envolvente superior de la señal de referencia	68
Figura 26. Picos de interés obtenidos luego de la umbralización de los mismos	69
Figura 27. Señal de referencia con su respectiva envolvente superior y su derivada	70
Figura 28. Ventana de 300 muestras en donde se halla el inicio y final de un segmento .	70
Figura 29. Segmento final extraído de la señal.....	71
Figura 30. Representación gráfica del proceso realizado para extraer los segmentos	71
Figura 31. Características de la Aceleración Lineal en el Eje X de los diferentes dispositivos con respecto a la Velocidad del Paso	79
Figura 32. Características de la Aceleración Lineal en el Eje X de los diferentes dispositivos con respecto a la Longitud de Zancada	80

Figura 33. Características de la Velocidad Angular en el Eje Z de los diferentes dispositivos con respecto a la Velocidad del Paso	82
Figura 34. Coeficiente R^2 vs Características del GWALK	93
Figura 35. Residuos vs Valores predichos de la Cadencia con el GWALK.....	94
Figura 36. Residuos vs Valores predichos de la Velocidad con el GWALK.....	95
Figura 37. Residuos vs Valores predichos de la Longitud de Zancada con el GWALK ..	95
Figura 38. Coeficiente R^2 vs Características del sistema IMU	97
Figura 39. Residuos vs Valores predichos de la Cadencia con el sistema IMU	98
Figura 40. Residuos vs Valores predichos de la Velocidad con el sistema IMU	98
Figura 41. Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU	99
Figura 42. Coeficiente R^2 vs Características del sistema Apple Watch.....	100
Figura 43. Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch	101
Figura 44. Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch	102
Figura 45. Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch.....	102
Figura 46. Coeficiente R^2 vs Características del GWALK	105
Figura 47. Residuos vs Valores predichos de la Cadencia con el GWALK.....	106
Figura 48. Residuos vs Valores predichos de la Velocidad con el GWALK.....	106
Figura 49. Residuos vs Valores predichos de la Longitud de Zancada con el GWALK	107
Figura 50. Coeficiente R^2 vs Características del sistema IMU	108

Figura 51. Residuos vs Valores predichos de la Cadencia con el sistema IMU	109
Figura 52. Residuos vs Valores predichos de la Velocidad con el sistema IMU	110
Figura 53. Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU	110
Figura 54. Coeficiente R^2 vs Características del sistema Apple Watch	112
Figura 55. Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch	113
Figura 56. Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch	113
Figura 57. Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch.....	114
Figura 58. Coeficiente R^2 vs Características del GWALK	117
Figura 59. Residuos vs Valores predichos de la Cadencia con el GWALK.....	118
Figura 60. Residuos vs Valores predichos de la Velocidad con el GWALK.....	118
Figura 61. Residuos vs Valores predichos de la Longitud de Zancada con el GWALK	119
Figura 62. Coeficiente R^2 vs Características del sistema IMU	120
Figura 63. Residuos vs Valores predichos de la Cadencia con el sistema IMU	121
Figura 64. Residuos vs Valores predichos de la Velocidad con el sistema IMU	122
Figura 65. Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU	122
Figura 66. Coeficiente R^2 vs Características del sistema Apple Watch	124
Figura 67. Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch	125

Figura 68. Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch	125
Figura 69. Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch.....	126
Figura 70. Coeficiente R^2 vs Características del GWALK	128
Figura 71. Residuos vs Valores predichos de la Cadencia con el GWALK.....	129
Figura 72. Residuos vs Valores predichos de la Velocidad con el GWALK	130
Figura 73. Residuos vs Valores predichos de la Longitud de Zancada con el GWALK	130
Figura 74. Coeficiente R^2 vs Características del sistema IMU	132
Figura 75. Residuos vs Valores predichos de la Cadencia con el sistema IMU	133
Figura 76. Residuos vs Valores predichos de la Velocidad con el sistema IMU	133
Figura 77. Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU	134
Figura 78. Coeficiente R^2 vs Características del sistema Apple Watch	135
Figura 79. Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch	136
Figura 80. Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch	137
Figura 81. Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch.....	137

RESUMEN GENERAL DE TRABAJO DE GRADO

TITULO: ESTIMACIÓN DE PARÁMETROS CARACTERÍSTICOS DEL CICLO DE MARCHA UTILIZANDO TÉCNICAS DE APRENDIZAJE DE MÁQUINA

AUTOR(ES): Mario Earles Otero Andrade

PROGRAMA: Facultad de Ingeniería Electrónica

DIRECTOR(A): Silvia Alejandra Sotelo López

RESUMEN

El análisis de la marcha humana permite identificar y diagnosticar oportunamente diversas patologías, donde un correcto tratamiento y rehabilitación permitiría dar a las personas con dificultades motoras mejor calidad de vida. Para realizar un estudio completo y detallado de la marcha, es necesaria una infraestructura y equipos adecuados, estos pueden presentar costos elevados. Por lo anterior, en este trabajo se realiza la estimación automática de parámetros espaciotemporales de la marcha, tales como cadencia del paso, velocidad del paso y longitud de zancada, empleando señales relacionadas con la cinética de la misma (aceleración lineal y velocidad angular en cada uno de los ejes), utilizando técnicas de aprendizaje de máquina supervisado. En este trabajo se consideran señales adquiridas por tres dispositivos, dos comerciales, tales como el GWALK y el Apple Watch, y otro basado en sensores IMU, de bajo costo, desarrollado en el grupo de investigación BISEMIC. Esta base de datos, adquirida por el mismo grupo, está compuesta por 58 registros de señales inerciales adquiridos de 33 voluntarios. En primer lugar, las señales fueron preprocesadas para luego extraer de ellas características espaciales y no lineales. Posteriormente, se crearon grupos de características, que fueron los datos de entrada, para desarrollar diferentes estimadores de cadencia, velocidad y longitud de zancada. Esto fue desarrollado en Python, utilizando la librería Scikit-Learn. El mejor algoritmo para la estimación de todos los parámetros, en todos los dispositivos, fue máquinas de soporte vectorial; destacando los resultados obtenidos en la estimación de cadencia ($R^2=0,866$), velocidad ($R^2=0,868$) y longitud de zancada ($R^2=0,824$) utilizando el dispositivo basado en IMU. Estos resultados abren el panorama a trabajos futuros que permitan realizar la estimación de otros parámetros espaciotemporales de la marcha con dispositivos de bajo costo, de manera que puedan ser utilizados para una evaluación cuantitativa de la marcha.

PALABRAS CLAVE:

Marcha humana, Aprendizaje de máquina, Estimación de parámetros de marcha

V° B° DIRECTOR DE TRABAJO DE GRADO

GENERAL SUMMARY OF WORK OF GRADE

TITLE: ESTIMATION OF CHARACTERISTIC PARAMETERS OF THE GAIT CYCLE USING MACHINE LEARNING TECHNIQUES

AUTHOR(S): Mario Earles Otero Andrade

FACULTY: Facultad de Ingeniería Electrónica

DIRECTOR: Silvia Alejandra Sotelo López

ABSTRACT

The analysis of human gait allows the timely identification and diagnosis of various pathologies, where a correct treatment and rehabilitation would allow to provide people with motor difficulties a better quality of life. To carry out a complete and detailed study of the human gait, it is necessary to have an adequate infrastructure and equipment, which can have high costs. Therefore, in this research, the automatic estimation of spatial-temporal parameters of walking is carried out, such as step cadence, step speed and stride length, using signals related to the kinetics of walking (linear acceleration and angular speed in each of the axis), by means of supervised machine learning techniques. This work considers signals acquired by three devices, two of commercial brands, GWALK and Apple Watch, and another one with a low cost, based on IMU sensors developed by the BISEMIC research group. This database, acquired by the same group, is composed by 58 records of inertial signals acquired from 33 volunteers. First, the signals were pre-processed to then extract spatial and non-linear characteristics from them. Then, groups of characteristics were created, which were the input data, to develop different estimators of cadence, speed and stride length. This was developed in Python, using the Scikit-Learn library. The best algorithm for the estimation of all parameters in all devices, was support vector machines; highlighting the results obtained in the estimation of cadence ($R^2=0,866$), speed ($R^2=0,868$) and stride length ($R^2=0,824$) using the IMU-based device. These results widen the outlook for future research that will allow the estimation of other spatial-temporal parameters of gait with low-cost devices, so that they can be used for a quantitative evaluation of gait.

KEYWORDS:

Human gait, Machine learning, Estimation of gait parameters



V° B° DIRECTOR OF GRADUATE WORK

INTRODUCCIÓN

El estudio de la marcha humana permite evaluar diferentes tipos de patologías, donde el tratamiento y rehabilitación permitiría dar a las personas con dificultades motoras mejor calidad de vida (Collado, 2004; Mock & Sweeting, 2007). La existencia de estas incomodidades generan en las personas posturas físicas incorrectas, además enfermedades que afectan el organismo causando un decaimiento general como obesidad, patologías respiratorias, cánceres (Vismara et Al., 2007), o incluso problemas psicológicos o psiquiátricos como cuadros depresivos (Van Iersel, Haitsma, Olde Rikkert & Benraad, 2005).

Un correcto estudio de la marcha y sus parámetros espaciotemporales (Daza, 2007, p.262) necesita de infraestructura y equipos adecuados para realizar una evaluación cuantitativa de la misma, esto puede no suceder por los elevados costos en los dispositivos utilizados, por lo tanto, la evaluación de la marcha se hace de forma cualitativa, esto impide tener un diagnóstico de mayor calidad y la posibilidad de extraer más información acerca del sujeto, que contribuiría directamente al mejoramiento en el diagnóstico de patologías y selección de terapias de rehabilitación de pacientes.

Existen estudios donde se busca realizar la estimación de parámetros de marcha que pueden proporcionar información acerca de las patologías que presenta un sujeto, estas pueden ser neurológicas, musculo-esqueléticas y circulatorias (Tabla 3), estos utilizan técnicas clásicas como lo son la regresión lineal y la regresión múltiple, empleadas en los trabajos (Stansfield, B. W. et Al, 2006; Dixon, P. C. et Al, 2014; Wahid, F. et Al, 2016;

Jena, S. et Al, 2017; Mikos, V. et Al, 2018; Braga, J. et Al, 2020), en los cuales se realiza estimación de parámetros espaciotemporales de la marcha (Tabla 39).

Teniendo en cuenta el auge que tienen las técnicas de aprendizaje de máquina, en este caso se propone evaluar que tan conveniente resulta considerar estas técnicas para la estimación. En concordancia a lo presentado anteriormente se propone estimar la cadencia, la longitud de zancada y la velocidad del ciclo de marcha basado en técnicas de aprendizaje de máquina usando señales adquiridas a partir de diferentes dispositivos. La base de datos utilizada fue desarrollada en el grupo de investigación en Bioingeniería, Señales y Microelectrónica – BISEMIC y está conformada por señales provenientes de tres sistemas para la medición de la marcha: el GWALK, sistema de referencia para este trabajo, se encuentra certificado medicamente para realizar esta medición, el sistema IMU, un sistema de bajo costo desarrollado por completo en el grupo BISEMIC (Vargas, 2017) y el sistema Apple Watch, también desarrollado en el grupo BISEMIC.

Este documento se encuentra estructurado de la siguiente forma:

En el capítulo 1 se presenta el planteamiento del problema. Inicialmente se explica el problema, luego se muestran los trabajos realizados anteriormente por otros autores para así proponer el objetivo general y los objetivos específicos del trabajo, y para finalizar se da a conocer la justificación del trabajo hecho.

En el capítulo 2 se exhibe el marco teórico que permite comprender el trabajo realizado. Expone la teoría relacionada con la cinética de la marcha humana y los dispositivos utilizados para su medición, algunas técnicas de regresión de aprendizaje automático

supervisado que pueden utilizarse para resolver problemas de estimación, y, por último, las medidas de desempeño aplicadas.

En el capítulo 3 se plantea la metodología con la que se realizó este trabajo de investigación. Se describe completamente los procedimientos realizados en cada una de las fases del trabajo: revisión de la base de datos, preprocesamiento de las señales y extracción de las características, análisis exploratorio de los datos y desarrollo de los estimadores de parámetros espaciotemporales de la marcha. Esto con el fin de dar claridad de la investigación hecha, con ello mostrar cómo pueden otros investigadores reproducir el mismo proceso y así generar resultados similares a los presentados en este trabajo.

En el capítulo 4 se muestran en detalle los resultados obtenidos en este proyecto. Aquí se encuentran los desempeños conseguidos por los diferentes algoritmos de aprendizaje de máquina empleados para la estimación.

En el capítulo 5 se analizan los resultados, dando importancia no únicamente al cumplimiento del objetivo propuesto, sino también resaltando los diversos hallazgos logrados y la interpretación de los mismos, y la comparación con otras investigaciones realizadas.

Por último, en el capítulo 6 se finaliza el documento presentando las conclusiones del trabajo llevado a cabo, recomendaciones y trabajos que pueden surgir a futuro.

CAPÍTULO 1

PLANTEAMIENTO DEL PROBLEMA

1.1 Definición del problema

Hoy en día la marcha humana y su estudio permite evaluar diferentes tipos de patologías, estas pueden ser temporales o definitivas, locales o generales, donde el tratamiento y rehabilitación permitiría dar a las personas con dificultades motoras mejor calidad de vida (Collado, 2004; Mock & Sweeting, 2007); adicional a ello, otros tipos de dolencias que se ven implicados en la marcha también son valorados. La presencia de molestias hace que los sujetos empiecen a tomar posturas físicas incorrectas, además enfermedades que afectan el organismo causando un decaimiento general como obesidad, patologías respiratorias, edad, cánceres (Vismara et Al., 2007), o incluso problemas psicológicos o psiquiátricos como cuadros depresivos (Van Iersel, Haitsma, Olde Rikkert & Benraad, 2005).

Para realizar un estudio completo y detallado, es necesario contar con la infraestructura y equipos adecuados, los cuales se pueden localizar y ser utilizados en el respectivo laboratorio de marcha. Allí se podrá garantizar que mediante un conjunto de herramientas se tomarán los datos necesarios y se llevara a cabo un examen cuantitativo de los patrones de movimiento. La información obtenida facilita el diagnóstico, tratamiento, seguimiento e implementación de métodos de rehabilitación en patologías asociadas con el movimiento (Carrillo, Jaramillo & Castro, 2010).

Los centros de rehabilitación física requieren de herramientas para hacer una evaluación cuantitativa del progreso de sus pacientes, es decir, poder tomar datos de variables de la marcha como lo son las fases del ciclo de la marcha, periodo de paso, cadencia, velocidad, longitud de zancada y de paso, entre otros, para así aumentar la calidad del diagnóstico y las posibilidades de extraer conclusiones acerca de la evolución de un paciente en rehabilitación; sin embargo, muchos carecen de herramientas, como un laboratorio de marcha, que les permita tener un registro de estas variables, y por lo tanto la evaluación de la marcha se hace, frecuentemente, de forma cualitativa.

Analizar la marcha humana permite identificar y diagnosticar oportunamente diversas patologías que se presentan, esto se logra con el estudio adecuado de los parámetros de la marcha humana necesarios para realizar la evaluación de la misma. Para conseguir una correcta evaluación se hace necesario procesar apropiadamente las señales obtenidas en las pruebas de marcha para poder extraer la información que entrega el sujeto, además determinar si presenta alguna patología, esto se puede realizar mediante técnicas de aprendizaje de máquina, dando la posibilidad de generar reportes robustos del estado en que se encuentra el paciente.

Uno de los primeros autores en realizar trabajos relevantes en marcha humana utilizando aprendizaje de máquina se encuentra Begg (2005) quien investigó la aplicación de un enfoque de aprendizaje de máquina (Support vector machine, SVM) para el reconocimiento automático de los cambios de la marcha debido al envejecimiento utilizando tres tipos de medidas de la marcha: básica temporal / espacial, cinética y cinemática.

También es conocido que la clasificación de los patrones de marcha tiene un gran potencial como herramienta de diagnóstico, por ejemplo, para el diagnóstico de lesiones o para identificar la marcha en riesgo en los ancianos. En este tema de importancia en la marcha Eskofier (2013) presenta un método para clasificar las diferencias grupales en el patrón de la marcha utilizando la información espacial y temporal completa del movimiento del segmento cuantificado por marcadores. Las tasas de clasificación que se obtienen se comparan con estudios previos que utilizan características de clasificación convencionales.

Autores como Horst (2019) estudian la singularidad de los patrones de marcha individuales en biomecánica clínica utilizando redes neuronales profundas. Al atribuir porciones de las predicciones del modelo a las variables de entrada (fuerzas de reacción del suelo y ángulos de articulación de cuerpo completo), la técnica de Propagación de relevancia en capas (LRP) demuestra de manera confiable qué variables en qué momento de las ventanas del ciclo de la marcha son más relevantes para la caracterización de los patrones de marcha de un determinado individuo.

Por lo anterior, se pretende contribuir al mejoramiento en el diagnóstico de patologías y selección de terapias de rehabilitación de pacientes, a partir de la estimación automática de parámetros de marcha, tales como cadencia del paso, velocidad, longitud de zancada, entre otros, utilizando señales relacionadas con la cinética de la misma que son adquiridas empleando dispositivos no comerciales de bajo costo. A partir de estas señales se realiza un preprocesamiento que permita tener una adecuada base de datos para luego proceder a

realizar extracción de diferentes características de las señales y con ellas a partir de técnicas de aprendizaje de maquina lograr la estimación automática de parámetros de marcha.

1.2 Antecedentes

El patrón de marcha humana tiene una variedad de parámetros, que van desde los más básicos hasta los más complejos, con ellos se puede caracterizar la marcha de un sujeto; siendo el modo más sencillo la descripción de la marcha utilizando los parámetros espaciotemporales. Estos parámetros no siempre son constantes, pueden variar entre sujetos y también en el mismo sujeto, solo cuando se mantienen las condiciones y factores que afectan a la marcha, como la edad, la altura, el peso, la fatiga, el terreno, entre otros, se dice que los parámetros resultan ser representativos (Collado, 2004). El análisis espaciotemporal de estos parámetros, así como las demás características espaciotemporales de la marcha permiten un estudio detallado de esta actividad física (Cámara, 2011).

Actualmente existen en el mercado sistemas que posibilitan el análisis de la marcha humana, estos se utilizan principalmente para las terapias de rehabilitación, permitiendo monitorear durante las pruebas determinados parámetros espaciotemporales de la marcha y con ello realizar un seguimiento a la evolución del paciente. Entre las empresas más reconocidas por el desarrollo de sistemas comerciales para analizar la marcha se encuentra NORAXON (NORAXON, 2017). Entre sus desarrollos se encuentra MyoVideo, que es un sistema de análisis por video con software de vanguardia que permite el rastreo automático de ángulos; el sistema MyoPressure, el cual consta de una caminadora adaptada para medir la distribución de la fuerza/presión mientras se está parado, caminando o corriendo; otro desarrollo es MyoMotion, el cual es un sistema cinemático de cuerpo completo en 3D en

el cual los sensores miniatura de NORAXON son colocados en los segmentos elegidos del usuario (pueden ser cabeza, brazo superior/inferior, manos, tórax, tronco, pelvis, muslos, espinillas y pies) para procesar y mostrar toda la información cinemática y cinética de estos segmentos en tiempo real y por último se encuentra el sistema MyoMuscle, el cual permite medir hasta 32 músculos de forma inalámbrica. Además, una variedad de sensores biomecánicos, como goniómetros, interruptores de pie, acelerómetros, y de ritmo cardíaco/respiratorio pueden ser añadidos (Kim & Lee, 2013).

Otros sistemas comerciales que permiten el análisis de la marcha fueron desarrollados por la compañía suiza Kistler (KISTLER, 2015), la cual es líder mundial en tecnología de medición dinámica de presión, fuerza, par y aceleración con las diferentes plataformas de fuerza que venden actualmente, y la compañía inglesa Vicon (VICON, 2018) ellos han desarrollado diferentes soluciones para el análisis de la marcha tanto en hardware y software, como lo son sensores inerciales, cámaras y visores de realidad aumentada. Estas dos últimas empresas han ofrecido sistemas que se pueden sincronizar y utilizar en conjunto para estudiar la marcha y con ello realizar aportes a la ciencia en este campo de estudio (Wiszomirska, Błażkiewicz, Kaczmarczyk, Brzuszkiewicz-Kuźmicka & Wit, 2017)

Uno de los sistemas comerciales desarrollados más cómodos y portables es el BTS G-WALK (BTS Bioengineering, 2017), el cual es un sistema inercial inalámbrico para la evaluación funcional de movimiento, el cual permite hacer test clínicos al paciente y obtener en poco tiempo los parámetros fundamentales y la cinemática de marcha, carrera y salto. Estos datos, esenciales en la rehabilitación, ayudan médicos y especialistas a

observar el estado del paciente y a evaluar la eficacia de terapias o programas de rehabilitación. El sensor se ubica en la parte baja de la espalda del sujeto y puede hacer la terapia en un laboratorio o en cualquier otro entorno; sin embargo, su costo resulta una desventaja para su acceso.

Entre las investigaciones que se han apoyado en esta tecnología se han realizado estudios en marcha normal y patológica. Cuando la marcha es normal, la Escuela Universitaria de Educación Física, Wrocław en su Laboratorio de Análisis Biomecánico se ha dedicado a establecer un patrón cinemático de la marcha adulta (Pietraszewski, Winiarski & Jaroszczuk, 2012); en el caso de afecciones neurológicas se encuentra el trabajo realizado para el estudio del riesgo de caída y desbalanceo dinámico en pacientes que padecen ataxia, llegando a la conclusión de que el G-WALK funciona eficientemente en la evaluación de la marcha y el balanceo cuando se presenta esta enfermedad (Caliandro, Conte, Iacovelli, Tatarelli, Castiglia, Reale & Serrao, 2019); también se ha trabajado en el caso de enfermedades neuromusculares, aquí se investigó los efectos de diferentes ayudas para caminar (bastón simple, muleta bilateral de antebrazo y Walker) sobre parámetros de marcha y análisis cinemático de la pelvis en pacientes con enfermedades neuromusculares adultas, concluyendo que en el proceso de determinar las ayudas para caminar se debe tener en cuenta la biomecánica del paciente, necesidades fisiológicas y psicosociales, expectativas, satisfacciones y niveles de independencia antes de proporcionar alguna ayuda para caminar (Demir & Yildirim, 2019).

Respecto al análisis de la marcha, Arellano-Gonzalez (2019) afirma que es una herramienta importante para la identificación y diagnóstico pertinente de enfermedades, así como para la evaluación y monitoreo de procedimientos de rehabilitación. Además, resalta que el campo de aplicación clínica es donde se utiliza la mayoría de los parámetros de la marcha humana reportados en la literatura. También observa que los parámetros espaciotemporales son los más comunes y permiten un estudio detallado y económico del proceso de la marcha humana, tanto normal como patológica, en las distintas áreas de aplicación.

Para analizar la marcha humana se han utilizado diferentes técnicas de aprendizaje de máquina para poder evaluar el efecto de la estimulación subtalámica en la enfermedad de Parkinson en la fuerza de reacción del suelo durante la marcha, además de poder clasificar sujetos que sufren de Parkinson, con y sin medicación, y sujetos normales comparando el desempeño de clasificación en redes neuronales probabilísticas, máquinas de soporte vectorial y regresión logística (Muniz et Al., 2010). También se ha identificado y clasificado tipos de enfermedades neurológicas y enfermedades neuromusculares (NND) o artritis idiopática juvenil (JIA). que afectan la marcha, ahorrando tiempo ya que esto se realizaba manualmente por un empleado y permitiendo que una clasificación efectiva facilite su recuperación futura (Joyseeree, Abou & Müller, 2015), igualmente se ha realizado la clasificación de la marcha para la detección de la enfermedad de Parkinson usando características espaciotemporales de la marcha, estos hallazgos ayudarán en el diagnóstico y el tratamiento de la Enfermedad de Parkinson utilizando características espaciotemporales de la marcha (Wahid, Begg, Hass, Halgamuge & Ackland, 2015).

1.3 Objetivos

1.3.1 Objetivo general

Estimar la cadencia, la longitud de zancada y la velocidad del ciclo de marcha basado en técnicas de aprendizaje de máquina usando señales adquiridas a partir de diferentes dispositivos.

1.3.2 Objetivos específicos

- Evaluar el estado de la base de datos adquirida en las pruebas de laboratorio, usando los dispositivos G-WALK, Apple Watch y Sistema IMU, realizadas en la Universidad Pontificia Bolivariana seccional Bucaramanga.
- Procesar las señales adquiridas por los diferentes dispositivos para la identificación y extracción de características espaciales y no lineales del ciclo de marcha.
- Entrenar diferentes algoritmos de aprendizaje de máquina supervisado utilizando las características extraídas de las señales para la estimación de la cadencia, la longitud de zancada y la velocidad del ciclo de marcha.
- Identificar las señales y el algoritmo que proporcionan el mejor desempeño en la estimación de parámetros de marcha a partir de métodos estadísticos.

1.4 Justificación

El análisis de la marcha humana es una herramienta que resulta ser de gran provecho para diversas prácticas, como lo son el diagnóstico y elección de tratamientos en pacientes con enfermedades neuro-músculo-esqueléticas. Actualmente hay diferentes tecnologías y procedimientos que permiten realizar correctamente este análisis y con ello la adquisición de los parámetros cuantitativos característicos de un patrón de marcha de manera objetiva. El análisis de marcha es un examen susceptible a muchas perturbaciones y en donde se deben considerar muchos factores para realizar este estudio de manera adecuada, estos factores van desde la etapa de configuración y planeación del laboratorio hasta el momento del análisis mismo de los resultados, sin dejar a un lado el desarrollo del examen de la marcha humana y el proceso de adquisición de los parámetros (Villa, Gutiérrez & Pérez, 2008).

En el mundo se está investigando acerca del uso de sensores inerciales para evaluar la marcha humana (Hak et Al., 2015; Isaacson, Swanson & Pasquina, 2013; Rábago, Dingwell & Wilken, 2015; Rampp et Al., 2014; Sloot, Van der Krogt & Harlaar, 2014; Wang et Al., 2014; Zhuang et Al., 2016). Esta alternativa es más económica y el paciente no debe ser grabado en video, lo que contribuye a que su patrón natural de marcha no se altere (Camargo, Garzón & Camacho, 2012).

Cabe resaltar que son pocos los laboratorios que en Colombia cuentan con sistemas de sensores inerciales para análisis de movimiento humano, adicional a ello la investigación acerca de estos sistemas para la medición de la marcha no está presente en muchas universidades del país (Agudelo, Briñez, Guarín, Ruiz & Zapata, 2013). También es

importante mencionar que en Colombia se han realizado pocos estudios para analizar la marcha humana usando técnicas de aprendizaje de máquinas, lo que permite sentar un precedente en este campo que tiene mucho potencial para ser explorado, además de ser un tema de actualidad e interés médico.

Con este trabajo se abre la oportunidad para comprobar si se pueden emplear sistemas no convencionales ni comerciales para la evaluación de la marcha humana; puesto que es muy común que la evaluación de la marcha sea hecha de forma cualitativa y sin tener ninguna historia cuantitativa que permita contrastar, con información verídica, el progreso o retroceso de una persona.

Con la realización de este proyecto se podrá evaluar el desempeño de un sistema para la medición de parámetros de la marcha humana que usa sensores IMU y fue desarrollado en el grupo de investigación Bioingeniería, Señales y Microelectrónica – BISEMIC (Vargas, 2017) con dispositivos comerciales tales como G-WALK y Apple Watch. Además de darle versatilidad al dispositivo desarrollado en los laboratorios de la universidad para realizar estimaciones de cantidades diferentes a las temporales, esto permitiría una mejora al poder estimar otros parámetros obtenidos en el tiempo. Asimismo, posibilita a futuro una interface para el usuario que le genere el reporte de interés. También, se establece un precedente al estudio de la marcha en pacientes con diferentes patologías ofreciendo a la UPB, afianzar el foco de investigación en salud y fortalecer la línea de trabajo en aprendizaje automático y procesamiento de señales del grupo de investigación Bioingeniería, Señales y Microelectrónica – BISEMIC que pertenece a la facultad de ingeniería eléctrica y electrónica.

CAPÍTULO 2

MARCO TEÓRICO

2.1 Cinética de la marcha humana

La marcha humana es un modo de locomoción bípeda con actividad alternada de los miembros inferiores, que se caracteriza por una sucesión de doble apoyo y de apoyo unipodal, es decir que durante la marcha el apoyo no deja nunca el suelo, mientras que, en la carrera, como en el salto, existen fases aéreas, en las que el cuerpo queda suspendido durante un instante. También se puede definir como un desequilibrio permanente hacia delante. Desde una óptica dinámica, la marcha es una sucesión de impulsos y frenados, en los que el motor o el impulso se sitúa a nivel del miembro inferior posterior y el frenado en el anterior. (Sanz, 2006, p.1)

2.1.1 Ciclo de la marcha

Dada la alta complejidad que se presenta para el análisis de la marcha, esta actividad humana se ha descrito generalmente en términos temporales de periodos y fases, para facilitar la descripción y el estudio de los eventos que se derivan en cada uno de ellos. Un ciclo de marcha es el periodo en el que se presentan acciones sucesivas, alternas y uniformes; se inicia en un evento específico hasta que se repite en el pie ipsilateral generalmente, se utiliza el contacto inicial para su descripción de inicio y culminación (Daza, 2007).

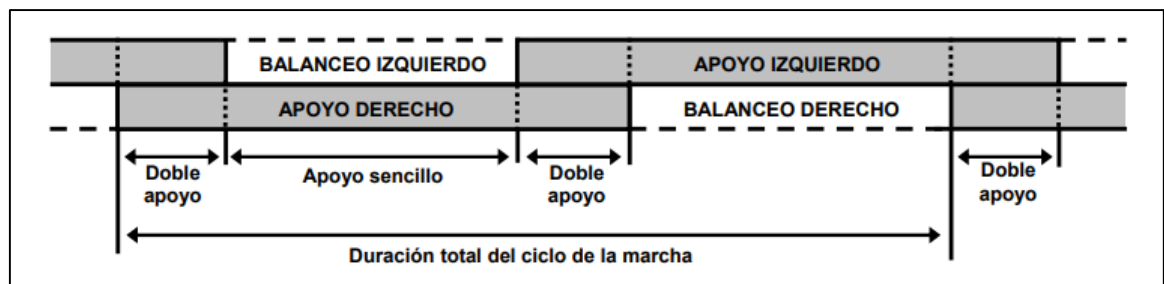
Como lo dice Vera (1999) citado por Hernández (2008)

El ciclo de marcha comienza cuando un pie hace contacto con el suelo y termina con el siguiente contacto del mismo pie; a la distancia entre estos dos puntos de contacto con el suelo se le llama un paso completo. También divide al ciclo de la marcha en dos principales componentes: la fase de apoyo y la fase de balanceo. Una pierna está en fase de apoyo cuando está en contacto con el suelo y después está en fase de balanceo cuando no contacta con el suelo.

Estas dos fases se van alternando de una pierna a la otra durante la marcha. En un paso completo, el apoyo sencillo se refiere al periodo cuando solo una pierna está en contacto con el suelo. El periodo de doble apoyo ocurre cuando ambos pies están en contacto con el suelo simultáneamente. La diferencia entre correr y caminar es la ausencia de un periodo de doble apoyo.

Figura 1

Representación de las principales componentes de la marcha



Nota. Adaptado de “Biomecánica de la marcha humana normal y patológica”, de Vera, P., 1999, Valencia, España: Instituto de Biomecánica de Valencia.

En su libro de Biomecánica de la marcha humana normal y patológica, el Dr. Vera (1999) del Instituto de Biomecánica de Valencia divide la fase de apoyo y la fase de balanceo en diferentes periodos, la información será presentada en las siguientes tablas y figuras.

Tabla 1


Fase de apoyo de la marcha y su división

Fase de Apoyo (62% del ciclo de la marcha)		
Periodo	Descripción	Duración y distribución porcentual
Contacto del talón	Instante en que el talón toca el suelo.	
Apoyo plantar	Contacto de la parte anterior del pie con el suelo.	10%
Apoyo medio	Momento en que el trocánter mayor se encuentra alineado verticalmente con el centro del pie, visto desde el plano sagital	20% (del 10% al 30%)
Elevación del talón	Instante en que el talón se eleva del suelo	20% (del 30% al 50%)
Despegue del pie	Momento en que los dedos se elevan del suelo	12% (del 50% al 62%)

Nota. Adaptado de “Biomecánica de la marcha humana normal y patológica”, de Vera, P., 1999, Valencia, España: Instituto de Biomecánica de Valencia.

Figura 2

Fases del ciclo de la marcha durante el periodo de soporte



Nota. Recuperado de “Evaluación clínico funcional del movimiento corporal. Capítulo 11: Examen de la marcha”, de Daza, J. 2007, p. 261, Bogotá, Colombia: Editorial Panamericana.

Tabla 2


Fase de balanceo de la marcha y su división

Fase de Balanceo (38% del ciclo de la marcha)		
Periodo	Descripción	Duración y distribución porcentual
Aceleración	Se caracteriza por la rápida aceleración del extremo de la pierna inmediatamente después que los dedos dejan el suelo	13% (del 62% al 75%)
Balanceo medio	La pierna en movimiento rebasa a la pierna de apoyo como un pendulo.	10% (del 75% al 85%)
Desaceleración	La pierna desacelera al acercarse al final del intervalo.	15% (del 85% al 100%)

Nota. Adaptado de “Biomecánica de la marcha humana normal y patológica”, de Vera, P., 1999, Valencia, España: Instituto de Biomecánica de Valencia.

Figura 3

Fases del ciclo de la marcha durante el periodo de balanceo



Nota. Recuperado de “Evaluación clínico funcional del movimiento corporal. Capítulo 11: Examen de la marcha”, de Daza, J. 2007, p. 262, Bogotá, Colombia: Editorial Panamericana.

2.1.2 Parámetros espaciotemporales de la marcha

El examen de la marcha debe permitir la cuantificación de parámetros temporales y espaciales que proporciona una descripción básica de la marcha de la persona. Sus resultados facilitan la relación con los datos obtenidos durante el proceso de evaluación del movimiento corporal humano y la identificación de deficiencias corporales que inciden en la marcha, y de limitaciones en esta actividad. (Daza, 2007, p.262)

A continuación, se presentan los parámetros temporales de la marcha, estos pueden valorarse con relativa facilidad en el examen por observación.

- Ciclo de la marcha: Lapso de tiempo en el que transcurren dos eventos idénticos sucesivos del mismo pie; generalmente, se selecciona el contacto inicial para su descripción de inicio y culminación. En este sentido, se registra el ciclo de

marcha de la extremidad inferior derecha e izquierda para establecer la comparación que permita identificar asimetrías. (Daza, 2007, p.263)

- Periodo de paso: Referido al intervalo de tiempo entre el contacto inicial de un pie y el mismo evento del pie contralateral. El registro comprende la medición de las dos extremidades. Cuando existe dolor en una extremidad inferior, la persona reduce considerablemente el tiempo de apoyo. (Daza, 2007, p.263)
- Periodo de soporte: Es el lapso de tiempo que pasa entre el instante en que el pie hace contacto con el piso (talón), hasta el momento del despegue de los dedos del mismo. De forma similar a los parámetros anteriores, requiere el registro bilateral. (Daza, 2007, p.263)
- Periodo de balanceo: Es el tiempo transcurrido entre el instante del despegue de los dedos del pie que pierden por completo la relación con el piso, hasta el punto del contacto del talón con el suelo. También exige el registro de las dos extremidades. (Daza, 2007, p.263)
- Frecuencia o cadencia: Este parámetro hace referencia al número de pasos por unidad de tiempo que, generalmente, se fija en un minuto. La frecuencia determina el ritmo y la rapidez de marcha que autoselecciona toda persona cuando camina naturalmente. Varía de acuerdo con la longitud de las extremidades, el peso corporal y la habilidad para caminar y, disminuye con el proceso de envejecimiento. (Daza, 2007, p.263)

- Velocidad: Es la relación de la distancia recorrida en la dirección de la marcha por unidad de tiempo ($\text{velocidad} = \text{distancia} / \text{tiempo}$), se expresa en metros sobre segundo (m/s). Constituye una variable que indica la habilidad para caminar. Establece una relación con la cadencia y la longitud del paso largo. (Daza, 2007, p.263)


Ahora se presentan los parámetros espaciales de la marcha, estos se deben explorar bilateralmente.

- Longitud de paso largo o zancada: Es la distancia lineal en metros entre dos eventos iguales y sucesivos de la misma extremidad. En ocasiones, se confunde con el ciclo de marcha, pero es determinante aclarar que uno es parámetro espacial, mientras que el otro es temporal, aunque sus definiciones parezcan similares. (Daza, 2007, p.263)
- Longitud de paso o paso corto: Es la distancia lineal en metros desde un evento específico, que, generalmente, es el contacto inicial de una extremidad hasta el mismo evento de la extremidad opuesta. La comparación de los registros que permite la medición, tanto del paso corto derecho como el izquierdo, proporciona información de la simetría de la marcha. (Daza, 2007, p.263)
- Ancho de paso: Está dado por la distancia lineal en centímetros entre dos puntos iguales de los pies. Es una variable directamente relacionada con la estabilidad y el equilibrio; esto significa que con un ancho amplio de paso la persona incrementa su estabilidad y equilibrio. (Daza, 2007, p.263)


- Ángulo de paso: Se refiere a la orientación que tiene el pie durante el apoyo. El eje longitudinal de cada pie forma un ángulo con la línea de progresión (línea de dirección de la marcha); normalmente, está entre los 5° y los 8°. (Daza, 2007, p.263)

Figura 4

Longitudes de paso largo o zancada y paso corto



Nota. Recuperado de “Evaluación clínico funcional del movimiento corporal. Capítulo 11: Examen de la marcha”, de Daza, J. 2007, p. 264, Bogotá, Colombia: Editorial Panamericana.

Figura 5*Parámetros espaciales de la marcha*

Nota. A. Ancho de paso. B. Ángulo de paso. El ancho y el ángulo de paso constituyen dos variables de importante valoración; el centro del retropié es un punto de referencia que facilita la medición. Recuperado de “Evaluación clínico funcional del movimiento corporal. Capítulo 11: Examen de la marcha”, de Daza, J. 2007, p. 264, Bogotá, Colombia: Editorial Panamericana.

En su libro Daza (2007) afirmó lo siguiente:

Los parámetros temporales y espaciales son variables que se pueden ver alteradas por factores como la estatura, la edad, el sexo, la forma, la posición y la función de las estructuras neuromusculares y osteoarticulares, y el dolor, entre otros; Además, el calzado, la indumentaria, los aspectos culturales, la moda, la condición emocional y mental son factores que repercuten en los parámetros espaciotemporales de la marcha. (p. 263-265)

2.1.3 Parámetros clínicos de la marcha y su importancia

Según Arellano-González, Medellín-Castillo & Cervantes-Sánchez (2019) la importancia del análisis de la marcha humana en el área clínica radica en el hecho de que los trastornos de la marcha afectan a un alto porcentaje de la población mundial. La discapacidad debido a problemas en el caminado representa aproximadamente el 55% del total de discapacidades a nivel mundial. Los trastornos de la marcha pueden ser consecuencia de diversas patologías que se sabe afectan las funciones motrices. La semiología más común de los procesos patológicos que afectan a la marcha humana son: el dolor, limitación del movimiento o movilidad, debilidad muscular, y el control neurológico deficitario.

En consecuencia, el estudio de las características de la marcha humana, a través de parámetros biomecánicos representa una herramienta de gran potencial para el diagnóstico, tratamiento y monitoreo de patologías. En la literatura se han analizado una gran cantidad de marchas patológicas, las cuales se pueden clasificar en tres grupos de acuerdo con el problema que las origina: neurológico, músculo-esquelético y circulatorio. En la siguiente tabla se presenta una síntesis de los parámetros de la marcha utilizados para analizar y detectar los diferentes tipos de patologías o problemas, y se comparan con los parámetros utilizados en el estudio de la marcha normal.

Tabla 3

Síntesis de los parámetros de la marcha en aplicaciones clínicas y de acuerdo con el tipo de problema patológico

Tipo de parámetros	Parámetro de la marcha	Acrónimo	Marcha patológica de acuerdo con el problema de origen			Marcha normal
			Neurológico	Músculo-esquelético	Circulatorio	
Espaciales	Altura de paso	ALP	X			
	Ancho de paso/Amplitud de base	AP	X	X	X	
	Distancia recorrida	DR	X			
	Longitud de paso	LP	X	X	X	X
	Longitud de zancada	LZ	X	X	X	X
Temporales	Cadencia	CAD	X	X	X	X
	Duración de paro	DP	X			
	Tiempo de apoyo	TA	X	X	X	X
	Tiempo de balanceo	TB	X	X	X	X
	Tiempo de paso	TP	X	X		X
	Velocidad de la marcha	VM	X	X	X	X
	Velocidad de zancada	VZ	X			X
Angulares	Ángulo de paso	ANP	X	X		
	Ángulos de articulaciones	ANA	X	X		X
	Orientación del segmento corporal	OSC	X	X		X
	Postura del cuerpo (inclinación, simetría)	PC	X	X		
Fuerza	Fuerza muscular	FM	X	X		
	Fuerzas de reacción del suelo	GRF	X	X		X
	Momento	MO	X	X	X	
Otros	Autonomía de la marcha	AM	X			
	Caidas	CAI	X			
	Electromiografía	EMG	X	X		X
	Existencia de temblores	ET	X			
	Fases de la marcha	FMA	X	X	X	X
	Monitoreo de la marcha a largo plazo	MMLP	X			
	Ruta	RUT	X			

Nota. Fuente: Arellano-González, J. C., Medellín-Castillo, H. I., & Cervantes-Sánchez, J. J. (2019) Identificación y análisis de los parámetros biomecánicos utilizados para la evaluación de la marcha humana normal y patológica. XXV CONGRESO INTERNACIONAL ANUAL DE LA SOMIM

2.1.4 Examen y análisis de la marcha

La valoración de la marcha compone un mecanismo diagnóstico primordial en la valoración de enfermedades especialmente las que están vinculadas al sistema músculo esquelético (Öberg, Karsznia & Öberg, 1993).

El análisis de la marcha es un tema de interés desde hace muchos años, por ende los procedimientos usados para su evaluación se han transformado con el paso del tiempo, se han mejorado y simplificado los métodos para su análisis y se han avanzado en nuevas formas que posibilitan evaluar los diversos indicadores de la marcha de forma objetiva y eficaz, valorar las circunstancias que pueden modificarla, identificar variaciones del patrón de marcha en diferentes patologías y lesiones traumáticas, y realizar un control y seguimiento de pacientes para observar la evolución de los mismos, valorar la efectividad del tratamiento, recuperación tras una intervención quirúrgica, necesidad de ayudas técnicas, etc. (Bensoussan, Viton, Barotsis & Delarque, 2008 citado por Agudelo, Briñez, Guarín, Ruiz & Zapata, 2013)

Ridao Fernández (2019) afirma que la intervención en reeducación de la marcha necesita de una correcta evaluación de esta función motriz. Sólo a través de la valoración fiable y objetiva podrán identificarse las limitaciones estructurales y funcionales que guíen el establecimiento de los objetivos terapéuticos y la elección del tratamiento adecuado para el paciente. La valoración inicial del paciente es, por tanto, fundamental. Posteriores evaluaciones, realizadas de forma continuada, permitirán conocer la evolución del usuario a lo largo del tiempo.

En el entorno investigativo, tener vacantes diferentes maneras de poder valorar de forma objetiva, cuantitativa, eficaz y eficiente supone importantes avances. Uno de estos es el desarrollo de tratamientos novedosos capaces de abordar nuevos propósitos terapéuticos o la comparación entre diferentes terapias, ya sean conservadoras o quirúrgicas, para conocer su efectividad.

La evaluación de la marcha es muy importante, por esto muchos investigadores se han dedicado al desarrollo de diferentes métodos de análisis de esta función motriz. Así, la marcha ha sido evaluada desde diferentes perspectivas: biomecánica, tecnológica y clínica.

- Análisis observacional o clínico: El análisis clínico de la marcha tiene como objeto principal deducir los desórdenes de esta función motriz a través de datos visuales, objetivarlos, cuantificarlos y documentar el progreso de los pacientes durante el proceso terapéutico (Araújo, 2009). Estas técnicas, ampliamente utilizadas por los profesionales de la salud, exigen un procedimiento riguroso y sistemático en su ejecución. Es recomendable evaluar la marcha de los pacientes mediante grabaciones en vídeo. Para ello pueden emplearse dos cámaras de vídeo comercial, que dispongan de zoom y enfoque automático, apoyadas sobre un trípode en una sala normalmente iluminada. Una de las cámaras se coloca en el plano frontal y la otra en el plano sagital. De este modo se consigue un registro de la marcha de los pacientes, además de facilitar la enseñanza del análisis observacional a otros profesionales sanitarios (Sánchez-Lacuesta, 1999).

- Análisis biomecánico de la marcha: La biomecánica analiza la marcha desde las perspectivas cinemática y cinética. El análisis cinemático estudia el movimiento de los cuerpos, sin analizar las fuerzas que generan ese movimiento (Plas, 1996). La goniometría y la electrogoniometría, que miden el rango de movilidad de una determinada articulación durante la marcha, o la videofotogrametría, que aporta información bidimensional o tridimensional del movimiento y que será expuesta más adelante, son ejemplos de análisis cinemático (Kim, 2015). El análisis cinético se centra en el estudio de las fuerzas a las que está sometido el cuerpo. Estas fuerzas se agrupan en dos categorías: fuerzas internas y externas. Existen diferentes dispositivos para tratar de estimar estas fuerzas como las plataformas de fuerza o las plantillas dinamométricas (Chumanov, 2010).

- Análisis de la marcha mediante medios tecnológicos: Los últimos avances tecnológicos en el campo de la Biomecánica comprenden una serie de métodos de evaluación eficaces y eficientes, que priorizan la precisión en los datos cuantitativos (Zipp, 2004). A lo largo del tiempo, se han desarrollado una gran variedad de dispositivos para su uso clínico. Entre los medios tecnológicos más empleados podemos encontrar: la dinamometría, la acelerometría, los podómetros, las plantillas instrumentadas, los sistemas de grabaciones en vídeo, la electromiografía y los sistemas de análisis de movimiento en tres dimensiones. Cada uno de ellos, empleado en laboratorio, es capaz de valorar distintos ámbitos de la biomecánica de la marcha, como el movimiento de las

articulaciones, la actividad eléctrica muscular o las fuerzas generadas. (Thomas, 2004)

2.2 Dispositivos para la medición de la marcha

Aquí se presentan los diferentes dispositivos que permiten el registro y análisis de la marcha humana, a continuación serán mencionados los más usados para esta práctica.

- Electrogoniómetro: Consiste en un potenciómetro giratorio con brazos fijados al eje y la base para la fijación a los segmentos del cuerpo yuxtapuestos a la articulación de interés. Los goniómetros multiaxiales extienden esta capacidad al proporcionar medidas ortogonales adicionales de desplazamiento rotativo, más apropiadas para la medición del movimiento de las articulaciones humanas. Los electrogoniómetros ofrecen las ventajas de la visualización en tiempo real y la recopilación rápida de información de una sola articulación. Sin embargo, estos dispositivos están limitados a la medición de ángulos relativos y pueden ser engorrosos en aplicaciones clínicas típicas como la simultánea, evaluación bilateral del movimiento de cadera, rodilla y tobillo durante la marcha. (Bronzino & Peterson, 2014, p. 270)

- Acelerómetros: Estos permiten medir aceleraciones lineales y angulares (si varios transductores están configurados correctamente). Los datos de velocidad y posición pueden derivarse a través de la integración numérica, aunque se debe tener cuidado con la selección de las condiciones iniciales y el manejo de los efectos gravitacionales. (Bronzino & Peterson, 2014, p. 270)

- Sistemas basados en cámaras de video: Este enfoque para la medición del movimiento humano implica el uso de marcadores externos que se colocan en los segmentos del cuerpo del paciente y se alinean con puntos de referencia anatómicos específicos. Las trayectorias de los marcadores se controlan mediante un sistema de cámaras de captura de movimiento (generalmente de 6 a 12) colocadas alrededor de una medición volumen. En un análisis cuadro por cuadro, se utilizan técnicas estereofotogrametría para producir las coordenadas tridimensionales (3-D) instantáneas de cada marcador (en relación con un sistema de coordenadas de laboratorio fijo) a partir del conjunto de imágenes de cámara bidimensionales. (Bronzino & Peterson, 2014, p. 270)

- Plataformas de fuerza: El vector de fuerza de reacción en tierra tridimensional, el par de reacción en tierra vertical y el punto de aplicación del vector de fuerza de reacción en tierra (denominado centro de presión) se miden con plataformas de fuerza incrustadas en la pasarela. Las plataformas de fuerza con dimensiones de superficie de medición típicas de 0.5×0.5 m se componen de varios conjuntos de sensores de tensión o sensores piezoeléctricos montados rígidamente juntos. (Bronzino & Peterson, 2014, p. 271)

- Pedobarografía: La carga dinámica distribuida que corresponde a la fuerza de reacción vertical del suelo se puede evaluar con el uso de una matriz plana y bidimensional de pequeños sensores de fuerza piezoresistivos. La resolución general del pedobarógrafo está dictada por el tamaño de la "celda" del sensor individual. Las matrices de sensores configuradas como plantillas de zapatos o


placas planas ofrecen al usuario clínico dos alternativas de medición. Aunque esta tecnología proporciona al médico clínico una mejor comprensión de la interacción entre la superficie plantar del pie del paciente y el suelo, la interpretación cuidadosa de los datos es esencial en pacientes con deformidad del pie y patrones de marcha alterados. (Bronzino & Peterson, 2014, p. 271)

- Electromiografía dinámica: Los electrodos colocados en la superficie de la piel y los alambres finos insertados en el músculo se utilizan para medir los potenciales de voltaje producidos al contraer los músculos. La actividad de la musculatura de las extremidades inferiores se evalúa de esta manera con respecto al momento y la intensidad de la contracción. Las variables de recolección de datos que afectan la calidad de la señal EMG incluyen la ubicación y la distancia entre los electrodos de grabación, las condiciones de la superficie de la piel, la distancia entre el electrodo y el músculo objetivo, la amplificación y el filtrado de la señal, y la tasa de adquisición de datos. La calidad de la señal EMG debe evaluarse en toda la recopilación de datos EMG utilizando la señal sin procesar. Las características físicas de la actividad muscular se pueden estimar a partir de la señal EMG sin procesar cuando se hace referencia a las fases del ciclo de la marcha. Los datos EMG también se pueden presentar como una forma de onda rectificadas y / o integrada. Para evaluar la intensidad de la contracción, las amplitudes EMG dinámicas generalmente se normalizan mediante un valor de referencia, por ejemplo, la amplitud EMG durante una contracción voluntaria máxima. Este último requisito es difícil de lograr de manera consistente para los pacientes que tienen un

control aislado limitado de los músculos individuales, como los pacientes con parálisis cerebral. (Bronzino & Peterson, 2014, p. 271)

- Giroscopios: Estos sensores inerciales que miden la velocidad angular en los tres ejes y su principio de funcionamiento se basan en la medición del efecto Coriolis que se produce entre la estructura del giroscopio y una segunda estructura existente dentro del dispositivo. Una distinción grande que hay con respecto al acelerómetro es que el análisis del movimiento humano con giroscopios es más condicionado debido a sus características implícitas. Una de ellas es el hecho de no aportar información inercial añadida respecto del acelerómetro cuando hay ausencia de movimiento (Martín, 2014).

En la siguiente figura se observa a un paciente "instrumentado" con esferas reflectantes o marcadores y electrodos EMG que camina a lo largo de un camino nivelado mientras es monitoreada por 6–12 cámaras de movimiento (que monitorean el desplazamiento de los marcadores reflectantes) y 2–4 plataformas de fuerza (que miden las cargas de reacción en el suelo). También podría caminar sobre una plataforma de presión de pie que mide la distribución de la presión plantar. Su caminata también está grabada en video con 1 o 2 cámaras de video convencionales. Todas estas señales (de las cámaras de movimiento, plataformas de fuerza, electrodos EMG, plataforma de presión del pie) se envían a la computadora central de recolección de datos en el laboratorio. Luego, el operador procesa estas señales para producir la información utilizada, junto con las grabaciones de video y otros datos de exámenes clínicos, para identificar anomalías en la marcha y guiar la planificación del tratamiento (Bronzino & Peterson, 2014, p. 271).

Figura 6*Enfoques y sistemas de medición de la marcha*

Nota. Recuperado de “Biomedical engineering fundamentals”, de Bronzino, J. & Peterson, D., 2014, p. 271, Estados Unidos: CRC Press.

2.3 Dispositivos para la medición de parámetros de la marcha

2.3.1 Sistema IMU

En el laboratorio BISEMIC de la facultad de ingeniería eléctrica y electrónica de la Universidad Pontificia Bolivariana Seccional Bucaramanga se desarrolló un sistema para la medición de parámetros de tiempo de la marcha humana. Este sistema cuenta con sensores de medición inercial (IMU) que se localizan en cada uno de los tobillos del paciente. Las señales obtenidas por medio del giroscopio fueron señales analógicas de velocidad angular en los ejes X, Y y Z en función del tiempo, sin ningún procesamiento, a una frecuencia de muestreo de 100 Hz. (Vargas, 2017)

2.3.2 Apple Watch

El Apple Watch Series 3 es un dispositivo comercial que posee varios sensores, para este trabajo solo se explotaron y usaron los sensores de acelerómetro y giroscopio. El reloj inteligente tiene un procesador de doble núcleo de 2.4 GHz, conexión Wi-Fi y Bluetooth 4.2 para transferencia de datos. Las señales obtenidas fueron señales analógicas de aceleración lineal y velocidad angular, sin ningún procesamiento, a una frecuencia de muestreo de 50 Hz. Teniendo en cuenta la ubicación del reloj es posible configurarlo para obtener las medidas tanto para la muñeca derecha como para la izquierda.

Figura 7

Apple Watch Series 3



Nota. Recuperado de “Apple Watch Series 3”, de Apple (Mayo 2020). Recuperado de <https://www.apple.com/es/shop/buy-watch/apple-watch-series-3>

2.3.3 G-WALK

El sistema BTS G-WALK es un dispositivo comercial diseñado para el estudio de la marcha y sus parámetros. Este dispositivo está constituido por cuatro IMU para medir parámetros de tiempo y espacio de la marcha humana; el algoritmo que emplea este sistema se basa en la técnica de fusión de sensores, que consiste en tomar las señales de todos los IMU e integrarlas para hacer las compensaciones necesarias y obtener una sola señal corregida, a partir de la cual se calculan los parámetros deseados. Las señales obtenidas fueron señales analógicas filtradas y procesadas, de aceleración lineal y velocidad angular, por medio del acelerómetro y el giroscopio, a una frecuencia de muestreo de 100 Hz.

Figura 8

Kit del dispositivo G-WALK



Nota. Recuperado de “G-WALK”, de BTS Bioengineering (Mayo 2020). Recuperado de <https://www.btsbioengineering.com/products/g-walk-inertial-motion-system/>

2.4 Aprendizaje de máquina

Esta área del conocimiento proviene de la rama de la computación y de la inteligencia artificial, y se enfoca en conceder la capacidad de aprender a máquinas y que sean capaces de modificarse cuando reciben nuevos datos a través de diferentes técnicas de aprendizaje de máquina. Estos algoritmos buscan reconocer patrones en datos y a través de ellos obtener predicciones futuras de un ambiente o situación utilizando algoritmos estadística y teorías de probabilidad (Murdoch, 2019).

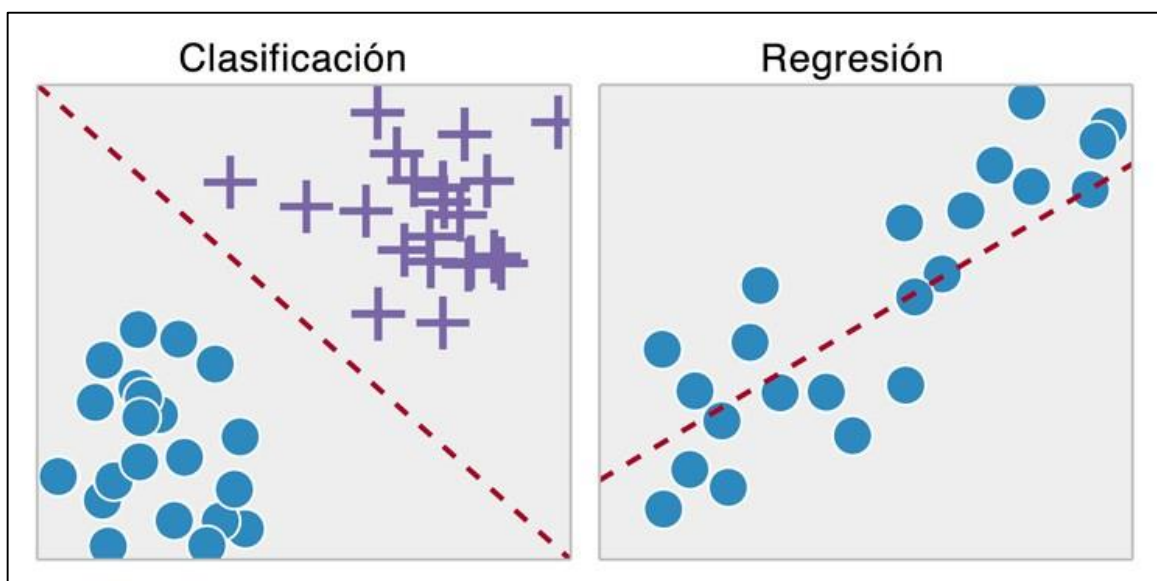
El aprendizaje de máquina tiene dos grandes ramas como lo son el aprendizaje supervisado y aprendizaje no supervisado, el supervisado se cimenta en información que ha sido etiquetada o clasificada para tomar sus propias decisiones y el no supervisado está preparado para sacar y deducir información relevante de los datos entregados sin ser etiquetados o clasificados, es mayormente usado para realizar predicciones (Alpaydin, 2016).

El aprendizaje supervisado tiene como finalidad originar una ecuación que describa el comportamiento del sistema, esto se lleva a cabo mediante la recolección significativa de un conjunto de ejemplos que están previamente etiquetados o clasificados, y con esta ecuación poder dar una posible solución a una nueva entrada (Ciaburro, 2017). Esta rama del aprendizaje de máquina presenta dos tipos de problemas:

- De regresión: Su propósito es crear un modelo que pueda entregar una respuesta cuantitativa, un valor continuo de acuerdo a la información entregada en un grupo de datos etiquetados o clasificados, por ejemplo, predicciones acerca del valor de una vivienda teniendo en cuenta su estrato, ubicación y cantidad de pisos o el tiempo que una persona visualiza una información en un mensaje de un tema determinado.
- De clasificación: De forma semejante a lo que sucede en los problemas de regresión, aquí se busca obtener una respuesta cualitativa, un valor discreto, también llamado variable categórica, con unos datos de entrada con información para alimentar el modelo de clasificación, por ejemplo, poder clasificar si un tumor es benigno o maligno o clasificar diferentes modelos de coches fabricados en distintas empresas.

Figura 9

Tipos de aprendizaje de máquina supervisado



Nota. Recuperado de “[Azure Machine Learning] Tipos de problemas en Machine Learning”, de EPICALSOFT INSTANCE BLOG (Mayo 2020). Recuperado de <http://epicalsoft.blogspot.com/2018/11/azure-machine-learning-algoritmos-de.html>

En cambio, el aprendizaje no supervisado permite agrupar los datos de entrada según las características que se le facilitan previamente al algoritmo y la salida representa que tanta similitud existe entre la información que se le ha presentado al modelo para ser entrenado hasta entonces y los datos de entrada que está recibiendo el mismo modelo (Ciaburro, 2017).

Un detalle muy importante cuando se ejecutan estas clasificaciones, predicciones, entre otras es que el modelo creado sea capaz de generalizar su conocimiento aprendido, si esto no se hace de una forma adecuada el modelo puede presentar alguno de estos dos grandes problemas como lo son el sobreajuste (overfitting) y sub-ajuste (underfitting). El sobreajuste sucede cuando el modelo solo aprende con información muy específica y particular, esto genera un sesgo y por ende al ingresar nueva información y no ser idéntica a la información con la que fue entrenado pierde la capacidad de identificarlo, y el sub-ajuste ocurre cuando el modelo recibe muy poca información del conjunto de datos de entrenamiento, lo que lleva a identificar cualquier cosa ingresada como correcta (Gollapudi & Laxmikanth, 2016).

2.4.1 Regresión

El análisis de Regresión es una rama del aprendizaje de máquina supervisado. Su finalidad es plantear un modelo que relacione cierto número de características dadas en los datos de entrada y una variable de respuesta a la salida que es de tipo continua. En los problemas de regresión se busca conseguir una respuesta cuantitativa dentro de un conjunto infinito de posibles resultados, como, por ejemplo, predicciones sobre precios de inmuebles o el número de segundos que alguien dedicará a visualizar un vídeo (Raschka, 2015).

Algunos ejemplos de regresión son:

- Predecir cuantos artículos serán vendidos en una temporada.
- Predecir la cantidad de personas que se hospedaran en mayo en un hotel.
- Estimar cuánto tiempo va a durar el trayecto de un carro hasta llegar a su destino.
- Estimar la mortalidad de pacientes con cáncer.

Hay varios algoritmos de Aprendizaje de máquina que se pueden utilizar para resolver problemas de Regresión. Se pueden resaltar las siguientes técnicas:

- Árboles de decisión.
- Máquinas de vectores de soporte.
- Bosques aleatorios.
- Aprendizaje profundo.
- Redes neuronales.

2.4.2 Máquinas de vectores de soporte

Según Cortes & Vapnik (1995) la red de vectores de soporte es una nueva máquina de aprendizaje para problemas de clasificación de dos grupos. La máquina implementa conceptualmente la siguiente idea: los vectores de entrada se asignan de forma no lineal a un espacio de características de muy alta dimensión. En este espacio de características se construye una superficie de decisión lineal. Propiedades especiales de la superficie de decisión garantizan una alta capacidad de generalización de la máquina de aprendizaje. La idea detrás del vector de soporte la red se implementó previamente para el caso restringido donde los datos de entrenamiento se pueden separar sin errores.

2.4.3 Árboles de decisión

Según Loh (2011) los árboles de clasificación y regresión son métodos de aprendizaje automático para construir modelos de predicción a partir de datos. Los modelos se obtienen dividiendo recursivamente el espacio de datos y ajustando un modelo de predicción simple dentro de cada partición. Como resultado, la partición se puede representar gráficamente como un árbol de decisión. Los árboles de clasificación están diseñados para variables dependientes que toman un número finito de valores desordenados, con un error de predicción medido en términos de costo de clasificación errónea. Los árboles de regresión son para variables dependientes que toman valores discretos continuos u ordenados, con un error de predicción típicamente medido por la diferencia al cuadrado entre los valores observados y los pronosticados. Este artículo ofrece una introducción al tema al revisar algunos algoritmos ampliamente disponibles y comparar sus capacidades, fortalezas y debilidades en dos ejemplos.

2.4.4 Bosques aleatorios

Según Breiman (2001) los Bosques Aleatorios son una combinación de predictores de árboles, de modo que cada árbol depende de los valores de un vector aleatorio muestreado independientemente y con la misma distribución para todos los árboles en el bosque. La generalización del error para bosques converge hasta un límite a medida que aumenta el número de árboles en el bosque. El error de un bosque de clasificadores de árboles depende de la fuerza de los árboles individuales en el bosque y la correlación entre ellos. El uso de una selección aleatoria de características para dividir cada nodo produce tasas de error que se comparan favorable a Adaboost, pero son más robustos con respecto al ruido. Error interno del monitor de estimaciones, fuerza y correlación se utilizan para mostrar la respuesta al aumento del número de características utilizadas en la división del bosque. Las estimaciones internas también se utilizan para medir la importancia variable. Estas ideas también son aplicables a la regresión.

2.4.5 Redes neuronales

Van Gerven & Bohte (2017) definen las redes neuronales artificiales como una técnica computacional que fue inspirada en la dinámica que presentan las neuronas biológicas, que están conectadas entre sí y transmiten señales. La información ingresa a las neuronas, en donde recibe diferentes operaciones para terminar entregando datos de salida. Las conexiones de neuronas se dan a través de enlaces, los cuales son regidos por un valor de peso, estos pesos pueden modificar el estado dando paso a la activación de las neuronas que siguen en el enlace, también a la salida de la neurona puede existir una función

limitadora, esta modifica la salida o establece un margen a superar antes de continuar con la neurona siguiente y es llamada función de activación.

La finalidad de una red neuronal es dar respuesta a los problemas de la misma forma como lo hace el cerebro humano, a pesar que las redes neuronales son más abstractas ya que estas presentan normalmente dos capas que interactúan con el mundo exterior, son la capa de entrada que es donde ingresan los datos a la red y la capa de salida que muestra la respuesta de la red a los datos de entrada, además presentan capas intermedias llamadas capas ocultas.

2.4.6 Aprendizaje profundo

Para Bengio, Courville & Vincent (2013) existe el aprendizaje profundo, y este a su vez es una rama del aprendizaje automático el cual hace uso de redes neuronales para realizar sus tareas. Actualmente es muy usado y ha permitido el desarrollo de herramientas como la traducción automática o el reconocimiento de la voz. Se caracteriza por necesitar grandes cantidades de datos para su entrenamiento, y tiene la capacidad de hallar esas características relevantes de los datos por sí solo. Esta técnica está incluida en un conjunto más grande de algoritmos de aprendizaje de máquina que se basan en asimilar representaciones de datos. Una observación tiene diferentes formas de representarse, pero algunas representaciones permiten que el aprendizaje de tareas tenga mayor facilidad si es basado en ejemplos, además, la investigación que se lleva a cabo en este campo busca qué representaciones son mejores y cómo crear modelos para reconocer estas representaciones.

Diversos algoritmos de aprendizaje profundo, como lo son las redes neuronales profundas, las redes neuronales profundas convolucionales, y las redes Long Short Term Memory, han sido aplicadas de forma activa a soluciones tecnológicas, mantenimiento predictivo, además de ser de interés en temas como reconocimiento de señales de audio y música, reconocimiento automático del habla y visión por computador, en donde han presentado resultados destacados en el desarrollo de diferentes tareas asignadas.

2.4.7 Medidas de desempeño

El desempeño de un estimador puede observarse con diferentes medidas de desempeño (Botchkarev, A., 2018; Handelman et Al.,2019), las utilizadas en este trabajo son las siguientes:

- Coeficiente de determinación: Denominado R^2 , es una medida estadística que representa la proporción de la varianza de una variable dependiente que se explica por una o varias variables independientes en un modelo de regresión. Mientras que la correlación explica la fuerza de la relación entre una variable independiente y una dependiente, el R-cuadrado explica en qué medida la varianza de una variable explica la varianza de la segunda variable. Este coeficiente puede tomar valores entre 0 y 1. Se presenta que cuanto más cercano a 0 es el valor obtenido, menos ajustado estará el modelo, por ende, los resultados obtenidos serán menos confiables; en cambio, cuanto más cercano a 1 es el valor obtenido, mayor será el ajuste del modelo a la variable que se pretende estimar. (Cameron, A. C., & Windmeijer, F. A.,1997).

- Raíz del error cuadrático medio: Denominado RMSE. Es la desviación estándar de los residuos (errores de predicción). Los residuos son una medida de cuán lejos de la línea de regresión están los puntos de datos; RMSE es una medida de cuán extendidos están estos residuos. En otras palabras, te dice cuán concentrados están los datos alrededor de la línea de mejor ajuste. El error cuadrado medio de la raíz se utiliza comúnmente en climatología, predicción y análisis de regresión para verificar los resultados experimentales (Barnston, A. G., 1992; Hyndman, R. J., & Koehler, A. B., 2006).

En el RMSE, los errores se elevan al cuadrado antes de ser promediados. Esto básicamente implica que el RMSE asigna un mayor peso a los errores más grandes. Esto indica que el RMSE es mucho más útil cuando hay grandes errores y éstos afectan drásticamente al rendimiento del modelo. En esta métrica también, cuanto más bajo es el valor, mejor es el rendimiento del modelo.

- Error cuadrático medio: Denominado MSE. Este error dice cuán cerca está una línea de regresión de un conjunto de puntos. Lo hace tomando las distancias de los puntos a la línea de regresión (estas distancias son los "errores") y al cuadrado. La cuadratura es necesaria para eliminar cualquier signo negativo. También da más peso a las diferencias más grandes. Se llama error de la media al cuadrado ya que se encuentra el promedio de un conjunto de errores (Lehmann, E. L., & Casella, G., 2006; Wackerly, D., Mendenhall, W., & Scheaffer, R. L., 2014).

Es una de las métricas más utilizadas, pero menos útil cuando una sola mala predicción arruinaría toda la capacidad de predicción del modelo, es decir, cuando el conjunto de datos contiene mucho ruido. Es más útil cuando el conjunto de datos contiene valores atípicos o inesperados (valores demasiado altos o demasiado bajos).

- Error absoluto medio: Denominado MAE. Es una medida de los errores entre observaciones emparejadas que expresan el mismo fenómeno. Entre los ejemplos de Y frente a X figuran las comparaciones de lo previsto frente a lo observado, el tiempo subsiguiente frente al tiempo inicial y una técnica de medición frente a una técnica de medición alternativa (Willmott, C. J., & Matsuura, K., 2005).

No es muy sensible a los valores atípicos en comparación con MSE, ya que no castiga los grandes errores. Se utiliza normalmente cuando el rendimiento se mide con datos variables continuos. Da un valor lineal, que promedia las diferencias individuales ponderadas por igual. Cuanto más bajo es el valor, mejor es el rendimiento del modelo.

Figura 10*Medidas de desempeño*

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}|$$
$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2$$
$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2}$$
$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2}$$

Donde,
 \hat{y} - Valor predicho de y
 \bar{y} - Valor medio de y

2.5 Análisis exploratorio de datos

El análisis exploratorio de datos (Exploratory Data Analysis, EDA) o estadística descriptiva es un paso previo e imprescindible a la hora de comprender los datos con los que se va a trabajar y altamente recomendable para una correcta metodología de investigación. Este procedimiento fue desarrollado por John W. Tukey en la década de 1970 y tiene como objetivo desarrollar un entendimiento de los datos obtenidos, lo cual permite identificar las principales características de un conjunto, utilizando pocas gráficas

y/o valores estadísticos. Los pasos seguidos en esta exploración de los datos básicamente son dos:

- **Medición y descripción de los datos:** Esto se realiza por medio de la estadística descriptiva, utilizando las medidas de tendencia central (promedios que, en una sola cifra, resumen todos los valores de una muestra: media, mediana y moda son las más habituales) y las medidas de dispersión (que calculan hasta qué punto la muestra se agrupa o no en torno a esos promedios).
- **Comparación de los caracteres:** Esto se realiza por medio de la estadística inferencial. Las pruebas más frecuentemente utilizadas comienzan por las más sencillas comparaciones visuales, a través de gráficas como la campana de Gauss, nubes de dispersión o diagramas de caja y arbotantes, pasando por las socorridas tablas de contingencia, y por los típicos análisis de varianza (que no es más que una confrontación muy precisa de los promedios de varias muestras), hasta llegar a los más complejos análisis multivariantes de conglomerados.

CAPÍTULO 3

METODOLOGÍA

La metodología utilizada para el desarrollo de este trabajo es la metodología cuantitativa con un diseño experimental, en donde el desempeño se rige por la exactitud lograda en la correcta estimación de parámetros de la marcha. Este tipo de metodología es una de las más reconocidas en áreas del conocimiento como la informática, las matemáticas y la estadística. Es una metodología que tiene como centro el uso de los números para analizar, investigar y comprobar tanto información como datos. Además, esta investigación es de tipo descriptiva; las variables a medir y la población sobre las cuales se recolectan los datos están claramente definidos. Como los resultados dependen de la técnica a utilizar, aun así, el enfoque posee relación con lo visto en los antecedentes.

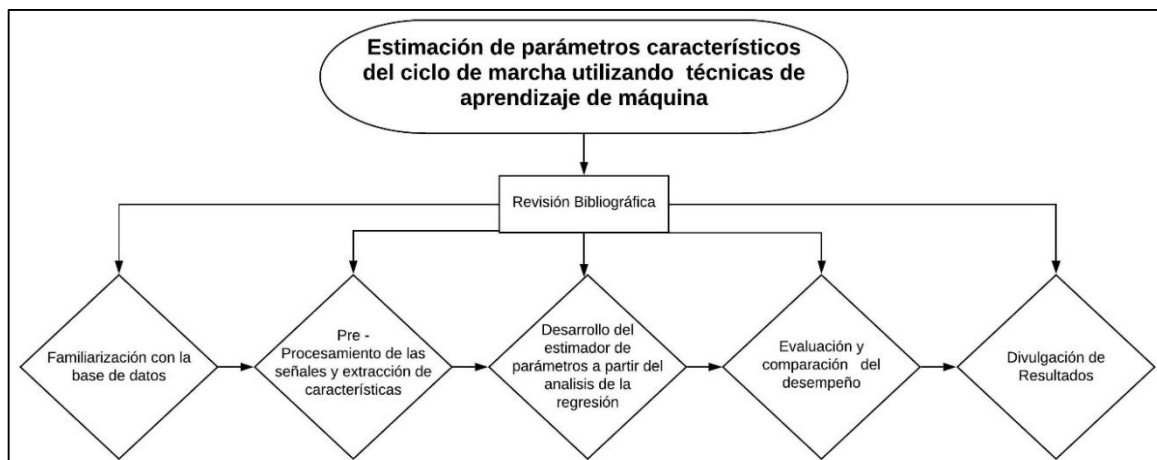
Normalmente, el método cuantitativo utiliza de recursos usados en el campo de la estadística y con ello manipular la información numérica que se tiene. Esta metodología precisa que exista una relación numérica entre las variables del problema de investigación para así trabajar con facilidad, además de saber cómo está conformada la información, la cantidad de datos, el inicio y fin de los mismo y el tipo de elementos que lo conforman.

A continuación, se presentará la manera en que se desarrollará el trabajo propuesto titulado ESTIMACIÓN DE PARÁMETROS CARACTERÍSTICOS DEL CICLO DE MARCHA UTILIZANDO TÉCNICAS DE APRENDIZAJE DE MÁQUINA, en el cual se van a estimar parámetros espaciotemporales característicos del ciclo de marcha basado

en técnicas de aprendizaje de máquina. En la siguiente figura se observan las fases del trabajo.

Figura 11

Desarrollo del trabajo de grado



3.1 Base de datos

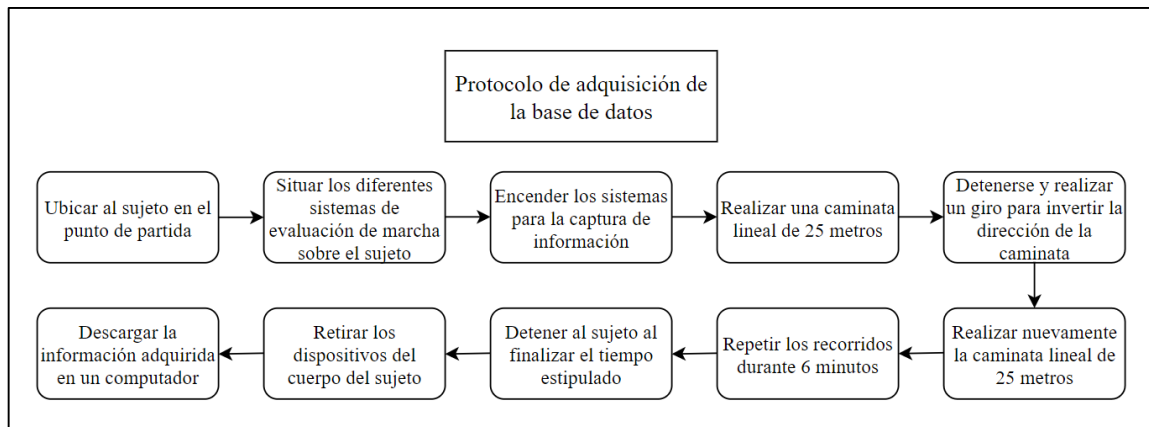
La base de datos está compuesta por señales obtenidas de tres diferentes sistemas para la evaluación de parámetros de la marcha, uno comercial, G-WALK, y otros dos dispositivos no convencionales para la evaluación de la marcha, Apple Watch y IMU.

Esta base de datos se obtuvo en un experimento realizado en el laboratorio de Bioingeniería, Señales y Microelectrónica, BISEMIC, perteneciente a la facultad de ingeniería eléctrica y electrónica de la Universidad Pontificia Bolivariana Seccional Bucaramanga. El experimento consistió en tomar a un sujeto, ubicarlo en un punto específico, colocar los diferentes sistemas para la evaluación de parámetros de la marcha sobre él, encenderlos y realizar una caminata lineal de 25 metros durante 6 minutos; en este

periodo de tiempo los dispositivos adquieren los datos de la marcha del sujeto y esta información procede a guardarse en un computador.

Figura 12

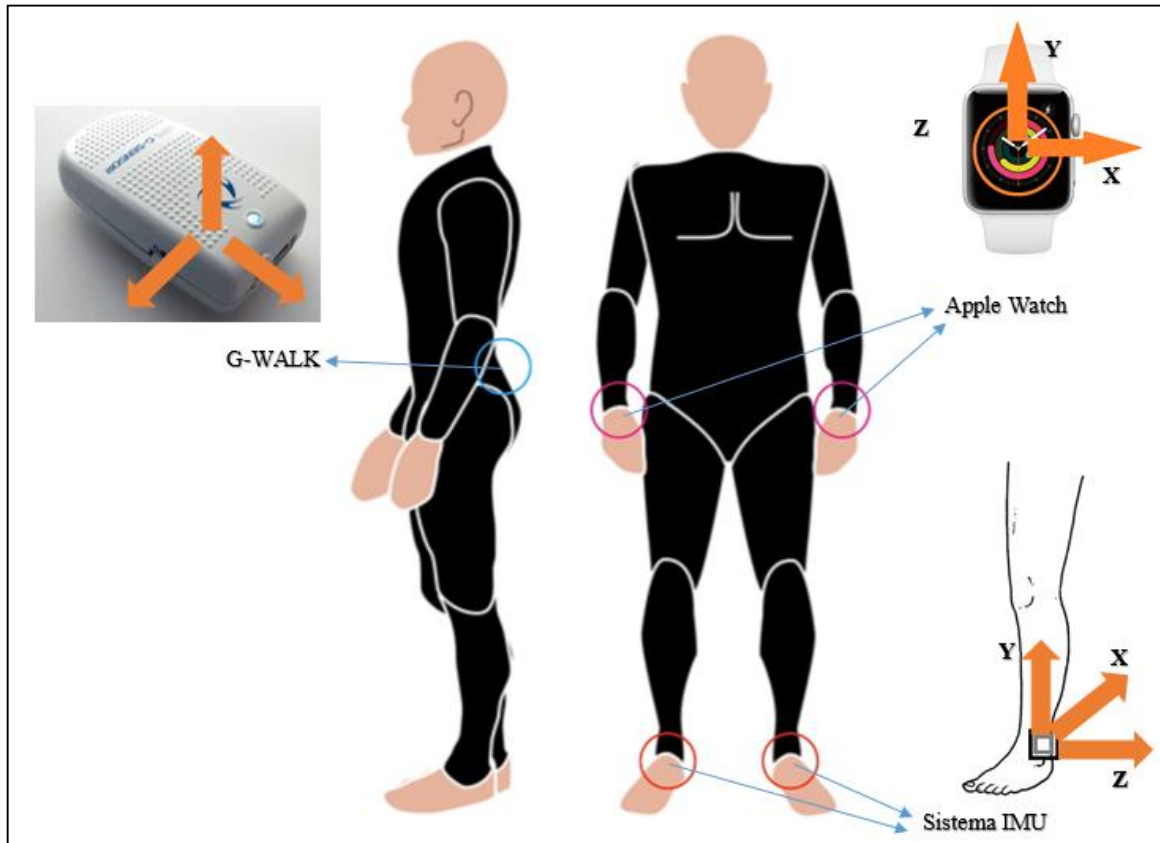
Protocolo experimental para la adquisición de la base de datos



Es importante resaltar que los dispositivos usados se encuentran ubicados en diferentes partes del cuerpo al realizar la prueba de marcha, el dispositivo G-WALK se encuentra ubicado en la parte baja de la espalda, específicamente sobre la vértebra S1, los Apple Watch se encuentran ubicados en cada muñeca y el sistema IMU está posicionado en los tobillos del sujeto, estas ubicaciones se encuentran representadas en la figura 12.

Figura 13

Localización de los dispositivos utilizados en la adquisición de la base de datos en un sujeto con sus respectivos ejes



Este experimento se realizó con 33 personas que afirman no presentar ninguna patología en la marcha, 21 hombres y 12 mujeres, en un rango de edad entre 18 y 28 años. La base de datos cuenta con un total de 58 registros, cada uno consta de 3 archivos los cuales contienen la información adquirida por cada dispositivo. Los parámetros fisiológicos con los que cuenta la base de datos son género, edad, altura y peso de cada uno de los sujetos,

y los parámetros de la marcha medidos por los diferentes dispositivos se encuentran en la siguiente tabla.

Tabla 4*Parámetros obtenidos de los diferentes dispositivos*

G-WALK (Fs = 100 Hz)	Apple Watch (Fs = 50 Hz)	Sistema IMU (Fs = 100 Hz)
<p>El archivo con las series de tiempo entrega los siguientes vectores:</p> <ul style="list-style-type: none"> - Muestras tomadas. - De tiempo. - De aceleración lineal de los ejes X, Y y Z (m/ s²). - De velocidad angular de los ejes X, Y y Z (grados/s). <p>Los informes entregan la siguiente información:</p> <ul style="list-style-type: none"> - Duración de la marcha. - Momento del inicio de la marcha. - Momento del final de la marcha. - Pasos elaborados. - Cadencia del Paso. - Velocidad de la marcha. - Longitud de la Zancada. - Porcentaje de Longitud de la Zancada respecto a la altura. - Longitud de paso. - Duración de zancada de cada lado. - Duración Fase de Apoyo. - Duración Fase de Oscilación. - Duración Apoyo Doble. - Duración Soporte Individual. 	<p>Se tienen los siguientes vectores:</p> <ul style="list-style-type: none"> -Donde se encuentra el momento en que fue tomada una muestra. -De muestras. -De aceleración lineal de los ejes X, Y y Z (m/s²). -De velocidad angular de los ejes X, Y y Z (rad/s). <ul style="list-style-type: none"> -Con la cantidad de pasos realizados. -Con la cadencia de paso. -Con la distancia recorrida. -Con la cantidad de pisos ascendidos. -Con la cantidad de pisos descendidos. -Con el tiempo de inicio un paso. -Con el tiempo del final un paso. 	<p>Se tienen los siguientes vectores:</p> <ul style="list-style-type: none"> -De muestras. -De velocidad angular de la pierna derecha en los ejes X, Y y Z (grados/s). -De velocidad angular de la pierna izquierda en los ejes X, Y y Z (grados/s).

En este trabajo la estimación de los parámetros se enfocará en la cadencia, la longitud de zancada y la velocidad del ciclo de marcha. Teniendo en cuenta la versatilidad que tienen estos parámetros para la identificación y análisis del ciclo de marcha tanto normal como patológico, en casos neurológicos, musculo-esqueléticos y circulatorios. (Arellano, 2019)

El G-WALK es un sistema inalámbrico que consiste en un sensor de inercia compuesto por un acelerómetro triaxial, un sensor magnético y un giroscopio triaxial que al posicionarse en la vértebra L5 permite realizar un análisis funcional de la marcha. El sistema extrapola de datos adquiridos los parámetros de la marcha espacio-temporales necesarios para realizar un diagnóstico o para definir una estrategia de entrenamiento o rehabilitación.

La información fue obtenida con el reporte de evaluación de marcha que entrega el software BTS G-STUDIO y está conformada por 2 informes, en uno está detallada la información promedio de los parámetros del ciclo de marcha en cada uno de los recorridos realizados ENTIENDASE COMO RECORRIDO EL TRAYECTO ENTRE CAMBIOS DE DIRECCIÓN, y en el otro se encuentra la información promedio de todos los recorridos que fueron realizado durante toda la prueba, y un archivo donde se encuentran las series de tiempo de la prueba realizada.

Los Apple Watch Series 3 poseen varios sensores, para este trabajo solo se explotaron y usaron los sensores de acelerómetro y giroscopio. Las señales obtenidas fueron señales analógicas de aceleración lineal y velocidad angular en los ejes X, Y y Z en función del tiempo, sin ningún procesamiento, a una frecuencia de muestreo de 50 Hz. La información

entregada por el dispositivo Apple Watch está conformada por un archivo donde se encuentran las series de tiempo de la prueba realizada.

El sistema desarrollado en la Universidad Pontificia Bolivariana Seccional Bucaramanga cuenta con sensores de medición inercial (IMU) que se localizan en cada uno de los tobillos del paciente. Las señales obtenidas por medio del giroscopio fueron señales analógicas de velocidad angular en los ejes X, Y y Z en función del tiempo, sin ningún procesamiento, a una frecuencia de muestreo de 100 Hz. La información entregada por el sistema IMU está conformada por un archivo donde se encuentran las series de tiempo de la prueba realizada.

Figura 14

Señales adquiridas con el dispositivo IMU

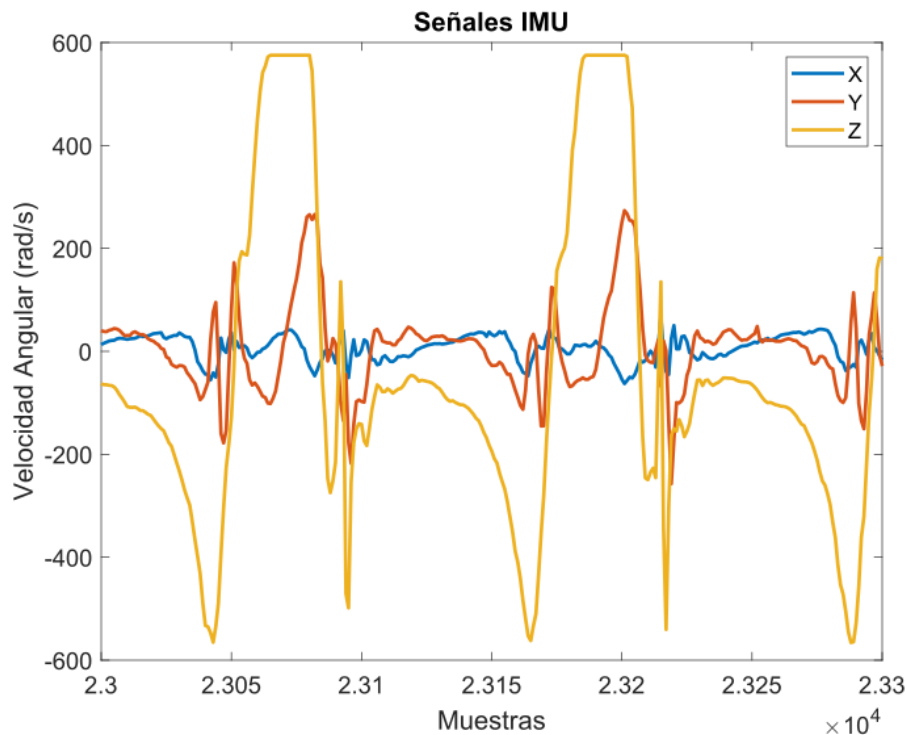


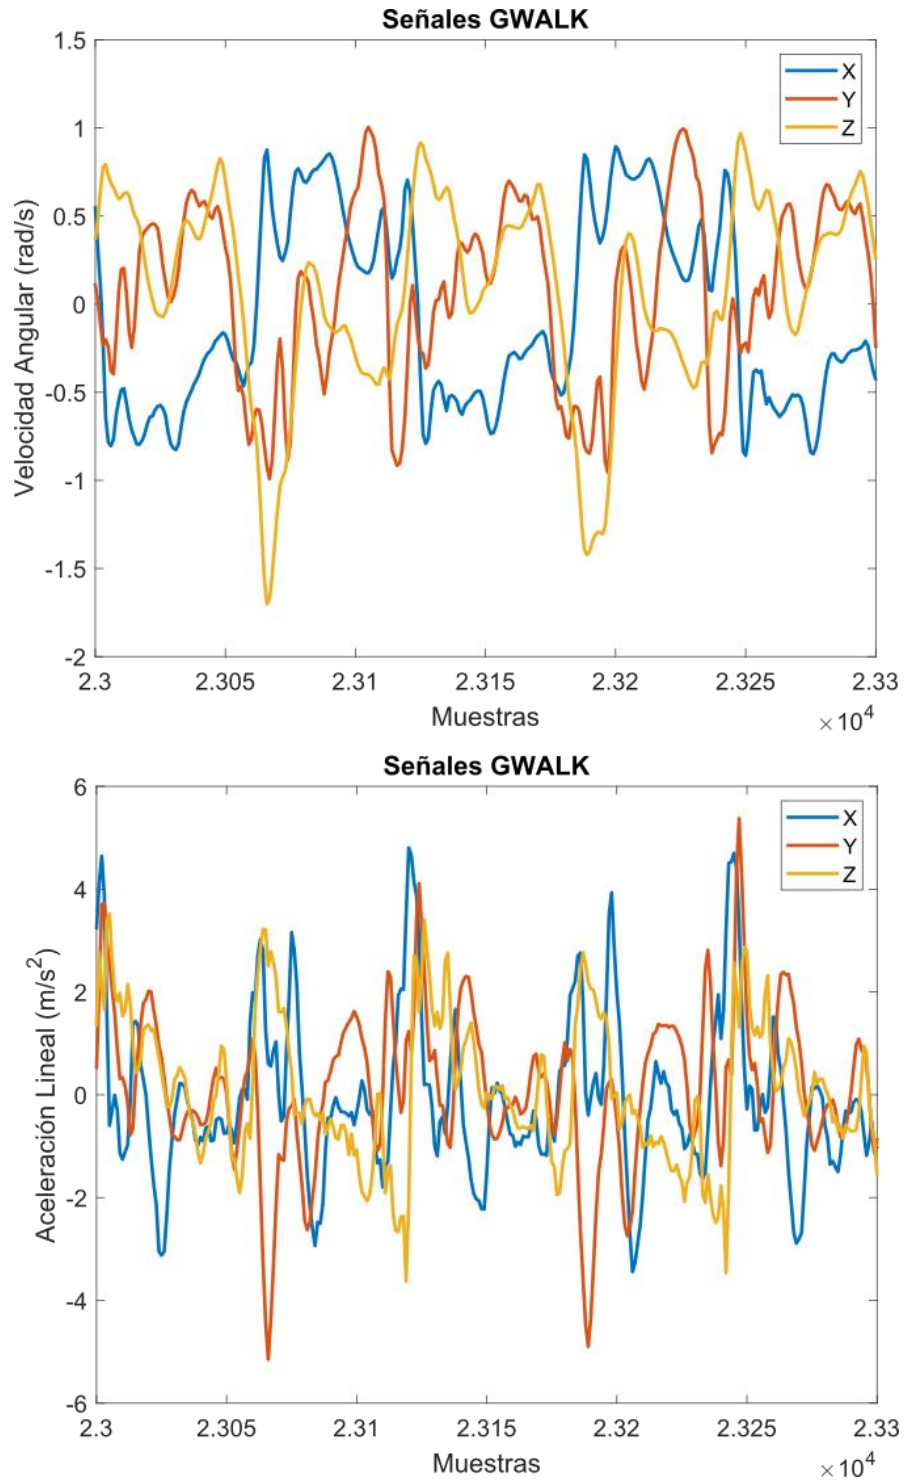
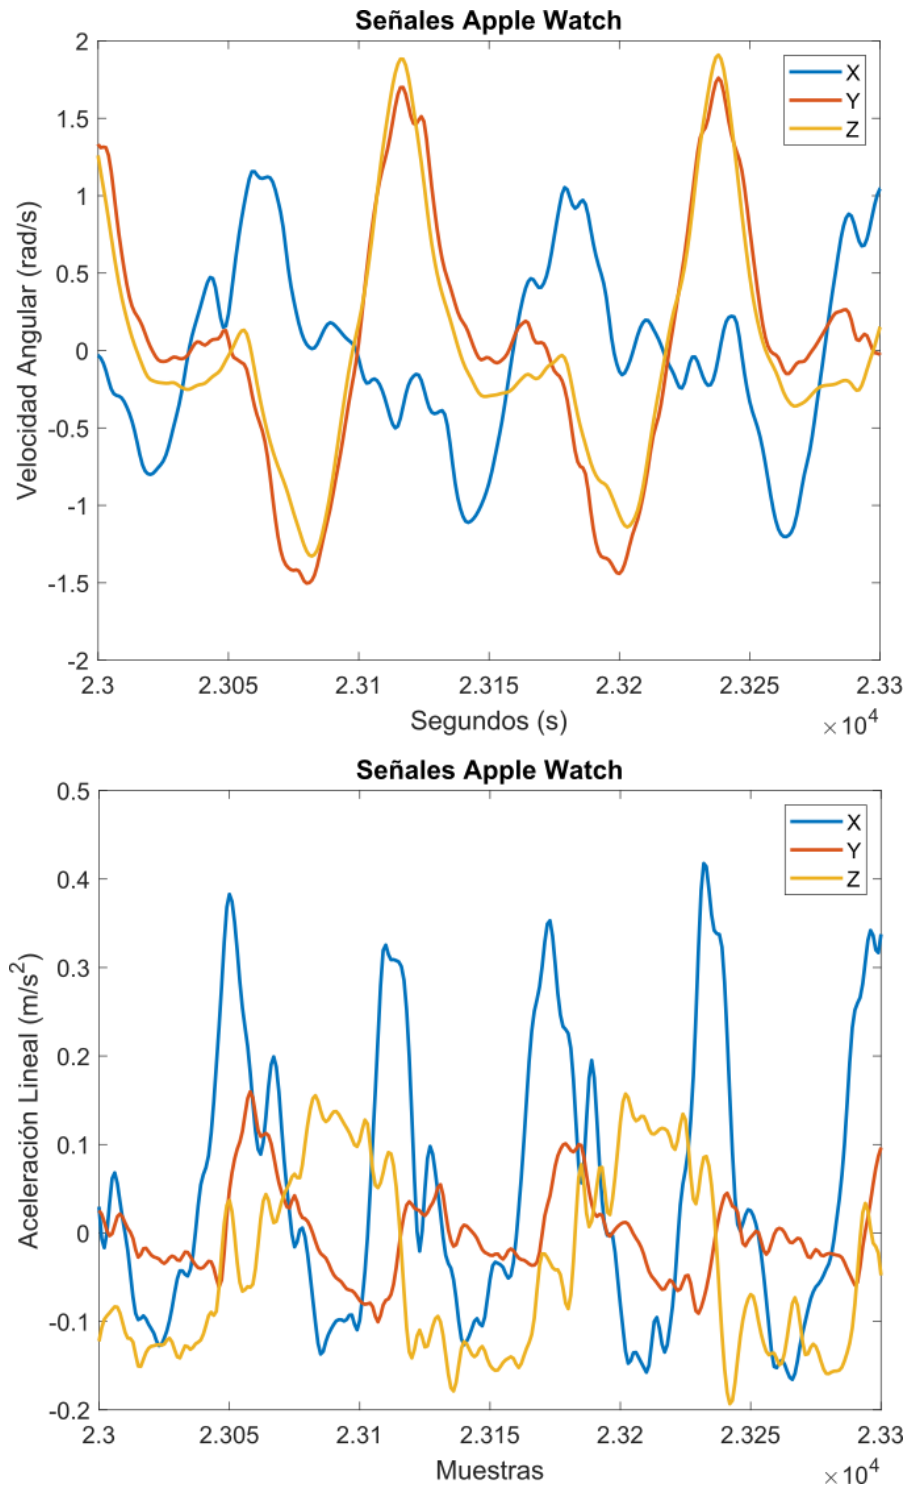
Figura 15*Señales adquiridas con el dispositivo G-WALK*

Figura 16

Señales adquiridas con el dispositivo Apple Watch



Para el desarrollo de este trabajo se seleccionaron de la base de datos completa a 28 sujetos sanos, 18 hombres y 10 mujeres, contando con un total de 53 registros. Esta decisión de depurar la base de datos se tomó luego de revisar la calidad de la información que tenían las pruebas e informes de los sujetos, ya que algunos presentaban pruebas o informes incompletos debido a que se desactivaron durante la prueba.

La distribución de la base de datos se puede observar en las siguientes figuras:

- Son 18 hombres y 10 mujeres, representados en el histograma con el número 0 y 1.
- La edad de los sujetos de la base de datos se encuentra distribuida entre los 18 y 28 años, teniendo en su mayoría personas con 22 años o menos.
- La altura de los sujetos de la base de datos se encuentra distribuida con personas que miden desde 1.50 m hasta 1.90 m

Figura 17

Representación de distribuciones de frecuencias correspondientes al género, edad y altura de los sujetos que conforman la base de datos

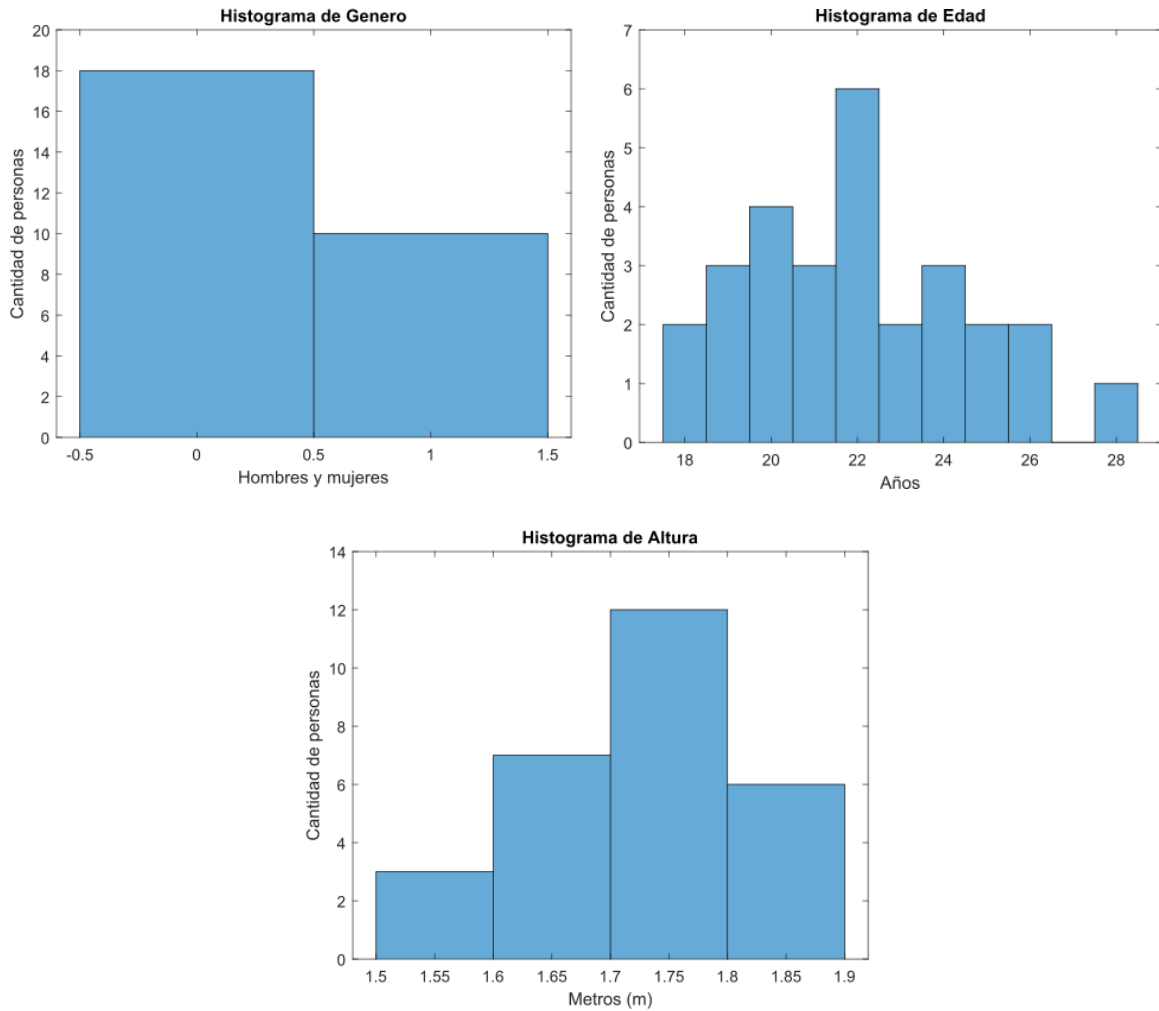
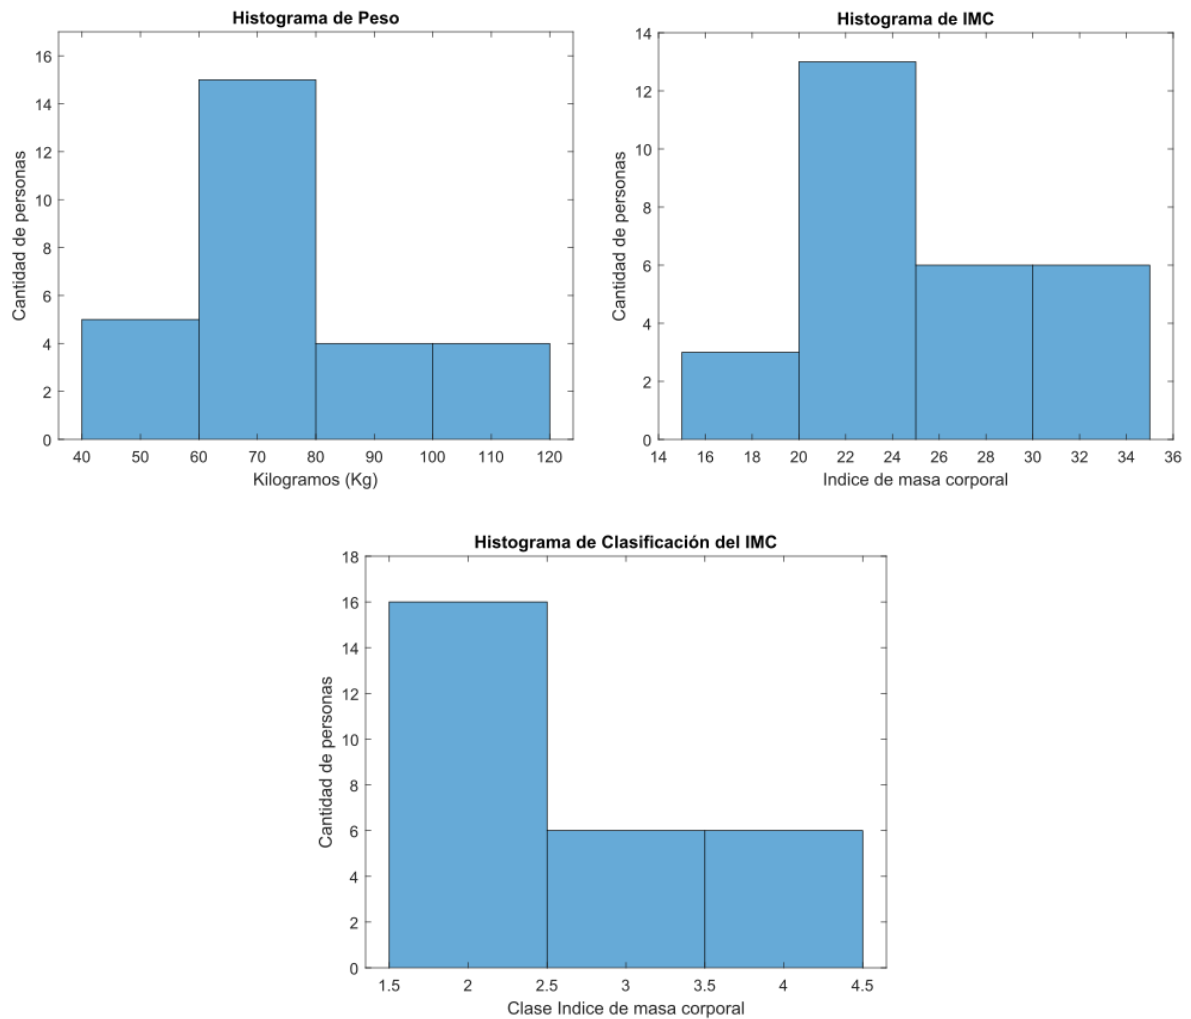


Figura 18

Representación de distribuciones de frecuencias correspondientes al peso, al índice de masa corporal (IMC) y a la clasificación del índice de masa corporal (IMC) de los sujetos que conforman la base de datos



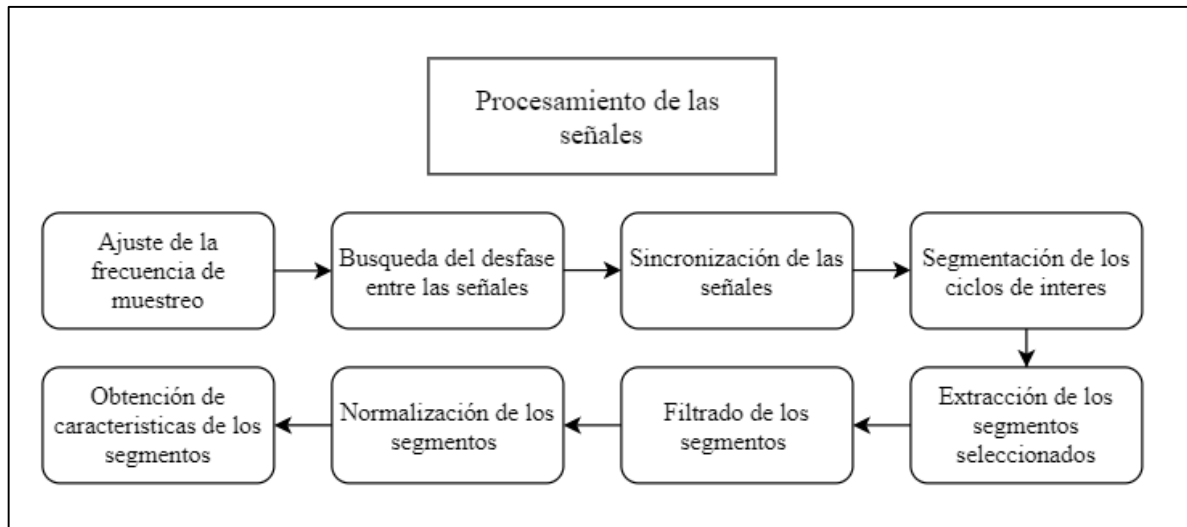
3.2 Pre - Procesamiento de las señales y extracción de características

Toda señal biológica y eléctrica es susceptible al ruido, por lo tanto, es necesario realizar un filtrado que permita obtener una mejor señal para poder ser utilizada y extraer la información requerida para la estimación de los parámetros de marcha. Es importante dejar claro que las características a estimar serán comparadas con la información que entrega el sistema G-WALK, ya que es el dispositivo comercial con aval médico para evaluar la condición de los pacientes en un análisis de marcha. Estas señales deben ser adaptadas para ser procesadas por varios motivos: no todos los dispositivos adquirieron los datos a la misma frecuencia de muestreo, por ello es necesario definir una frecuencia de muestreo estándar para trabajar; además las señales tienen un desfase al inicio de la toma de datos debido a que los dispositivos se encendieron en tiempos diferentes y requieren de una sincronización; igualmente debe realizarse una segmentación de las señales para descartar los giros que el sujeto realizaba para cambiar de dirección.

El proceso realizado se encuentra descrito en la siguiente figura.

Figura 19

Proceso realizado para el procesamiento de las señales de la base de datos



El proceso inicia con la selección de la frecuencia de muestreo con la que se va a trabajar todas las señales. Después, se procede a realizar la sincronización de las señales, buscando la pareja de variables entre dispositivos diferentes que mejor permitan la sincronización de las mismas. Luego, se realiza la segmentación y extracción de los ciclos de marcha en cada una de las señales, eliminando el registro del giro realizado durante la prueba de marcha. A continuación, se filtran y normalizan los segmentos seleccionados y por último se obtienen las características de todos los segmentos, las cuales van a ser utilizadas en el aprendizaje de máquina.

Inicialmente se tienen las señales de los dispositivos con diferentes frecuencias de muestreo, con una frecuencia de 100 Hz las señales del dispositivo GWALK e IMU, y con una frecuencia de 50 Hz las señales del dispositivo Apple Watch. Teniendo en cuenta que

el dispositivo de referencia es el GWALK la frecuencia de muestreo con la que se trabajará durante este proyecto será de 100 Hz.


Esto significa que la frecuencia de muestreo de las señales adquiridas por el Apple Watch fueron duplicadas, esto se hizo utilizando la función *interp* de MATLAB para la interpolación, para luego obtener todas las señales del Apple Watch con una frecuencia de 100 Hz. Cabe resaltar que la morfología de la señal no se ve afectada al realizar este aumento de frecuencia.

Luego de definir y ajustar la frecuencia de muestreo de las señales, se procede a realizar la sincronización de las señales de los diferentes dispositivos. Para esto fue necesario graficar las señales para visualizar el inicio del movimiento del sujeto en cada uno de los dispositivos utilizados. Hay que dejar claro que la sincronización se realizó teniendo como referencia la señal del dispositivo GWALK.

En la figura 20 se pueden observar las señales del dispositivo IMU y GWALK, aquí se destaca que el IMU fue encendido después que el GWALK, por lo tanto, estas se encuentran adelantadas con respecto al GWALK, y las señales del IMU de la pierna izquierda y derecha se encuentran sincronizadas entre ellas. En esta misma figura se pueden observar las señales de los dispositivos Apple Watch y GWALK, donde se identifica que los Apple Watch fueron encendidos después que el GWALK, por lo tanto, éstas se encuentran adelantadas con respecto al GWALK, y las señales de los Apple Watch de la muñeca izquierda y derecha no se encuentran sincronizadas entre ellas, esto se debe a que primero se encendió el dispositivo de la muñeca derecha y luego el de la muñeca izquierda.

Figura 20

Señales originales del Sujeto 1 en la 1ra prueba realizada correspondientes a la Velocidad angular en el eje X de los diferentes dispositivos




Luego de analizar el comportamiento de las diferentes señales de los dispositivos IMU y Apple Watch (Y) con respecto a la señal de referencia del dispositivo GWALK (X) se lleva a cabo la búsqueda de los desfases que existen entre las señales X y Y, esto se realiza con la función *finddelay* de MATLAB, que entrega una estimación del desfase entre las señales. La pareja de señales utilizadas para la sincronización fueron las correspondientes a la velocidad angular en el eje X de los dispositivos a sincronizar. Es importante resaltar que para facilitar el proceso de sincronización de las señales es necesario mejorar el protocolo de adquisición de las señales, en donde se establezca un estricto orden de encendido de los dispositivos.

Después de encontrar el desfase que hay entre las señales, lo siguiente a realizar es agregar ceros equivalentes a esta diferencia en la señal a sincronizar; es decir, concatenar al inicio de la señal un vector de ceros que corresponde al desfase que hay entre las señales que se desean sincronizar. Finalmente, en la figura 21 se observan las señales de los diferentes dispositivos sincronizadas.

Figura 21

Señales sincronizadas del Sujeto 1 en la 1ra prueba realizada correspondientes a la Velocidad angular en el eje X de los diferentes dispositivos




Después de sincronizar las señales y ajustar la frecuencia de muestreo de la base de datos se procede a extraer los segmentos de las señales de los diferentes dispositivos. Analizando las diferentes señales se encuentra que en la Velocidad angular en el eje X del GWALK se encuentra un pico en la señal, este máximo entre segmentos se asocia al giro

realizado por el sujeto para cambiar la dirección de su movimiento al completar los 25 metros del recorrido (figura 22), a partir de esta característica se realiza la segmentación.

Figura 22

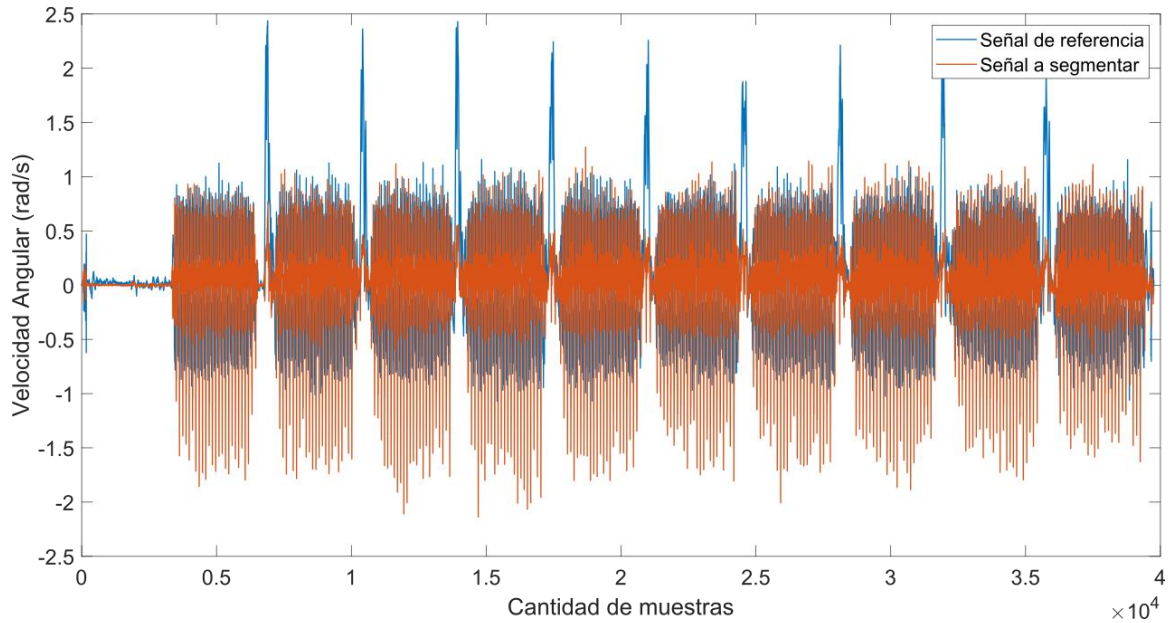
Señal original del Sujeto 1 en la 1ra prueba realizada correspondientes a la Velocidad angular en el eje X del dispositivo GWALK



Para segmentar las señales es necesario cargar dos señales, como se observa en la figura 23, teniendo como señal de referencia para realizar la segmentación la señal de velocidad angular en el eje X del G-WALK, y otra señal que será segmentada.

Figura 23


Señal de referencia y señal a segmentar



Inicialmente se procede a sacar la envolvente de la señal de referencia de la velocidad angular en el eje X con la función *envelope* de MATLAB, aquí se obtiene la envolvente superior e inferior de la señal, esto se visualiza en la figura 24.

Figura 24

Señal de referencia con su respectiva envolvente superior e inferior



Utilizando una ventana deslizante de 1.000 muestras se localizan los máximos locales de cada una de las ventanas en la envolvente de la velocidad angular, esto es posible realizarlo con la función *findpeaks* de MATLAB. Después se define un umbral con respecto a la envolvente superior, el cual se define como:

$$Umbral = \bar{X}_{envolvente\ Superior} + 2 * \sigma_{envolvente\ Superior}$$

Donde:

$\bar{X}_{envolvente\ Superior}$: Es la media de la amplitud de la señal envolvente superior.

$\sigma_{envolvente\ Superior}$: Es la desviación estándar de la amplitud de la señal envolvente superior.

Los máximos locales que superen este umbral serán utilizados para realizar la segmentación, los otros serán descartados. Al tener los puntos de interés, se guarda la ubicación de estos para proceder a segmentar la señal. Este proceso se puede ver en las figuras 25 y 26.

Figura 25

Detección de picos en la envolvente superior de la señal de referencia





Figura 26


Picos de interés obtenidos luego de la umbralización de los mismos



A continuación, se define una ventana de 300 muestras teniendo como centro el pico de interés para luego extraerlo de la señal; luego, en este fragmento se calcula la derivada de la envolvente superior, y en ella se identifica un máximo y un mínimo local, correspondientes al inicio y el final de cada giro realizado, esto a su vez permite ubicar los inicios y finales de los segmentos que existen en la señal. Teniendo el inicio y final de cada segmento se calcula el tamaño de las diferentes ventanas que permiten eliminar el pico que se presenta al final del segmento; con la ubicación y tamaño de cada segmento se proceden a extraer los segmentos de la señal. La secuencia de lo mencionado anteriormente se encuentra en las figuras 27, 28, 29 y 30.

Figura 27

Señal de referencia con su respectiva envolvente superior y su derivada

**Figura 28**

Ventana de 300 muestras en donde se halla el inicio y final de un segmento






Figura 29*Segmento final extraído de la señal***Figura 30***Representación gráfica del proceso realizado para extraer los segmentos*

Después de tener los segmentos extraídos es necesario filtrarlos para eliminar posibles ruidos y altas potencias que interfieran en las señales, esto se realizó con las funciones *buttpord*, *butter* y *filter* de Matlab, y luego se escalaron las señales, que ahora tendrán su amplitud en 1 y -1, con la función *rescale* de Matlab, la cual utiliza la siguiente ecuación:

$$X' = a + \frac{(X - X_{min})(b - a)}{X_{max} - X_{min}}$$

En el siguiente ciclo, luego de tener los segmentos de cada señal filtrados y normalizados, listos para ser usados, se proceden a extraer características de los mismos, esto se realiza en cada segmento y se obtienen las siguientes características espaciales: Media aritmética, Mediana, Curtosis, Desviación estándar, Coeficiente de asimetría de Pearson, Rango Intercuartílico y Coeficiente de variación; y las características no lineales son: Entropía de Shannon y Entropía de la muestra.

- Media aritmética: También llamado promedio de un grupo de datos o serie de tiempo es quien la caracteriza cuantitativamente, es obtenido sumando todos sus valores y dividiendo esto por entre el número de sumandos. (Rustom, A.,2012)
- Mediana: También llamado valor mediado, al valor de la variable que ocupa la posición central o las dos posiciones centrales de los datos ordenados. Así la mediana es un valor o dos valores que separa a los datos ordenados en dos grupos con igual número de observaciones, uno con valores mayores o iguales

a la mediana y el otro con valores menores o iguales a la mediana. (Rustom, A.,2012)

- Curtosis: Además de la simetría, otra característica importante de la forma en que se distribuyen los datos de la muestra es cómo es el agrupamiento en torno al valor central. Como se observa en la Figura 3.4, los datos se pueden distribuir de forma que tengamos un gran apuntamiento (o pico en el histograma) alrededor del valor central, en cuyo caso diremos que tenemos una distribución leptocúrtica, o en el extremo contrario, el histograma puede ser muy aplanado, lo que corresponde a una distribución platicúrtica. En el caso intermedio, diremos que la distribución es mesocúrtica y el agrupamiento corresponderá al de una distribución llamada normal, o en forma de campana de Gauss. Esta característica del agrupamiento de los datos se denomina curtosis y para cuantificarla se define el coeficiente de curtosis como el cociente entre el momento de cuarto orden respecto a la media y la cuarta potencia de la desviación típica. Este coeficiente adimensional alcanza valores mayores cuanto más puntiaguda es la distribución, teniendo un valor de 3 para la distribución mesocúrtica (o normal), mayor que 3 para la leptocúrtica y menor para la platicúrtica. (Zamorano Calvo, J., 2011)
- Desviación estándar: La desviación estándar, representada por σ , es una medida que se implementa para cuantificar la dispersión de un conjunto de datos o variación. La desviación estándar es igual a la raíz cuadrada de la varianza. Tener una desviación baja nos dice que los datos están agrupados cerca de su

promedio, que es lo que se espera, mientras que un valor alto quiere decir que los datos se encuentran en valores más amplios. La desviación estándar se puede utilizar para establecer un valor de referencia para estimar la variación general de un proceso. (Zamorano Calvo, J., 2011)

- Coeficiente de asimetría de Pearson: Se dice que una distribución de medidas es simétrica cuando valores de la variable equidistantes, a uno y otro lado, del valor central tienen la misma frecuencia. Es decir, en este caso tendremos simetría en el histograma (o en el diagrama de barras) alrededor de una vertical trazada por el punto central. En el caso de una distribución perfectamente simétrica los valores de media aritmética, mediana y moda coinciden. En el caso de no tener simetría, diremos que tenemos asimetría a la derecha (o positiva) o a la izquierda (o negativa) dependiendo de que el histograma muestre una cola de medidas hacia valores altos o bajos de la variable respectivamente. También se puede decir que la distribución está sesgada a la derecha (sesgo positivo) o a la izquierda (sesgo negativo). (Zamorano Calvo, J., 2011)
- Rango Intercuartil: El rango intercuartílico IQR (o rango intercuartil) es una estimación estadística de la dispersión de una distribución de datos. Consiste en la diferencia entre el tercer y el primer cuartil. Mediante esta medida se eliminan los valores extremadamente alejados. El rango intercuartílico es altamente recomendable cuando la medida de tendencia central utilizada es la mediana (ya que este estadístico es insensible a posibles irregularidades en los extremos). Conforme aumente el IQR, indicará que la dispersión será mayor. Por lo tanto,

en distribuciones con una gran asimetría, (alejadas de la distribución normal o campana de Gauss) es más apropiado medir la tendencia central y la dispersión mediante la mediana y el rango intercuartílico respectivamente que con la media aritmética y la desviación típica. (Molinero, L., 2003)

- Coeficiente de Variación: Es una medida estadística que ofrece información respecto de la dispersión relativa de un conjunto de datos. Esta medida es muy utilizada en la ciencia de las estadísticas, relacionando la media aritmética y la desviación estándar de un conjunto de datos. Así, en resumen, el coeficiente de variación sería la variación ambicionada de un conjunto de datos respecto de su media aritmética. Este coeficiente es utilizado para comparar conjuntos de datos de poblaciones distintas, teniéndose en cuenta el valor de la media aritmética, lo que nos permite eliminar las eventuales distorsiones de las medias de dos o más poblaciones. (Rustom, A.,2012)
- Entropía de Shannon: Mide la incertidumbre de una fuente de información. La entropía también se considera como la cantidad de información promedio que contienen los valores de una señal. Los valores con menor probabilidad son los que aportan más información. Cuando todos los símbolos son igualmente probables (distribución de probabilidad plana), todos aportan información relevante y la entropía es máxima. Básicamente, una entropía más alta indica sistemas más complejos o caóticos, por lo tanto, menos previsibilidad. (Shannon, C. E., 1948)

- Entropía de la muestra: En inglés llamada Sample Entropy, es una herramienta útil para investigar la dinámica de la frecuencia cardíaca y otras series de tiempo. La entropía de la muestra es el logaritmo natural negativo de una estimación de la probabilidad condicional de que las subseries (epoch) de longitud m que coincidan puntualmente dentro de una tolerancia r también coincidan en el siguiente punto. (Goldberger et Al., 2000)

3.3 Desarrollo de un estimador de parámetros usando aprendizaje de máquina

El propósito de esta sección es proponer un estimador que permita obtener valores aceptados de los diferentes parámetros de marcha que se pretenden estimar: la velocidad del paso, la cadencia, la longitud de zancada, la cantidad de pasos elaborados y la duración de la marcha. Para ello se extrajeron de las señales diferentes características espaciales y no lineales que servirán como entradas en los diferentes algoritmos de aprendizaje de máquina utilizados para desarrollar el estimador. Para esto es necesario analizar las relaciones presentes entre las características extraídas con respecto a los parámetros que se pretenden estimar, de manera que se pueda seleccionar el algoritmo de aprendizaje de máquina apropiado para mejorar el desempeño de la estimación.

3.3.1 Análisis exploratorio de datos

Al realizarse el análisis es importante tener claridad acerca de las magnitudes físicas obtenidas por cada uno de los dispositivos usados y las características extraídas de las mismas, esta información se encuentra en las siguientes tablas.

Tabla 5*Magnitudes físicas obtenidas por los diferentes dispositivos*

Dispositivo	Magnitud Física	
	Aceleración Lineal (m/s ²)	Velocidad Angular (m/° ²)
GWALK	X	X
Apple Watch	X	X
IMU		X

Tabla 6*Características extraídas de las señales de los dispositivos*

Características extraídas de las señales	
Espaciales	No Lineales
<ul style="list-style-type: none"> • Media • Mediana • Curtosis • Desviación estándar • Coeficiente de Asimetría de Pearson • Índice Intercuartílico • Coeficiente de Variación 	<ul style="list-style-type: none"> • Entropía de Shannon en Amplitud de la señal • Entropía de la Muestra en Amplitud de la señal • Entropía de Shannon en Tiempo de la señal • Entropía de la Muestra en Tiempo de la señal

De este análisis exploratorio de datos se pretende conocer y comprender la relación existente entre las características extraídas y los parámetros de marcha, evitando hacer suposiciones que lleven a modelos imprecisos o que lleven a modelos que no describan de forma apropiada a los datos. Esto permitirá encontrar alguna correlación y/o tendencia que para seleccionar los algoritmos de aprendizaje de máquina a utilizar para el desarrollo de los estimadores.

A continuación, se presentarán los resultados de la exploración de los datos, que fue realizada numéricamente con el coeficiente de Pearson y gráficamente con gráficas de dispersión, para cada una de las magnitudes físicas obtenidas de los dispositivos.

Aceleración Lineal

Luego de realizar la correspondiente exploración de los datos se pudo concluir que los valores más altos de la correlación lineal se dan con 3 características, el Índice Intercuartílico (IQR), la Entropía de Shannon y Entropía de la muestra en la amplitud de la señal, del dispositivo GWALK y los Apple Watch, de la señal adquirida en el eje X, y solo un par de parámetros, Velocidad del Paso y Longitud de Zancada, esta información se encuentra plasmada detalladamente en la tabla 7-8 y se observa en la Figura 31-32.

Tabla 7

Características extraídas de las señales de los dispositivos y su respectivo coeficiente de Pearson con la Velocidad del Paso

		Aceleracion Lineal Eje X		
		Apple Watch Izquierdo	GWALK	Apple Watch Derecho
Velocidad del Paso	XIQR	XIQR	XIQR	XIQR
	0,60	0,87	0,54	
	XEntShanonAMP	XEntShanonAMP	XEntShanonAMP	XEntShanonAMP
	0,58	0,91	0,61	
	XSampenAMP	XSampenAMP	XSampenAMP	XSampenAMP
	0,57	0,76	0,59	

Figura 31

Características de la Aceleración Lineal en el Eje X de los diferentes dispositivos con respecto a la Velocidad del Paso





Tabla 8

Características extraídas de las señales de los dispositivos y su respectivo coeficiente de Pearson con la Longitud de Zancada

Longitud de Zancada	Aceleracion Lineal Eje X		
	Apple Watch Izquierdo	GWALK	Apple Watch Derecho
	XIQR	XIQR	XIQR
	0,57	0,75	0,50
	XEntShanonAMP	XEntShanonAMP	XEntShanonAMP
	0,52	0,80	0,57
	XSampenAMP	XSampenAMP	XSampenAMP
	0,44	0,61	0,49

Figura 32

Características de la Aceleración Lineal en el Eje X de los diferentes dispositivos con respecto a la Longitud de Zancada



Velocidad Angular

Luego de realizar la correspondiente exploración de los datos se pudo concluir que existe una correlación lineal con una sola característica, la Entropía de la muestra en la amplitud de la señal, del dispositivo GWALK y sensores IMU, de la señal adquirida en el eje Z, y solo un parámetro, la Velocidad del Paso, esta información se encuentra plasmada detalladamente en la tabla 9 y se observa en la Figura 33.


Tabla 9

Características extraídas de las señales de los dispositivos y su respectivo coeficiente de Pearson con la Velocidad del Paso

		Velocidad Angular Eje Z		
Velocidad del Paso		IMU Izquierdo	GWALK	IMU Derecho
		ZSampenAMP	ZSampenAMP	ZSampenAMP
		0,67	0,57	0,74

Figura 33

Características de la Velocidad Angular en el Eje Z de los diferentes dispositivos con respecto a la Velocidad del Paso



Con las demás características extraídas no se encontró una relación lineal con los parámetros de la marcha, por lo tanto, es necesario utilizar algoritmos diferentes a la regresión lineal para el desarrollo del estimador.

Después de llevar a cabo el análisis correspondiente se implementarán los diferentes algoritmos de aprendizaje de máquina supervisado para desarrollar el estimador de parámetros de la marcha. Esto será realizado en Spyder, el cual es un entorno de desarrollo integrado multiplataforma de código abierto para programación científica en lenguaje Python, en este caso la versión de utilizada es Python 3; aquí se utilizarán diferentes librerías como lo son Pylab, Numpy, SciPy, Pyplot, Pandas, Seaborn y la más importante Scikit-learn, el cual es un módulo de Python que integra una amplia gama de algoritmos de aprendizaje automático de última generación para problemas supervisados y no

supervisados de mediana escala. Este paquete se centra en llevar el aprendizaje automático a los no especialistas mediante un lenguaje de alto nivel de uso general (Pedregosa et Al., 2011).

A continuación, se presenta como fue el diseño de los estimadores y lo realizado con cada uno de los diferentes algoritmos de aprendizaje de maquina utilizados para desarrollar el estimador de parámetros de marcha.

3.3.2 Diseño de los estimadores

Los estimadores fueron desarrollados utilizando los siguientes algoritmos mencionados en esta sección. En la tabla X se mencionan los algoritmos, módulos y funciones utilizadas para el desarrollo de los estimadores. Estas funciones pertenecen a la librería Scikit-learn de Python, la cual está enfocada en aprendizaje automático (Pedregosa et Al, 2011).

Tabla 10

Diseño de los estimadores

Algoritmo	Módulo	Función	Hiperparámetros
Regresión Lineal Simple	Linear Models	LinearRegression	-
Regresión Lineal Múltiple	Linear Models	LinearRegression	-
Árboles de Decisión	Decision Trees	DecisionTreeRegressor	Max_depth Min_samples_split Min_samples_leaf
Bosques Aleatorios	Ensemble Methods	RandomForestRegressor	N_estimators Max_depth Min_samples_split Min_samples_leaf
Máquinas de Soporte Vectorial	Support Vector Machines	SVR	Kernel Gamma Degree Epsilon C

Las entradas a estos estimadores fueron 3 grupos de variables de entrada, el primero compuesto por las características espaciales extraídas de las señales, el segundo por las características no lineales y el tercero compuesto por todas las características. Esta decisión fue tomada con el propósito de evaluar como es el desempeño de los diferentes grupos de características y encontrar cual es el que mejor permite estimar la cadencia del paso, la velocidad del paso y la longitud de zancada.

Tabla 11

Grupos de las características extraídas del GWALK

Número	Grupo de características	Descripción
1	GWALK	Características espaciales y no lineales de las señales de aceleración lineal y velocidad angular del GWALK
2	GWALKAccLinealEspacial	Características espaciales de las señales de aceleración lineal del GWALK
3	GWALKVelAngularEspacial	Características espaciales de las señales de velocidad angular del GWALK
4	GWALKEspacial	Características espaciales de las señales de aceleración lineal y velocidad angular del GWALK
5	GWALKAccLinealNoLineal	Características no lineales de las señales de aceleración lineal del GWALK
6	GWALKVelAngularNoLineal	Características no lineales de las señales de velocidad angular del GWALK
7	GWALKNoLineal	Características no lineales de las señales de aceleración lineal y velocidad angular del GWALK

Tabla 12

Grupos de las características extraídas del sistema IMU

Número	Grupo de características	Descripción
1	IMU	Características espaciales y no lineales de las señales velocidad angular de ambos sensores
2	IMUVelAngularEspacial	Características espaciales de las señales velocidad angular de ambos sensores
3	IMUVelAngularNoLineal	Características no lineales de las señales velocidad angular de ambos sensores
4	IMUL	Características espaciales y no lineales de las señales velocidad angular del sensor izquierdo
5	IMULVelAngularEspacial	Características espaciales de las señales velocidad angular del sensor izquierdo
6	IMULVelAngularNoLineal	Características no lineales de las señales velocidad angular del sensor izquierdo
7	IMUR	Características espaciales y no lineales de las señales velocidad angular del sensor derecho
8	IMURVelAngularEspacial	Características espaciales de las señales velocidad angular del sensor derecho
9	IMURVelAngularNoLineal	Características no lineales de las señales velocidad angular del sensor derecho

Tabla 13

Grupos de las características extraídas del sistema Apple Watch

Número	Grupo de características	Descripción
1	AW	Características espaciales y no lineales de las señales de aceleración lineal y velocidad angular de ambos relojes
2	AWAccLinealEspacial	Características espaciales de las señales de aceleración lineal de ambos relojes
3	AWVelAngularEspacial	Características espaciales de las señales de velocidad angular de ambos relojes
4	AWEspacial	Características espaciales de las señales de aceleración lineal y velocidad angular de ambos relojes
5	AWAccLinealNoLineal	Características no lineales de las señales de aceleración lineal de ambos relojes
6	AWVelAngularNoLineal	Características no lineales de las señales de velocidad angular de ambos relojes
7	AWNoLineal	Características no lineales de las señales de aceleración lineal y velocidad angular de ambos relojes
8	AWL	Características espaciales y no lineales de las señales de aceleración lineal y velocidad angular del Apple Watch izquierdo
9	AWLAccLinealEspacial	Características espaciales de las señales de aceleración lineal del Apple Watch izquierdo
10	AWLVelAngularEspacial	Características espaciales de las señales de velocidad angular del Apple Watch izquierdo
11	AWLEspacial	Características espaciales de las señales de aceleración lineal y velocidad angular del Apple Watch izquierdo
12	AWLAccLinealNoLineal	Características no lineales de las señales de aceleración lineal del Apple Watch izquierdo
13	AWLVelAngularNoLineal	Características no lineales de las señales de velocidad angular del Apple Watch izquierdo
14	AWLNoLineal	Características no lineales de las señales de aceleración lineal y velocidad angular del Apple Watch izquierdo
15	AWR	Características espaciales y no lineales de las señales de aceleración lineal y velocidad angular del Apple Watch derecho
16	AWRAccLinealEspacial	Características espaciales de las señales de aceleración lineal de Apple Watch derecho
17	AWRVelAngularEspacial	Características espaciales de las señales de velocidad angular del Apple Watch derecho
18	AWREspacial	Características espaciales de las señales de aceleración lineal y velocidad angular del Apple Watch derecho
19	AWRAccLinealNoLineal	Características no lineales de las señales de aceleración lineal del Apple Watch derecho
20	AWRVelAngularNoLineal	Características no lineales de las señales de velocidad angular del Apple Watch derecho
21	AWRNoLineal	Características no lineales de las señales de aceleración lineal y velocidad angular del Apple Watch derecho

Los datos se dividieron en dos conjuntos: los datos de entrenamiento, correspondientes al 70% de todos los datos, y los datos de prueba, correspondientes al 30% de todos los datos; esto se realiza con el fin de evitar un sobreajuste (overfitting) de los modelos con respecto a los datos que se tienen. Esto se realizó utilizando la función *train_test_split*.

Además, se implementó la técnica de la Validación Cruzada o k-fold Cross Validation empleando un k=10, para evaluar los desempeños obtenidos y garantizar que estos son independientes de la partición realizada entre datos de entrenamiento y de prueba; esta técnica también permite detectar un posible sobreajuste. Para esto se utilizó la función *cross_validate*.

Las medidas de desempeño utilizadas para la evaluación de los estimadores fueron el coeficiente de determinación R^2 , este determina que tan cercano o distante se encuentran las predicciones de la función de ajuste establecida en un modelo; el mejor resultado

posible es 1.0, y ocurre cuando la predicción coincide con los valores de la variable objetivo; el rango de valores que puede tomar esta medida es de $-\infty$ a 1, encontrando que si el valor es negativo, significa que el modelo no es capaz de predecir los datos ingresados y que es peor que predecir la media. Además, se utilizaron la raíz del error cuadrático medio (RMSE), el error cuadrático medio (MSE) y el error absoluto medio (MAE), métricas comúnmente utilizada para evaluar problemas de regresión.

Por último, la estrategia utilizada para realizar el ajuste de hiperparámetros de los estimadores (Tabla 14) se llevó a cabo con la función *GridSearchCV*, la cual considera exhaustivamente todas las combinaciones de hiperparámetros deseados y se conserva la combinación que mejor desempeño presenta.

Tabla 14*Características de los hiperparámetros*

Algoritmo	Hiperparámetros	Valores	Modelos Entrenados
Árboles de Decisión	Max_depth	1, 2, 3, ..., 18, 19, 20	Hiperparámetro 1 x Hiperparámetro 2 x Hiperparámetro 3 x Validaciones Cruzadas x Parámetros a estimar 20x20x20x10x3=240000
	Min_samples_split	1, 2, 3, ..., 18, 19, 20	
	Min_samples_leaf	1, 2, 3, ..., 18, 19, 20	
Bosques Aleatorios	N_estimators	100, 250	Hiperparámetro 1 x Hiperparámetro 2 x Hiperparámetro 3 x Hiperparámetro 4 x Validaciones Cruzadas x Parámetros a estimar 2x6x9x7x10x3=22680
	Max_depth	5, 10, 15, 20, 25, 50	
	Min_samples_split	2, 3, 4, 5, 6, 7, 8, 9, 10	
	Min_samples_leaf	2, 3, 4, 5, 10, 25, 50	
Máquinas de Soporte Vectorial	Kernel	linear, poly, rbd, sigmoid	Hiperparámetro 1 x Hiperparámetro 2 x Hiperparámetro 3 x Hiperparámetro 4 x Hiperparámetro 5 x Validaciones Cruzadas x Parámetros a estimar 4x2x5x9x6x10x3=64800
	Gamma	scale, auto	
	Degree	1, 2, 3, 4, 5	
	Epsilon	0.0001, 0.00025, 0.005, 0.001, 0.01, 0.05, 0.1, 0.5, 1	
	C	1, 5, 10, 25, 50, 100	

CAPÍTULO 4

RESULTADOS

4.1 Regresión lineal simple

El análisis fue realizado para cada una de las características extraídas de las señales. En las tablas 16, 18 y 20, se muestran las características extraídas de las señales consideradas para desarrollar los estimadores con la regresión lineal simple.

Debido a los malos resultados que se obtuvieron con este algoritmo y la gran cantidad de características presentes, a continuación, se presentan los mejores desempeños obtenidos en los diferentes sistemas de medición de la marcha humana.

Con respecto al GWALK se puede concluir que las características que mejor desempeño presentan son las correspondientes a las extraídas de la señal de Aceleración lineal del Eje X del dispositivo. Las características que presentan un desempeño superior son la desviación estándar ($R^2 = 0,815$), el Índice Intercuartílico ($R^2 = 0,720$) y la Entropía de Shannon en la amplitud de la señal ($R^2 = 0,831$) de la señal de aceleración lineal en el eje X con respecto a las demás características obtenidas de este dispositivo; por el contrario, la característica que peor desempeño presentó fue el coeficiente de variación ($R^2 = -0,131$ y $-0,148$) de la señal de aceleración lineal en el eje Z. El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.

Tabla 15*Mejores desempeños de la regresión lineal para el GWALK*

Parámetro	Característica	R ²	RMSE	MSE	MAE
Cadencia del paso	Entropía de la muestra en la amplitud de la señal en el eje X de la Velocidad Angular	0,225	5,996	36,541	5,042
Velocidad del paso	Entropía de Shannon en la amplitud de la señal en el eje X de la Aceleración Lineal	0,831	0,067	0,005	0,055
Longitud de Zancada	Desviación estándar de la señal en el eje X de la Aceleración Lineal	0,636	0,093	0,009	0,077

Tabla 16*Descripción de las características extraídas del GWALK*

Características GWALK											
Aceleración Lineal					Velocidad Angular						
1	XMedia	12	YMedia	23	ZMedia	34	XMedia	45	YMedia	56	ZMedia
2	XMediana	13	YMediana	24	ZMediana	35	XMediana	46	YMediana	57	ZMediana
3	XCurtosis	14	YCurtosis	25	ZCurtosis	36	XCurtosis	47	YCurtosis	58	ZCurtosis
4	XDesv Std	15	YDesv Std	26	ZDesv Std	37	XDesv Std	48	YDesv Std	59	ZDesv Std
5	XCAP	16	YCAP	27	ZCAP	38	XCAP	49	YCAP	60	ZCAP
6	XIQR	17	YIQR	28	ZIQR	39	XIQR	50	YIQR	61	ZIQR
7	XCV	18	YCV	29	ZCV	40	XCV	51	YCV	62	ZCV
8	XEntShanonAMP	19	YEntShanonAMP	30	ZEntShanonAMP	41	XEntShanonAMP	52	YEntShanonAMP	63	ZEntShanonAMP
9	XSampenAMP	20	YSampenAMP	31	ZSampenAMP	42	XSampenAMP	53	YSampenAMP	64	ZSampenAMP
10	XEntShanonTIME	21	YEntShanonTIME	32	ZEntShanonTIME	43	XEntShanonTIME	54	YEntShanonTIME	65	ZEntShanonTIME
11	XSampenTIME	22	YSampenTIME	33	ZSampenTIME	44	XSampenTIME	55	YSampenTIME	66	ZSampenTIME

Para el sistema IMU se analizaron por separado las características extraídas de los sensores ubicados en cada una de las piernas de los sujetos, aquí se observó que la característica que mejor desempeño presentaba entre los sensores IMU izquierdo y derecho es la Entropía de la muestra en la amplitud de la señal ($R^2 = 0,456$ y $0,429$) de la señal de velocidad angular en el eje Z del sensor izquierdo y derecho, y la característica que peor

desempeño presentó fue el coeficiente de variación ($R^2 = -21,541$) de la señal de velocidad angular en el eje X del sensor izquierdo.

Con respecto al sistema IMU completo, compuesto por los sensores ubicados en cada uno de los tobillos, se puede concluir que las características que mejor desempeño presentan son las correspondientes a las extraídas de la señal de Velocidad Angular del Eje Z de los sensores ubicados en cada pierna. La característica que presenta un desempeño superior con respecto a las demás características obtenidas de este sistema es la Entropía de la muestra en la amplitud de la señal ($R^2 = 0,456$ y $0,429$); por el contrario, la característica que peor desempeño presentó fue el coeficiente de variación ($R^2 = -22,081$). Los parámetros que mejor se pueden estimar con este algoritmo es la velocidad del paso, la cadencia del paso y la duración de la marcha.

Tabla 17

Mejores desempeños de la regresión lineal para el sistema IMU

Parámetro	Característica	R^2	RMSE	MSE	MAE
Cadencia del paso	Entropía de la muestra en la amplitud de la señal en el eje Z de la Velocidad Angular	0,456	4,937	24,798	3,909
Velocidad del paso	Entropía de la muestra en la amplitud de la señal en el eje Z de la Velocidad Angular	0,429	0,124	0,016	0,094
Longitud de Zancada	Desviación estándar de la señal en el eje Z de la Velocidad Angular	0,193	0,140	0,020	0,115

Tabla 18*Descripción de las características extraídas del sistema IMU*

Características IMU											
Velocidad Angular Sensor Izquierdo					Velocidad Angular Sensor Derecho						
1	XMedia	12	YMedia	23	ZMedia	34	XMedia	45	YMedia	56	ZMedia
2	XMediana	13	YMediana	24	ZMediana	35	XMediana	46	YMediana	57	ZMediana
3	XCurtosis	14	YCurtosis	25	ZCurtosis	36	XCurtosis	47	YCurtosis	58	ZCurtosis
4	XDesv Std	15	YDesv Std	26	ZDesv Std	37	XDesv Std	48	YDesv Std	59	ZDesv Std
5	XCAP	16	YCAP	27	ZCAP	38	XCAP	49	YCAP	60	ZCAP
6	XIQR	17	YIQR	28	ZIQR	39	XIQR	50	YIQR	61	ZIQR
7	XCV	18	YCV	29	ZCV	40	XCV	51	YCV	62	ZCV
8	XEntShanonAMP	19	YEntShanonAMP	30	ZEntShanonAMP	41	XEntShanonAMP	52	YEntShanonAMP	63	ZEntShanonAMP
9	XSampenAMP	20	YSampenAMP	31	ZSampenAMP	42	XSampenAMP	53	YSampenAMP	64	ZSampenAMP
10	XEntShanonTIME	21	YEntShanonTIME	32	ZEntShanonTIME	43	XEntShanonTIME	54	YEntShanonTIME	65	ZEntShanonTIME
11	XSampenTIME	22	YSampenTIME	33	ZSampenTIME	44	XSampenTIME	55	YSampenTIME	66	ZSampenTIME

Para el sistema Apple Watch se analizaron por separado las características extraídas de los relojes ubicados en cada una de las muñecas de los sujetos, aquí se observó que las características que mejor desempeño presentaban entre el Apple Watch izquierdo y derecho son el Índice Intercuartílico ($R^2 = 0,331$) y la Entropía de la muestra en la amplitud de la señal ($R^2 = 0,307$) en el eje X de la señal de aceleración lineal del Apple Watch izquierdo, y la característica que peor desempeño presentó fue la curtosis ($R^2 = -1,587$) en el eje Y de la señal de velocidad angular del Apple Watch izquierdo.

Con respecto al sistema Apple Watch completo, compuesto por los dos relojes ubicados en cada una en las muñecas, se puede concluir que las características que mejor desempeño presentan son las correspondientes a las extraídas de la señal de Aceleración Lineal del Eje X de los relojes ubicados en cada muñeca. Las características que presentan un desempeño superior con respecto a las demás características obtenidas de este dispositivo son el Índice Intercuartílico ($R^2 = 0,331$) y la Entropía de Shannon en la amplitud ($R^2 = 0,308$ y $0,307$)

en el eje X de la señal de aceleración lineal. Los parámetros que mejor se pueden estimar con este algoritmo es la velocidad del paso, la longitud de la zancada y la duración de la marcha.

Tabla 19

Mejores desempeños de la regresión lineal para el sistema Apple Watch

Parámetro	Característica	R ²	RMSE	MSE	MAE
Cadencia del paso	Coficiente de Asimetría de Pearson de la señal en el eje Z de la Aceleración Lineal	0,124	6,422	43,072	5,045
Velocidad del paso	Rango Intercuartil de la señal en el eje X de la Aceleración Lineal	0,331	0,136	0,019	0,112
Longitud de Zancada	Rango Intercuartil de la señal en el eje X de la Aceleración Lineal	0,321	0,128	0,017	0,101

Tabla 20

Descripción de las características extraídas del sistema Apple Watch

Características Apple Watch											
Aceleración Lineal Reloj Izquierdo					Velocidad Angular Reloj Izquierdo						
1	XMedia	12	YMedia	23	ZMedia	34	XMedia	45	YMedia	56	ZMedia
2	XMediana	13	YMediana	24	ZMediana	35	XMediana	46	YMediana	57	ZMediana
3	XCurtosis	14	YCurtosis	25	ZCurtosis	36	XCurtosis	47	YCurtosis	58	ZCurtosis
4	XDesv Std	15	YDesv Std	26	ZDesv Std	37	XDesv Std	48	YDesv Std	59	ZDesv Std
5	XCAP	16	YCAP	27	ZCAP	38	XCAP	49	YCAP	60	ZCAP
6	XIQR	17	YIQR	28	ZIQR	39	XIQR	50	YIQR	61	ZIQR
7	XCV	18	YCV	29	ZCV	40	XCV	51	YCV	62	ZCV
8	XEntShanonAMP	19	YEntShanonAMP	30	ZEntShanonAMP	41	XEntShanonAMP	52	YEntShanonAMP	63	ZEntShanonAMP
9	XSampenAMP	20	YSampenAMP	31	ZSampenAMP	42	XSampenAMP	53	YSampenAMP	64	ZSampenAMP
10	XEntShanonTIME	21	YEntShanonTIME	32	ZEntShanonTIME	43	XEntShanonTIME	54	YEntShanonTIME	65	ZEntShanonTIME
11	XSampenTIME	22	YSampenTIME	33	ZSampenTIME	44	XSampenTIME	55	YSampenTIME	66	ZSampenTIME
Aceleración Lineal Reloj Derecho					Velocidad Angular Reloj Derecho						
67	XMedia	78	YMedia	89	ZMedia	100	XMedia	111	YMedia	122	ZMedia
68	XMediana	79	YMediana	90	ZMediana	101	XMediana	112	YMediana	123	ZMediana
69	XCurtosis	80	YCurtosis	91	ZCurtosis	102	XCurtosis	113	YCurtosis	124	ZCurtosis
70	XDesv Std	81	YDesv Std	92	ZDesv Std	103	XDesv Std	114	YDesv Std	125	ZDesv Std
71	XCAP	82	YCAP	93	ZCAP	104	XCAP	115	YCAP	126	ZCAP
72	XIQR	83	YIQR	94	ZIQR	105	XIQR	116	YIQR	127	ZIQR
73	XCV	84	YCV	95	ZCV	106	XCV	117	YCV	128	ZCV
74	XEntShanonAMP	85	YEntShanonAMP	96	ZEntShanonAMP	107	XEntShanonAMP	118	YEntShanonAMP	129	ZEntShanonAMP
75	XSampenAMP	86	YSampenAMP	97	ZSampenAMP	108	XSampenAMP	119	YSampenAMP	130	ZSampenAMP
76	XEntShanonTIME	87	YEntShanonTIME	98	ZEntShanonTIME	109	XEntShanonTIME	120	YEntShanonTIME	131	ZEntShanonTIME
77	XSampenTIME	88	YSampenTIME	99	ZSampenTIME	110	XSampenTIME	121	YSampenTIME	132	ZSampenTIME

En el análisis de la sección 3.3.2 se concluyó que las características que presentan una tendencia lineal son el Índice Intercuartílico, la Entropía de Shannon y Entropía de la muestra en la amplitud de la señal, del dispositivo GWALK y los Apple Watch de la aceleración lineal en el eje X; y sobre la Entropía de la muestra en la amplitud de la señal, del dispositivo GWALK y sensores IMU de la velocidad angular en el eje Z. Esta conclusión se reafirma con el análisis y los resultados obtenidos de los estimadores realizados con el algoritmo de regresión lineal simple.

Al observar el bajo desempeño de los estimadores con este algoritmo, se procedió a utilizar otros algoritmos más robustos que pueden tener mejor desempeño como los presentados en las siguientes secciones.

4.2 Regresión lineal múltiple

El análisis fue realizado para diferentes grupos de características extraídas de las señales. Los resultados obtenidos son presentados en la Figura 34, 38 y 42.

En las tablas 11, 12 y 13 se muestra el significado de cada uno de los números representados en el eje X de la gráfica 34, 38 y 42, estos corresponden a cada uno de los grupos de las características consideradas para la regresión lineal múltiple.

Con respecto al GWALK se puede concluir que el grupo de características que mejor desempeño presenta son las correspondientes a las características espaciales extraídas de las señales de Aceleración lineal del dispositivo ($R^2 = 0,923$). Por el contrario, el grupo de características que peor desempeño presentó fue las características espaciales extraídas de

las señales de Velocidad Angular del dispositivo ($R^2 = 0,048$ y $0,196$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.

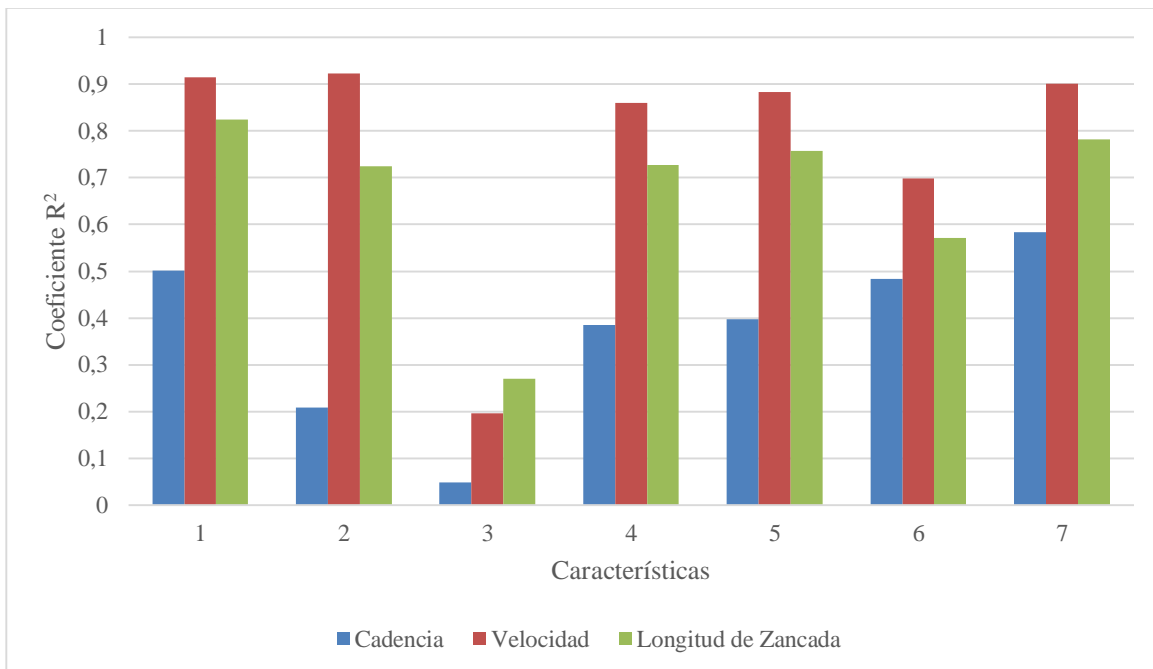
Tabla 21

Mejores desempeños de la regresión lineal múltiple para el GWALK

Parámetro	Característica	R^2	RMSE	MSE	MAE
Cadencia del paso	Características No Lineales de todas las señales	0,584	4,191	17,943	3,260
Velocidad del paso	Características Espaciales de las señales de la Aceleración Lineal	0,923	0,046	0,002	0,039
Longitud de Zancada	Características Espaciales y No Lineales de todas las señales	0,824	0,063	0,004	0,049

Figura 34

Coefficiente R^2 vs Características del GWALK



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 35, 36 y 37), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 35

Residuos vs Valores predichos de la Cadencia con el GWALK

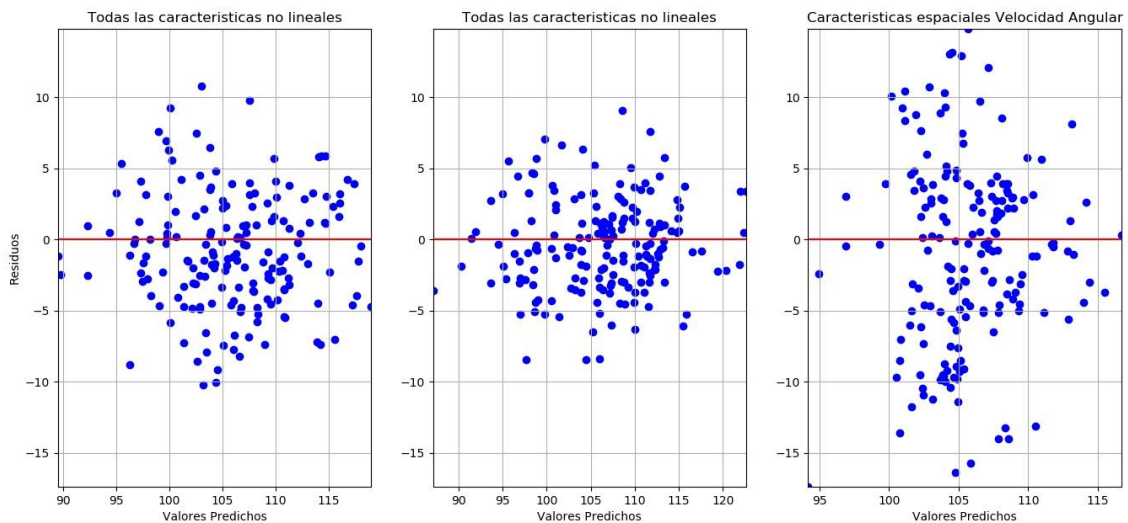




Figura 36

Residuos vs Valores predichos de la Velocidad con el GWALK

**Figura 37**

Residuos vs Valores predichos de la Longitud de Zancada con el GWALK



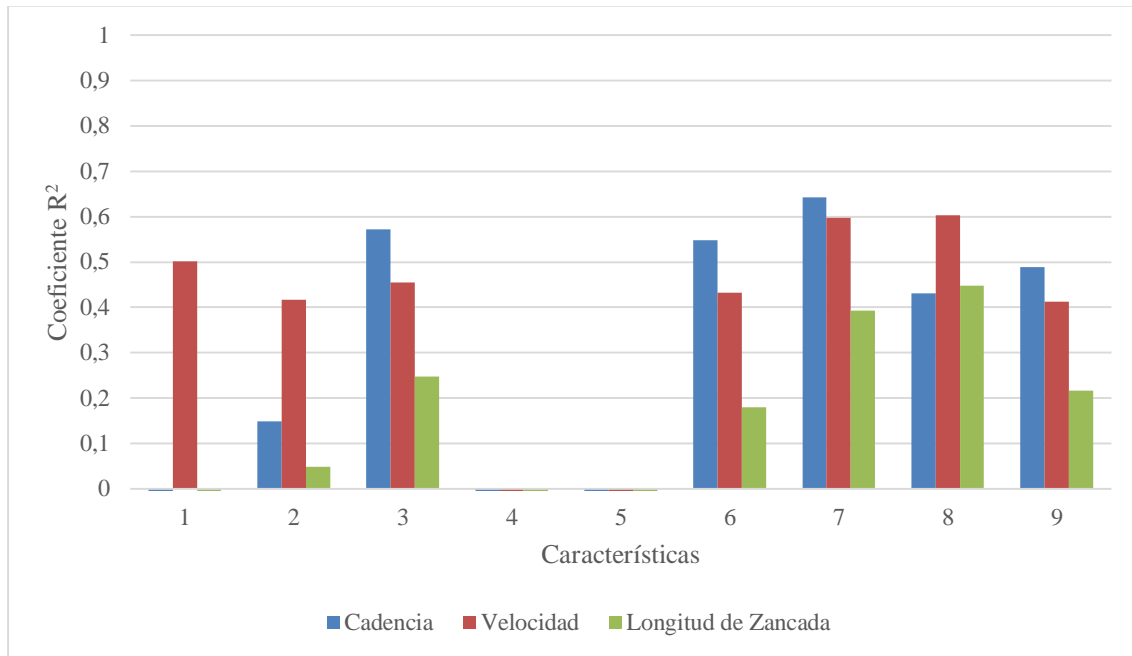
Para el sistema IMU se analizaron por separado los grupos de características extraídas de los sensores ubicados en cada una de las piernas de los sujetos, aquí se observó que el grupo de características que mejor desempeño presentaba es el correspondiente a las características espaciales y no lineales extraídas de las señales de Velocidad Angular del sensor derecho ($R^2 = 0,643$); y el grupo de características que peor desempeño presentó fue las características espaciales de la velocidad angular correspondientes al sensor izquierdo ($R^2 = -2,657$).

Con respecto al sistema IMU completo, compuesto por los sensores ubicados en cada uno de los tobillos, se puede concluir que el grupo de características que mejor desempeño presentó son las características no lineales a las extraídas de la señal de Velocidad Angular de ambos sensores ($R^2 = 0,573$). Por el contrario, el grupo de características que peor desempeño presentó fueron las características espaciales y no lineales extraídas de las señales de Velocidad Angular de ambos sensores ($R^2 = -0,094$). El parámetro que mejor se puede estimar con este algoritmo es la cadencia del paso.

Tabla 22

Mejores desempeños de la regresión lineal múltiple para el sistema IMU

Parámetro	Característica	R^2	RMSE	MSE	MAE
Cadencia del paso	Características Espaciales y No Lineales de las señales del sensor derecho	0,643	3,887	15,639	3,023
Velocidad del paso	Características Espaciales de la Velocidad Angular del sensor derecho	0,603	0,105	0,011	0,085
Longitud de Zancada	Características Espaciales de la Velocidad Angular del sensor derecho	0,448	0,114	0,014	0,091


Figura 38*Coefficiente R^2 vs Características del sistema IMU*

A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 39, 40 y 41), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la cadencia del paso.

Figura 39

Residuos vs Valores predichos de la Cadencia con el sistema IMU

**Figura 40**

Residuos vs Valores predichos de la Velocidad con el sistema IMU





Figura 41

Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU



Para el sistema Apple Watch se analizaron por separado las características extraídas de los relojes ubicados en cada una de las muñecas de los sujetos, aquí se observó que el grupo de características que mejor desempeño presentaba es el correspondiente a las características no lineales extraídas de las señales del Apple Watch derecho ($R^2 = 0,571$), y el grupo de características que peor desempeño presentó fue el correspondiente a las características espaciales extraídas de las señales del Apple Watch izquierdo ($R^2 = -3,407$).

Con respecto al sistema Apple Watch completo, compuesto por los dos relojes ubicados en cada una en las muñecas, se puede concluir que el grupo de características que mejor desempeño presentó fueron las correspondientes a las características no lineales extraídas de las señales de ambos relojes ($R^2 = 0,617$). Por el contrario, el grupo de características que peor desempeño presentó está conformado por las características espaciales extraídas

de las señales de ambos relojes ($R^2 = -4,113$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.


Tabla 23

Mejores desempeños de la regresión lineal múltiple para el sistema Apple Watch

Parámetro	Característica	R ²	RMSE	MSE	MAE
Cadencia del paso	Características Espaciales de las señales del reloj izquierdo	0,527	4,677	22,300	3,738
Velocidad del paso	Características No Lineales de las todas señales ambos relojes	0,617	0,101	0,010	0,080
Longitud de Zancada	Características No Lineales de las todas señales ambos relojes	0,483	0,111	0,013	0,085

Figura 42

Coefficiente R² vs Características del sistema Apple Watch



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 43, 44 y 45), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 43

Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch




Figura 44

Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch





Figura 45

Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch



4.3 Árboles de decisión

El análisis fue realizado para diferentes grupos de características extraídas de las señales. Los resultados obtenidos son presentados en las figuras 46, 50 y 54.

En las tablas 11, 12 y 13 se muestra el significado de cada uno de los números representados en el eje X de las figuras 46, 50 y 54, los cuales corresponden a cada uno de los grupos de características considerados para los árboles de decisión.

Los hiperparámetros optimizados en este algoritmo fueron:

- **Max_depth:** El principal parámetro a controlar es la profundidad máxima del árbol, calculado como el recorrido más largo desde la raíz hasta el último nodo; si no se pone un valor para la profundidad el árbol se expandirá al máximo y probablemente nuestro modelo sufra de overfitting. Además, se debe tomar en cuenta el número de observaciones disponibles: el número necesario para construir un árbol se duplica con cada nivel que se agrega, por lo que ante una muestra pequeña es aún más importante tomar en cuenta este parámetro.
- **Min_samples_split:** Este valor regula el número mínimo de muestras necesarias antes de dividir un nodo. Al obligar a los nodos a convertirse en hojas por no tener el número mínimo de datos para poder ser un nodo y dividirse, reducimos el sobre ajuste.
- **Min_samples_leaf:** Este valor regula el número mínimo de muestras que debe haber en un nodo para que este pueda ser considerado un nodo externo o hoja.


Esto obligara a los nodos a no seguir dividiendo y convertirse en hoja antes, reduciendo así el sobre ajuste.

Con respecto al GWALK se puede concluir que el grupo de características con mejor desempeño son las características espaciales extraídas de las señales del dispositivo ($R^2 = 0,895$); por el contrario, el grupo de características que peor desempeño presentó fue el compuesto por las características no lineales extraídas de las señales de velocidad angular del dispositivo ($R^2 = 0,061$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.

Tabla 24

Mejores desempeños de los árboles de decisión para el GWALK

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales de todas las señales	0,325	5,104	27,254	3,732	Max_depth = 10 Min_samples_leaf = 6 Min_samples_split = 2
Velocidad del paso	Características Espaciales de todas las señales	0,895	0,052	0,003	0,039	Max_depth = 14 Min_samples_leaf = 1 Min_samples_split = 13
Longitud de Zancada	Características Espaciales de todas las señales de Aceleración Lineal	0,780	0,067	0,005	0,048	Max_depth = 7 Min_samples_leaf = 1 Min_samples_split = 15

Figura 46*Coefficiente R^2 vs Características del GWALK*

A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 47, 48 y 49), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 47

Residuos vs Valores predichos de la Cadencia con el GWALK




Figura 48

Residuos vs Valores predichos de la Velocidad con el GWALK





Figura 49

Residuos vs Valores predichos de la Longitud de Zancada con el GWALK



Para el sistema IMU se analizaron por separado las características extraídas de los sensores ubicados en cada una de las piernas de los sujetos, aquí se observó que el grupo de características que mejor desempeño presentó está conformado por las características espaciales y no lineales extraídas de las señales del sensor izquierdo ($R^2 = 0,709$), y el grupo de características que peor desempeño presentó fue el compuesto por las características no lineales de las señales extraídas del sensor derecho ($R^2 = 0,177$).

Con respecto al sistema IMU completo, compuesto por los sensores ubicados en cada uno de los tobillos, se puede concluir que el grupo de características que mejor desempeño presentó son las características espaciales y no lineales extraídas de las señales de ambos sensores ($R^2 = 0,721$); por el contrario, el grupo de características que peor desempeño presentó está conformado por las características no lineales extraídas de las señales de

ambos sensores ($R^2 = 0,236$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.


Tabla 25

Mejores desempeños de los árboles de decisión para el sistema IMU

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales y No Lineales de todas las señales del sensor izquierdo	0,709	3,671	14,503	2,418	Max_depth = 13 Min_samples_leaf = 3 Min_samples_split = 13
Velocidad del paso	Características Espaciales y No Lineales de todas las señales de ambos sensores	0,721	0,087	0,008	0,067	Max_depth = 5 Min_samples_leaf = 12 Min_samples_split = 2
Longitud de Zancada	Características Espaciales y No Lineales de todas las señales del sensor izquierdo	0,596	0,092	0,009	0,062	Max_depth = 12 Min_samples_leaf = 1 Min_samples_split = 10

Figura 50

Coefficiente R^2 vs Características del sistema IMU



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 51, 52 y 53), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 51

Residuos vs Valores predichos de la Cadencia con el sistema IMU






Figura 52

Residuos vs Valores predichos de la Velocidad con el sistema IMU

**Figura 53**

Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU



Para el sistema Apple Watch se analizaron por separado las características extraídas de los relojes ubicados en cada una de las muñecas de los sujetos, aquí se observó que el grupo de características que mejor desempeño presentó está compuesto por las características espaciales extraídas de las señales del Apple Watch izquierdo ($R^2 = 0,763$), y el grupo de características que peor desempeño presentó está compuesto por las características no lineales extraídas de las señales de velocidad angular del Apple Watch derecho ($R^2 = -0,203$).

Con respecto al sistema Apple Watch completo, compuesto por los dos relojes ubicados en cada una en las muñecas, se puede concluir que el grupo de características que mejor desempeño presentó son las correspondientes a las características espaciales extraídas de las señales de Aceleración Lineal de ambos relojes ($R^2 = 0,720$). Por el contrario, el grupo de características que peor desempeño presentó son las correspondientes a las características no lineales extraídas de las señales de velocidad angular de ambos relojes ($R^2 = 0,040$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.


Tabla 26

Mejores desempeños de los árboles de decisión para el sistema Apple Watch

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales de todas las señales de ambos relojes	0,595	4,207	19,719	2,865	Max_depth = 7 Min_samples_leaf = 1 Min_samples_split = 10
Velocidad del paso	Características Espaciales de las señales de Aceleración Lineal de ambos relojes	0,720	0,086	0,008	0,059	Max_depth = 9 Min_samples_leaf = 3 Min_samples_split = 8
Longitud de Zancada	Características Espaciales de las todas señales del reloj izquierdo	0,764	0,074	0,006	0,054	Max_depth = 7 Min_samples_leaf = 3 Min_samples_split = 15

Figura 54

Coefficiente R^2 vs Características del sistema Apple Watch



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 55, 56 y 57), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la longitud de zancada.

Figura 55

Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch




Figura 56

Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch

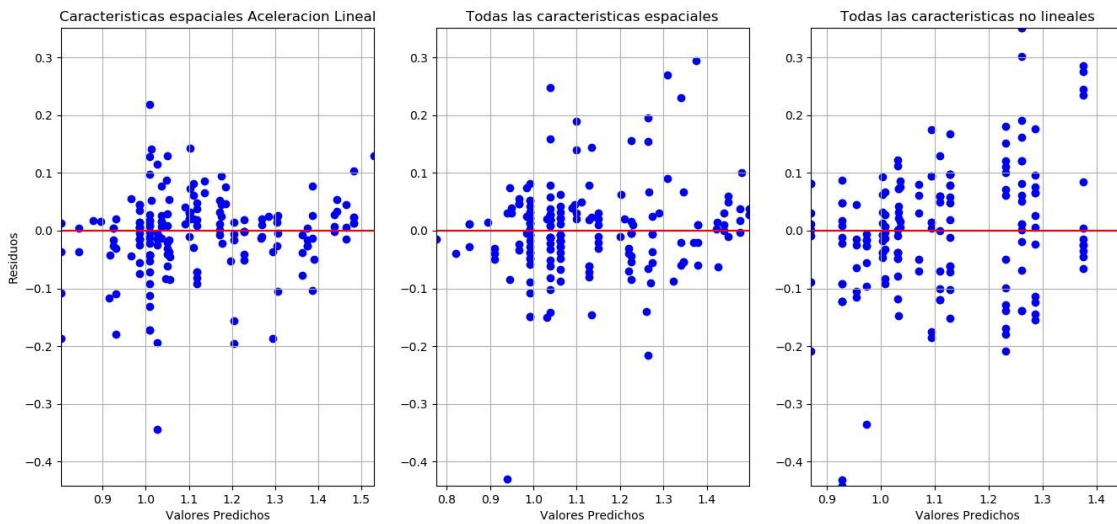



Figura 57

Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch

**4.4 Bosques aleatorios**

El análisis fue realizado para cada una de las características extraídas de las señales. Los resultados obtenidos son presentados en gráficas las figuras 58, 62 y 66.

En las tablas 11, 12 y 13, se muestra el significado de cada uno de los números representados en el eje X de las figuras 58, 62 y 66, los cuales corresponden a cada uno de los grupos de características considerados para los bosques aleatorios.

Los hiperparámetros optimizados en este algoritmo fueron:

- **N_estimators:** Este valor define el número de árboles que va a tener el bosque aleatorio. Normalmente a mayor cantidad de árboles se estabiliza el error en las estimaciones, por ende, se obtiene un mejor desempeño, pero a partir de cierto

punto deja de mejorar y sólo hace que vaya que sea más demorado el tiempo de procesamiento.


- **Max_depth:** El principal parámetro a controlar es la profundidad máxima del árbol, calculado como el recorrido más largo desde la raíz hasta el último nodo; si no se pone un valor para la profundidad el árbol se expandirá al máximo y probablemente nuestro modelo sufra de overfitting. Además, se debe tomar en cuenta el número de observaciones disponibles: el número necesario para construir un árbol se duplica con cada nivel que se agrega, por lo que ante una muestra pequeña es aún más importante tomar en cuenta este parámetro.
- **Min_samples_split:** Este valor regula el número mínimo de muestras necesarias antes de dividir un nodo. Al obligar a los nodos a convertirse en hojas por no tener el número mínimo de datos para poder ser un nodo y dividirse, reducimos el sobre ajuste.
- **Min_samples_leaf:** Este valor regula el número mínimo de muestras que debe haber en un nodo para que este pueda ser considerado un nodo externo o hoja. Esto obligara a los nodos a no seguir dividiendo y convertirse en hoja antes, reduciendo así el sobre ajuste.

Con respecto al GWALK se puede concluir que el grupo de características que mejor desempeño presentó son las correspondientes a las características espaciales extraídas de las señales del dispositivo ($R^2 = 0,937$); por el contrario, el grupo de características que peor desempeño presentó son las características espaciales extraídas de las señales de Velocidad Angular del dispositivo ($R^2 = 0,486$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.

Tabla 27

Mejores desempeños de los bosques aleatorios para el GWALK

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales y No Lineales de todas las señales	0,688	3,621	13,629	2,726	Max_depth = 10 Min_samples_leaf = 2 Min_samples_split = 3
Velocidad del paso	Características Espaciales de todas las señales	0,937	0,040	0,002	0,031	Max_depth = 20 Min_samples_leaf = 2 Min_samples_split = 2
Longitud de Zancada	Características Espaciales y No Lineales de todas las señales	0,879	0,052	0,003	0,039	Max_depth = 15 Min_samples_leaf = 2 Min_samples_split = 2

Figura 58*Coefficiente R^2 vs Características del GWALK*

A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 59, 60 y 61), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.




Figura 59*Residuos vs Valores predichos de la Cadencia con el GWALK***Figura 60***Residuos vs Valores predichos de la Velocidad con el GWALK*

Figura 61

Residuos vs Valores predichos de la Longitud de Zancada con el GWALK



Para el sistema IMU se analizaron por separado las características extraídas de los sensores ubicados en cada una de las piernas de los sujetos, aquí se observó que el grupo de características que mejor desempeño presentó está conformado por las características espaciales y no lineales extraídas de las señales del sensor izquierdo ($R^2 = 0,817$), y el grupo de características que peor desempeño presentó está conformado por las características no lineales extraídas de las señales de velocidad angular del sensor derecho ($R^2 = 0,558$).

Con respecto al sistema IMU completo, compuesto por los sensores ubicados en cada uno de los tobillos, se puede concluir que el grupo de características que mejor desempeño presentó son las correspondientes a las características espaciales y no lineales extraídas de las señales de ambos sensores ($R^2 = 0,849$). Por el contrario, el grupo de características que peor desempeño presentó son las correspondientes a las características no lineales extraídas

de las señales de ambos sensores ($R^2 = 0,642$). El parámetro que mejor se puede estimar con este algoritmo es la velocidad del paso.


Tabla 28

Mejores desempeños de los bosques aleatorios para el sistema IMU

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales y No Lineales de todas las señales de ambos sensores	0,801	3,001	9,457	2,250	Max_depth = 20 Min_samples_leaf = 2 Min_samples_split = 3
Velocidad del paso	Características Espaciales y No Lineales de todas las señales de ambos sensores	0,849	0,063	0,004	0,047	Max_depth = 20 Min_samples_leaf = 2 Min_samples_split = 2
Longitud de Zancada	Características Espaciales de las señales de Velocidad Angular de ambos sensores	0,782	0,070	0,006	0,051	Max_depth = 15 Min_samples_leaf = 2 Min_samples_split = 2

Figura 62

Coefficiente R2 vs Características del sistema IMU



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 63, 64 y 65), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 63

Residuos vs Valores predichos de la Cadencia con el sistema IMU






Figura 64

Residuos vs Valores predichos de la Velocidad con el sistema IMU

**Figura 65**

Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU




Para el sistema Apple Watch se analizaron por separado las características extraídas de los relojes ubicados en cada una de las muñecas de los sujetos, aquí se observó el grupo de características que mejor desempeño presentó está conformado por las características espaciales extraídas de las señales de aceleración lineal del Apple Watch izquierdo ($R^2 = 0,793$), y el grupo de características que peor desempeño presentó está conformado por las características no lineales extraídas de las señales de velocidad angular del Apple Watch derecho ($R^2 = 0,240$).

Con respecto al sistema Apple Watch completo, compuesto por los dos relojes ubicados en cada una en las muñecas, se puede concluir que el grupo de características que mejor desempeño presentan son las correspondientes a las características espaciales extraídas de las señales de aceleración lineal de ambos relojes ($R^2 = 0,822$). Por el contrario, el grupo de características que peor desempeño presentó son las correspondientes a las características no lineales extraídas de las señales de velocidad angular de ambos relojes ($R^2 = 0,408$). Los parámetros que mejor se pueden estimar con este algoritmo es la velocidad del paso y la longitud de la zancada.

Tabla 29

Mejores desempeños de los bosques aleatorios para el sistema Apple Watch

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales de todas las señales de ambos relojes	0,739	3,544	13,203	2,645	Max_depth = 15 Min_samples_leaf = 2 Min_samples_split = 5
Velocidad del paso	Características Espaciales de las señales de Aceleración Lineal de ambos relojes	0,822	0,069	0,005	0,052	Max_depth = 15 Min_samples_leaf = 2 Min_samples_split = 2
Longitud de Zancada	Características Espaciales de todas las señales de ambos relojes	0,801	0,069	0,005	0,050	Max_depth = 20 Min_samples_leaf = 2 Min_samples_split = 5


Figura 66*Coefficiente R^2 vs Características del sistema Apple Watch*

A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 67, 68 y 69), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 67

Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch

**Figura 68**

Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch





Figura 69

Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch

**4.5 Máquinas de soporte vectorial**

El análisis fue realizado para cada una de las características extraídas de las señales. Los resultados obtenidos son presentados en las figuras 70, 74 y 78.

En las tablas 11, 12 y 13, se muestra el significado de cada uno de los números representados en el eje X de las figuras 70, 74 y 78, los cuales corresponden a cada uno de los grupos de características considerados para las máquinas de soporte vectorial.

Los hiperparámetros optimizados en este algoritmo fueron:

- **Kernel:** Especifica el tipo de kernel (núcleo) que se utilizará en el algoritmo. Debe ser uno de "lineal", "poly", "rbf", "sigmoide" o "precompute". Si no se selecciona ninguno, se usa por defecto "rbf". Con el tipo especificado se realiza el precalculo de la matriz del núcleo.

- **Gamma:** Coeficiente de núcleo para "rbf", "poly" y "sigmoid".

Sí $\gamma = \text{scale}$, usa $1 / (n_{\text{características}} * X.\text{varianza}())$ como valor de γ .

Si $\gamma = \text{auto}$, usa $1 / n_{\text{características}}$ como valor de γ .
- **Grado:** Grado de la función del núcleo polinómico ('poly'). Este hiperparámetro es ignorado por todos los demás núcleos.
- **Epsilon:** Este valor especifica el rango dentro del cual no se asocia ninguna penalización en la función de pérdida de entrenamiento con los puntos pronosticados dentro de una distancia del valor real. Por lo tanto, este parámetro controla el error cometido por la función de regresión al aproximar las bandas, es decir, determina el nivel de precisión de la función aproximada.
- **C:** Es el parámetro de regularización, es una constante y debe ser mayor a 0. Este determina el equilibrio entre la regularidad de la función y el valor hasta el cual se tolera desviaciones mayores que las bandas de soporte.

Con respecto al GWALK se puede concluir que el grupo de características que mejor desempeño presentó son las correspondientes a las características espaciales y no lineales extraídas de todas las señales del dispositivo ($R^2 = 0,955$); por el contrario, el grupo de características que peor desempeño presentó son las características no lineales extraídas de las señales de Aceleración Lineal del dispositivo ($R^2 = 0,594$). Los parámetros que mejor se pueden estimar con este algoritmo es la velocidad del paso y la longitud de zancada.


Tabla 30

Mejores desempeños de las máquinas de soporte vectorial para el GWALK

Parámetro	Característica	R ²	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales de todas las señales	0,846	2,573	6,962	1,934	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,1 C = 100
Velocidad del paso	Características Espaciales y No Lineales de todas las señales	0,955	0,034	0,001	0,027	Kernel = rbf Gamma = auto Degree = 1 Epsilon = 0,0001 C = 1
Longitud de Zancada	Características Espaciales de todas las señales	0,935	0,038	0,002	0,029	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,01 C = 1

Figura 70

Coefficiente R² vs Características del GWALK



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 71, 72 y 73), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 71

Residuos vs Valores predichos de la Cadencia con el GWALK






Figura 72

Residuos vs Valores predichos de la Velocidad con el GWALK

**Figura 73**

Residuos vs Valores predichos de la Longitud de Zancada con el GWALK




Para el sistema IMU se analizaron por separado las características extraídas de los sensores ubicados en cada una de las piernas de los sujetos, aquí se observó que el grupo de características que mejor desempeño presentó está conformado por las características espaciales y no lineales extraídas de las señales del sensor izquierdo ($R^2 = 0,868$), y el grupo de características que peor desempeño presentó fue el compuesto por las características no lineales de las señales extraídas del sensor derecho ($R^2 = 0,441$).

Con respecto al sistema IMU completo, compuesto por los sensores ubicados en cada uno de los tobillos, se puede concluir que el grupo de características que mejor desempeño presentó son las características espaciales extraídas de las señales de ambos sensores ($R^2 = 0,866$); por el contrario, el grupo de características que peor desempeño presentó está conformado por las características no lineales extraídas de las señales de ambos sensores ($R^2 = 0,636$). El parámetro que mejor se puede estimar con este algoritmo es la cadencia del paso y velocidad del paso.

Tabla 31

Mejores desempeños de las máquinas de soporte vectorial para el sistema IMU

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales de todas las señales de ambos sensores	0,866	2,446	6,101	1,854	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 1 C = 100
Velocidad del paso	Características Espaciales y No Lineales de todas las señales del sensor izquierdo	0,868	0,060	0,004	0,045	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,01 C = 1
Longitud de Zancada	Características Espaciales y No Lineales de todas las señales del sensor izquierdo	0,824	0,063	0,004	0,047	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,01 C = 1

Figura 74*Coefficiente R² vs Características del sistema IMU*

A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 75, 76 y 77), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.




Figura 75*Residuos vs Valores predichos de la Cadencia con el sistema IMU***Figura 76***Residuos vs Valores predichos de la Velocidad con el sistema IMU*

Figura 77

Residuos vs Valores predichos de la Longitud de Zancada con el sistema IMU



Para el sistema Apple Watch se analizaron por separado las características extraídas de los relojes ubicados en cada una de las muñecas de los sujetos, aquí se observó el grupo de características que mejor desempeño presentó está conformado por las características espaciales y no lineales extraídas de todas las señales del Apple Watch derecho ($R^2 = 0,793$), y el grupo de características que peor desempeño presentó está conformado por las características no lineales extraídas de las señales de velocidad angular del Apple Watch derecho ($R^2 = 0,195$).

Con respecto al sistema Apple Watch completo, compuesto por los dos relojes ubicados en cada una en las muñecas, se puede concluir que el grupo de características que mejor desempeño presentan son las correspondientes a las características espaciales extraídas de todas las señales de ambos relojes ($R^2 = 0,848$). Por el contrario, el grupo de características que peor desempeño presentó son las correspondientes a las características no lineales

extraídas de las señales de velocidad angular de ambos relojes ($R^2 = 0,336$). Los parámetros que mejor se pueden estimar con este algoritmo es la velocidad del paso y la longitud de la zancada.


Tabla 32

Mejores desempeños de las máquinas de soporte vectorial para el sistema Apple Watch

Parámetro	Característica	R^2	RMSE	MSE	MAE	Hiperparámetros
Cadencia del paso	Características Espaciales y No Lineales de todas las señales de ambos relojes	0,779	3,198	10,587	2,398	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,05 C = 100
Velocidad del paso	Características Espaciales de todas las señales de ambos relojes	0,848	0,062	0,004	0,048	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,01 C = 1
Longitud de Zancada	Características Espaciales de todas las señales de ambos relojes	0,834	0,061	0,004	0,047	Kernel = rbf Gamma = scale Degree = 1 Epsilon = 0,001 C = 1

Figura 78

Coefficiente R^2 vs Características del sistema Apple Watch



A continuación, se presentan las gráficas de Residuos vs Valores predichos para los tres parámetros de la marcha a estimar (figura 79, 80 y 81), estas figuras están conformadas por tres gráficos, el primero se encuentra ubicado a la izquierda y pertenece al estimador con el mejor desempeño, el segundo se encuentra en el centro y pertenece al estimador con el segundo mejor desempeño, y por último se encuentra el tercero a la derecha y pertenece al estimador con el peor desempeño.

Analizando la información gráfica obtenida con estas figuras se puede afirmar que estos resultados son consistentes, puesto que entre más cercanos a cero se encuentren los puntos, que representan las predicciones realizadas, más precisa es la estimación de los parámetros. Por lo tanto, se encuentra que el parámetro con mejor desempeño es la velocidad del paso.

Figura 79

Residuos vs Valores predichos de la Cadencia con el sistema Apple Watch






Figura 80

Residuos vs Valores predichos de la Velocidad con el sistema Apple Watch

**Figura 81**

Residuos vs Valores predichos de la Longitud de Zancada con el sistema Apple Watch



CAPÍTULO 5

DISCUSIÓN DE RESULTADOS

En este trabajo al estimar los parámetros espaciotemporales de la marcha propuestos en los objetivos, la cadencia del paso, la longitud de zancada y la velocidad del paso, se encontraron los siguientes resultados. La tabla 33 se reportan los mejores desempeños obtenidos para el coeficiente de determinación R^2 , para los diferentes algoritmos entrenados con el mejor conjunto de características encontrado, para cada uno de los sistemas de medición de la marcha usados. Es importante resaltar la selección de R^2 como medida de referencia, esto se debe a que está medida no es afectada en gran parte por los valores atípicos, como sucede con el MSE.

Tabla 33

Desempeños obtenidos con el coeficiente de determinación R^2 en la estimación

Algoritmo	Coeficiente de determinación R^2								
	Cadencia del paso			Velocidad del paso			Longitud de Zancada		
	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch
Regresión Lineal Simple	0,225	0,456	0,124	0,831	0,429	0,331	0,636	0,193	0,321
Regresión Lineal Múltiple	0,584	0,643	0,527	0,923	0,603	0,617	0,824	0,448	0,483
Árboles de Decisión	0,325	0,709	0,595	0,895	0,721	0,720	0,780	0,596	0,764
Bosques Aleatorios	0,688	0,801	0,739	0,937	0,849	0,822	0,879	0,782	0,801
Máquinas de Soporte Vectorial	0,846	0,866	0,779	0,955	0,868	0,848	0,935	0,824	0,834

Con respecto a los algoritmos de aprendizaje de máquina utilizados, los que mejor desempeño presentan son las máquinas de soporte vectorial (Figura 70, 74 y 78), seguidos por los bosques aleatorios (Figura 58, 62 y 66). El peor desempeño se estuvo en la regresión

lineal simple. Estos resultados reflejaron concordancia respecto a la complejidad de estos algoritmos, en este caso, entre más complejo el algoritmo mejores desempeños al estimar los parámetros espaciotemporales de la marcha. En el Anexo B se encuentran todas las tablas de desempeño obtenidas.

En relación con a los tres sistemas utilizados en la adquisición de los datos, se corroboró que el sistema GWALK es el de referencia, ya que presentaba los mejores y más consistentes desempeños en los diferentes algoritmos utilizados (Tabla 33), en especial para la estimación de la velocidad del paso. Además, al observar el desempeño de los otros dos sistemas, se encontraron mejores desempeños en las estimaciones realizadas con la información obtenida del sistema IMU (Figura 74 y Tabla 33) que en las realizadas con el sistema Apple Watch (Figura 78 y Tabla 33). Estos resultados de la estimación de parámetros espaciotemporales con las señales adquiridas por el sistema IMU, desarrollado desde cero en el grupo de investigación BISEMIC de la facultad de ingeniería eléctrica y electrónica, son prometedores y otorgan solidez a este sistema, como una herramienta de bajo costo que permite la evaluación de la marcha humana de una forma adecuada.

Luego, al examinar el rendimiento de cada uno de los dispositivos con los que se adquirieron los datos, se encontraron patrones interesantes en ellos; en el sistema IMU se encontró similitud en los desempeños obtenidos sin importar en cual pierna se encontraba ubicado el sensor (Figura 38, 50, 62 y 74); estos resultados contrastaron con los desempeños obtenidos con el sistema Apple Watch, el cual dependía de en qué muñeca se encontraba ubicado el reloj (Figura 42, 54, 66 y 78), a partir de esta situación puede surgir

la inquietud sí la ubicación del reloj sobre la mano dominante afecta el registro de la marcha.

Por otra parte, en los grupos de características utilizados en la estimación de los parámetros de la marcha (Tabla 6), se encontró que en mayor parte las características espaciales extraídas de las señales de los diferentes sistemas son las de mejor desempeño (Anexo B), esto podría estar influenciado por la cantidad de características (7) que tienen con respecto a las características no lineales (4). Además, la magnitud física que mejor desempeño presenta es la aceleración lineal adquirida con el GWALK; por el contrario, la velocidad angular presenta una reducción en el desempeño, que puede estar asociada a la sensibilidad seleccionada en el giroscopio al momento de configurar el GWALK, esta fue ± 2000 °/s, siendo un factor importante en la precisión de la información registrada.

En cuanto a los parámetros de la marcha que se estimaron, el de mejor desempeño fue la velocidad del paso (Tabla 33), esto debido a la precisión de las medidas obtenidas por el sistema GWALK (Tabla 34), siendo este el sistema de referencia y el que entregaba las medidas de los parámetros a estimar, las cuales fueron las que presentaron menor desviación estándar; esto contrasta con la cadencia del paso, que presentó una mayor desviación estándar en la medición de este parámetro y lo hace el de peor desempeño. Estos resultados se corroboraron luego de analizar las gráficas de Residuos vs Valores predichos de la velocidad del paso con los diferentes algoritmos y sistemas de medición de marcha (Figura 48, 52, 56, 60, 64, 68, 72, 76 y 80), donde se encuentra que para los estimadores de mejor desempeño los valores predichos están más cerca de la línea horizontal ubicada en cero, es decir, menos dispersos; por el contrario, la cadencia del paso presenta valores

atípicos o outliers, afectando el desempeño de los estimadores desarrollados, el cual ha presenta un sesgo en un valor específico.

Tabla 34

Precisión encontrada en la medición del GWALK

Parámetro	Valor Promedio	Desviación Estándar	Porcentaje de Error
Cadencia del Paso	105,581	3,841	3,658%
Velocidad del Paso	1,113	0,063	5,703%
Longitud de Zancada	1,265	0,058	4,615%

También, al analizar todas las gráficas de Residuos vs Valores predichos se encontró que la mayoría de las predicciones realizadas se encuentran distribuidas homogéneamente, esto implica que la varianza corresponde a una variabilidad común en los datos que se están utilizando; además, se encontró que el algoritmo de árboles de decisión de peor desempeño presenta tendencias muy marcadas, observando predicciones sesgadas, ya que los valores predichos se acumulan en un solo valor, contrastando con los mejores desempeños, donde las predicciones se encuentran distribuidos más homogéneamente en la gráfica, con una varianza constante.

Respecto a las otras medidas propuestas para evaluar el desempeño de la estimación de los parámetros se encontró que a mayor valor del coeficiente R^2 había un menor valor en los errores RMSE, MSE y MAE (Tabla 33, Tabla 35, Tabla 36 y Tabla 37), esto indica que los resultados obtenidos por los estimadores presentan consistencia, ya que a valores más

cercanos a cero en los errores se presenta un mejor ajuste en el modelo, por lo tanto, la precisión con que el modelo realiza la estimación de los parámetros es mejor.

En las tablas presentadas a continuación se encuentran los desempeños obtenidos con las diferentes medidas. Estas fueron calculadas para tener mayor claridad del desempeño de los estimadores desde diferentes perspectivas, diferentes cuantificaciones. En el caso de la MAE, un detalle importante de esta métrica es que penaliza errores enormes mejor que el MSE. Por lo tanto, no es tan sensible a los valores atípicos como el error cuadrático medio. Además, el R^2 y el RMSE son las medidas que mejor interacción tienen al observar el desempeño de los estimadores y la calidad de las predicciones realizadas.

En general se encuentra que los errores más grandes se presentan en la cadencia del paso, parámetro con la mayor desviación estándar en las mediciones realizadas y con las predicciones más dispersas. También se infiere que a mayor cantidad de valores atípicos se presentan errores más grandes, por ende, menor desempeño, esto es visible en la disminución del desempeño a menor complejidad del algoritmo para desarrollar el estimador.

Tabla 35*Desempeños obtenidos con la raíz del error cuadrático medio en la estimación*

Algoritmo	Raíz del error cuadrático medio (RMSE)								
	Cadencia del paso			Velocidad del paso			Longitud de Zancada		
	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch
Regresión Lineal Simple	5,996	4,937	6,422	0,067	0,124	0,136	0,093	0,140	0,128
Regresión Lineal Múltiple	4,191	3,887	4,677	0,046	0,105	0,101	0,063	0,114	0,111
Árboles de Decisión	5,104	3,671	4,207	0,052	0,087	0,086	0,067	0,092	0,074
Bosques Aleatorios	3,621	3,001	3,544	0,040	0,063	0,069	0,052	0,070	0,069
Máquinas de Soporte Vectorial	2,573	2,446	3,198	0,034	0,060	0,062	0,038	0,063	0,061

Tabla 36*Desempeños obtenidos con el error cuadrático medio en la estimación*

Algoritmo	Error cuadrático medio (MSE)								
	Cadencia del paso			Velocidad del paso			Longitud de Zancada		
	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch
Regresión Lineal Simple	36,541	24,798	43,072	0,005	0,016	0,019	0,009	0,020	0,017
Regresión Lineal Múltiple	17,943	15,639	22,300	0,002	0,011	0,010	0,004	0,014	0,013
Árboles de Decisión	27,254	14,503	19,719	0,003	0,008	0,008	0,005	0,009	0,006
Bosques Aleatorios	13,629	9,457	13,203	0,002	0,004	0,005	0,003	0,006	0,005
Máquinas de Soporte Vectorial	6,962	6,101	10,587	0,001	0,004	0,004	0,002	0,004	0,004

Tabla 37*Desempeños obtenidos con el error absoluto medio en la estimación*

Algoritmo	Error absoluto medio (MAE)								
	Cadencia del paso			Velocidad del paso			Longitud de Zancada		
	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch	GWALK	IMU	Apple Watch
Regresión Lineal Simple	5,042	3,909	5,045	0,055	0,094	0,112	0,077	0,115	0,101
Regresión Lineal Múltiple	3,260	3,023	3,738	0,039	0,085	0,080	0,049	0,091	0,085
Árboles de Decisión	3,732	2,418	2,865	0,039	0,067	0,059	0,048	0,062	0,054
Bosques Aleatorios	2,726	2,250	2,645	0,031	0,047	0,052	0,039	0,051	0,050
Máquinas de Soporte Vectorial	1,934	1,854	2,398	0,027	0,045	0,048	0,029	0,047	0,047

También es importante resaltar el tiempo de procesamiento empleado para la optimización de los hiperparámetros propuestos (Tabla 11), esto consumió un tiempo total de 1.577 minutos, estas son aproximadamente 26 horas (Tabla 38). La única forma de disminuir estos tiempos fue empleando un equipo con mejor procesador (CPU), el cual tiene 3 veces más la cantidad de hilos y núcleos, puesto que no se utilizaba la memoria RAM y la GPU para este procedimiento. Se pasó de un equipo con un CPU Intel Core i3 6100 @ 3.70 GHz de 2 núcleos y 4 hilos, a un equipo con un CPU Ryzen 5 3600 @ 3.60 GHz de 6 núcleos y 12 hilos. En trabajos futuros pueden implementarse diversas formas de disminuir estos tiempos, ya sea con cambios en la estructura del código, en las librerías o equipos a utilizar, en realizar el procesamiento en la GPU, también existe la posibilidad de realizar la optimización en máquinas virtuales alojadas en servicios en la nube tales como Vast.ai, Azure, Google Colab, Paper Space, entre otros.

Tabla 38

Tiempos para la optimización de hiperparámetros

Algoritmo	Minutos																																				
	GWALK						Sistema IMU			Sensor IMU izquierdo			Sensor IMU derecho			Sistema Apple Watch						Apple Watch izquierdo			Apple Watch derecho												
Árboles de decisión	22	15	14	18	11	10	13	25	16	13	14	14	10	14	11	9	43	16	16	28	16	15	20	25	14	12	16	9	9	14	25	11	12	18	9	13	14
Bosques aleatorios	27	14	14	20	12	12	15	27	20	16	18	15	11	17	13	12	47	20	20	30	15	15	21	27	14	14	20	12	12	16	29	14	14	20	12	12	16
Máquinas de soporte vectorial	23	5	3	9	4	3	7	16	6	5	6	3	3	6	3	3	74	7	7	22	5	5	15	19	4	3	7	4	3	5	19	4	3	7	4	3	5

Finalmente, es importante resaltar que en la evaluación y el análisis de la marcha se han realizado más investigaciones para clasificación y detección que para estimación, por lo tanto, es un campo de investigación que tiene mucho por explorar. Esto se evidencia especialmente en la cantidad de autores que han realizado estimación de parámetros espaciotemporales de la marcha, específicamente la velocidad del paso y la longitud de

zancada, de los cuales se encontraron pocas investigaciones al respecto. Al contrastar los resultados obtenidos con otros trabajos realizados sobre la estimación de parámetros espaciotemporales de la marcha (Stansfield, B. W. et Al, 2006; Dixon, P. C. et Al, 2014; Wahid, F. et Al, 2016; Jena, S. et Al, 2017; Mikos, V. et Al, 2018; Braga, J. et Al, 2020) se lograron mejores desempeños (Tabla 39), cabe resaltar que ninguno de los trabajos fue realizado con técnicas de aprendizaje de máquina, como máquinas de soporte vectorial o bosques aleatorios, y usaron diferentes sistemas para la medición de la marcha humana con respecto a esta investigación. Desde la perspectiva de la regresión lineal simple y la regresión lineal múltiple, los autores obtuvieron mejores desempeños para la estimación de la cadencia del paso, sin embargo, empleando técnicas de aprendizaje automático, como las máquinas de soporte vectorial, se encontraron los mejores resultados. En particular se destaca el desempeño obtenido por el sistema IMU, este proporciona un desempeño mayor con respecto a la estimación de la cadencia del paso, siendo un dispositivo de bajo costo desarrollado en la universidad.

Tabla 39

Comparación de resultados obtenidos con otros autores

Autor(es)	Año	Método	Sistema	Coeficiente de determinación R^2		
				Cadencia del paso	Velocidad del paso	Longitud de Zancada
Stansfield, B. W. et Al	2006	Regresión lineal	Plataformas de fuerza Kistler, Vicon Nexus	0,531	-	-
Dixon, P. C. et Al	2014	Regresión lineal	Vicon Nexus	0,817	0,105	-
Wahid, F et Al	2016	Regresión múltiple	GaitRite, Vicon Nexus, Lake Forrest	0,760	-	-
Jena, S. et Al	2017	Regresión lineal	Plataformas de fuerza Kistler	0,740	-	-
Mikos, V. et Al	2018	Regresión múltiple	Diseño propio	0,763	-	-
Braga, J. et Al	2020	Regresión múltiple	Physilog	0,697	-	-
Otero, M.	2020	Aprendizaje de máquina	GWALK	0,846	0,955	0,935
			Sistema IMU UPB	0,866	0,868	0,824
			Sistema Apple Watch UPB	0,779	0,848	0,834

CAPÍTULO 6

CONCLUSIONES Y RECOMENDACIONES

A continuación, se presentan las conclusiones del trabajo realizado, haciendo énfasis especial en el cumplimiento detallado de los objetivos y en el impacto de este trabajo. El objetivo general de este trabajo era estimar la cadencia, la longitud de zancada y la velocidad del ciclo de marcha basado en técnicas de aprendizaje de máquina usando señales adquiridas a partir de diferentes dispositivos. Esto se logró utilizando una base de datos conformada por señales inerciales (acelerómetros y giroscopios) con diferentes sistemas para evaluar la marcha humana, creada en la Universidad Pontificia Bolivariana seccional Bucaramanga. De esta base de datos se extrajeron características con las que se implementaron diversos algoritmos de aprendizaje de máquina para estimar diferentes parámetros de marcha (Tabla 33).

El mejor estimador para la velocidad del paso fue desarrollado con el algoritmo de máquinas de soporte vectorial, configurando los hiperparámetros de la siguiente forma: Kernel = rbf, Gamma = auto, Degree = 1, Epsilon = 0,0001 y C = 1, utilizando las características espaciales y no lineales de todas las señales obtenidas de aceleración lineal y velocidad angular del GWALK. Los desempeños obtenidos fueron $R^2 = 0,955$, RMSE = 0,034, MSE = 0,001 y MAE = 0,027.

Y el mejor estimador para la longitud de zancada fue desarrollado con el algoritmo de máquinas de soporte vectorial, configurando los hiperparámetros de la siguiente forma: Kernel = rbf, Gamma = scale, Degree = 1, Epsilon = 0,01 y C = 1, utilizando las características espaciales de todas las señales obtenidas de aceleración lineal y velocidad angular del GWALK. Los desempeños obtenidos fueron $R^2 = 0,935$, RMSE = 0,038, MSE = 0,002 y MAE = 0,029.

Para la cadencia del paso, el mejor estimador fue desarrollado con el algoritmo de máquinas de soporte vectorial, configurando los hiperparámetros de la siguiente forma: Kernel = rbf, Gamma = scale, Degree = 1, Epsilon = 1 y C = 100, utilizando las características espaciales de todas las señales obtenidas de velocidad angular de ambos sensores del sistema IMU. Los desempeños obtenidos fueron $R^2 = 0,866$, RMSE = 2,446, MSE = 6,101 y MAE = 1,854. Adicionalmente, se destacan los resultados obtenidos en la estimación de la velocidad del paso con este mismo algoritmo, configurando los hiperparámetros de la siguiente forma: Kernel = rbf, Gamma = scale, Degree = 1, Epsilon = 0,01 y C = 1, utilizando las características espaciales y no lineales de todas las señales obtenidas de velocidad angular del sensor izquierdo del sistema IMU. Los desempeños obtenidos fueron $R^2 = 0,868$, RMSE = 0,060, MSE = 0,004 y MAE = 0,045; y los resultados obtenidos en la estimación de la longitud de zancada con este mismo algoritmo, configurando los hiperparámetros de la siguiente forma: Kernel = rbf, Gamma = scale, Degree = 1, Epsilon = 0,01 y C = 1, utilizando las características espaciales y no lineales de todas las señales obtenidas de velocidad angular del sensor izquierdo del sistema

IMU. Los desempeños obtenidos fueron $R^2 = 0,824$, $RMSE = 0,063$, $MSE = 0,004$ y $MAE = 0,047$.

El análisis de las señales inerciales y su posterior caracterización permitió obtener información importante que se encuentra implícita en las señales y que a simple vista es imposible de observar. Un hallazgo que se puede destacar es que las señales de aceleración lineal y las características espaciales de las señales son las que mejor desempeño presentan en la estimación de los parámetros espaciotemporales de la marcha. Por lo tanto, obtener características relevantes de las señales inerciales adquiridas es también una contribución importante de este trabajo, puesto que, al implementarse algoritmos de aprendizaje de máquina supervisado, la selección de características es una labor tediosa y fundamental, muy necesaria para obtener buenos desempeños.

Además, la implementación de varios algoritmos de aprendizaje de máquina supervisado permitió obtener diferentes desempeños y encontrar que a mayor complejidad del algoritmo se lograban mejores resultados (Anexo B). Siguiendo esta lógica se abre la ruta para desarrollar trabajos futuros con algoritmos más robustos, como lo son las redes neuronales o implementar aprendizaje profundo, también el extraer diferentes características de las señales y el uso de diferentes técnicas de selección de las mismas, esto abre una posibilidad a obtener mejores desempeños en la estimación de parámetros espaciotemporales de la marcha. Esto puede llevarse a cabo con los equipos disponibles en la facultad de ingeniería eléctrica y electrónica de la UPB, los cuales tienen las características para desarrollar actividades que tengan un costo computacional alto, disminuyendo así los tiempos de procesamientos requeridos para la investigación.

De acuerdo a los resultados obtenidos y el análisis realizado se puede concluir que los sistemas para analizar la marcha humana entregan información apta que permite estimar de buena forma los parámetros de la marcha. Es importante resaltar que el sistema IMU, desarrollado en el grupo BISEMIC, presenta mejores desempeños (Tabla 33), basados en el coeficiente de determinación R^2 , al utilizar los algoritmos más robustos, como los bosques aleatorios y máquinas de soporte vectorial, para realizar la estimación de parámetros, esto lo ratifica como una herramienta apta para hacer una evaluación de la marcha humana. Para mejorar los desempeños de la estimación y la evaluación realizada por parte del sistema IMU podrían incluirse acelerómetros a este dispositivo, ya que este sensor ofrece señal de aceleración lineal, esta fue la magnitud física que más relevancia tuvo en los grupos de las características extraídas de las señales de los diferentes sistemas utilizados para la adquisición de la base de datos.

Sobre la ubicación de los diferentes sistemas utilizados, los desempeños se ven afectados (Figura 13). Esto es debido a que movimientos bruscos en el transcurso del experimento pueden afectar la medición realizada. En particular, en el sistema Apple Watch, ubicado en ambas muñecas, se encontraron los peores desempeños, esto podría ser causado por su ubicación y la facilidad de realizar diversos movimientos con las manos durante la marcha humana, a mayor libertad para realizar movimientos existe más posibilidades de afectar el registro del ciclo de marcha, por ende, obtener señales con alteraciones. Por el contrario, el sistema GWALK y el sistema IMU, ubicados en la espalda baja y en ambos tobillos respectivamente, son menos propensos a movimientos voluntarios

del sujeto que afecten el registro de la marcha, por lo tanto, se encontraron mejores resultados en la estimación de parámetros con estas señales.

Es importante resaltar que este proyecto deja al grupo de investigación en Bioingeniería, Señales y Microelectrónica (BISEMIC) la organización, el análisis, el preprocesamiento y la adecuación realizada a la base de datos creada en este mismo grupo, puesto que está fue recibida sin procesamiento alguno. Esto servirá en el desarrollo de trabajos futuros, como el que viene realizando el estudiante de maestría Humberto Jose Navarro Nigrinis para desarrollar su trabajo de grado, el cual consiste en la identificación y detección de eventos de la marcha humana, ratificando el aporte y el trabajo que se ha realizado en este grupo de investigación de la Universidad Pontificia Bolivariana seccional Bucaramanga, del cual hago parte hace más de 3 años.

También abre las puertas a futuras investigaciones relacionadas con la marcha humana y el aprendizaje de máquina, especialmente con la estimación de parámetros espaciotemporales, siendo este campo poco explorado, lo que ayudaría a fortalecer las líneas de investigación del grupo de investigación de Bioingeniería, Señales y Microelectrónica (BISEMIC).

Finalmente, una recomendación importante es acerca de la base de datos y su creación, la cual consiste en crear un protocolo estricto para la adquisición de las señales que van a conformar la base de datos, el cual va a permitir que se obtenga información con más calidad y pueda trabajarse con ella de una forma más eficiente. Esto se debe a que durante la evaluación y el procesamiento de las señales de la base de datos se observó como el

orden de encendido de los diferentes dispositivos afectaba directamente el proceso de sincronización de las señales. También se observó que las señales obtenidas por los relojes Apple Watch son las más susceptibles a presentar ruidos, esto se debe a la ubicación de los relojes en las muñecas, las cuales pueden moverse de una forma diferente al movimiento natural que presentan en la marcha humana en un estado normal; diferente a lo acontecido con las señales adquiridas con los sensores IMU y el dispositivo GWALK, que se encontraban en los tobillos y la parte baja de la espalda, zonas del cuerpo rígidas y con movimientos muy marcados.

LISTA DE REFERENCIAS

- Agudelo, A. I., Briñez, T. J., Guarín, V., Ruiz, J. P., & Zapata, M. (2013). Marcha: descripción, métodos, herramientas de evaluación y parámetros de normalidad reportados en la literatura. *CES Movimiento y Salud*, 1(1), 29-43.
- Alpaydin, E. (2016). *Machine Learning: The New AI*. The MIT Press.
- Araújo, P. A., Kirkwood, R. N., & Figueiredo, E. M. (2009). Validity and intra-and inter-rater reliability of the Observational Gait Scale for children with spastic cerebral palsy. *Rev Bras Fisioter*, 13(3), 267-73.
- Arellano-González, J. C., Medellín-Castillo, H. I., & Cervantes-Sánchez, J. J. (2019). Identificación y análisis de los parámetros biomecánicos utilizados para la evaluación de la marcha humana normal y patológica. *XXV CONGRESO INTERNACIONAL ANUAL DE LA SOMIM*
- Barnston, A. G. (1992). Correspondence among the correlation, RMSE, and Heidke forecast verification measures; refinement of the Heidke score. *Weather and Forecasting*, 7(4), 699-709.
- Begg, R., & Kamruzzaman, J. (2005). A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data. *Journal of biomechanics*, 38(3), 401-408.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.

- Bensoussan, L., Viton, J. M., Barotsis, N., & Delarque, A. (2008). Evaluation of patients with gait abnormalities in physical and rehabilitation medicine settings. *Journal of rehabilitation medicine*, 40(7), 497-507.
- Botchkarev, A. (2018). Performance metrics (error measures) in machine learning regression, forecasting and prognostics: Properties and typology. arXiv preprint arXiv:1809.03006.
- Braga, J., Ferreira, F., Fernandes, C., Gago, M. F., Azevedo, O., Sousa, N., ... & Bicho, E. (2020, July). Gait Characteristics and Their Discriminative Ability in Patients with Fabry Disease with and Without White-Matter Lesions. In *International Conference on Computational Science and Its Applications* (pp. 415-428). Springer, Cham.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Bronzino, J. D., & Peterson, D. R. (2014). *Biomedical engineering fundamentals*. CRC press.
- BTS Bioengineering. (2017). G-WALK. Obtenido de BTS Bioengineering: <https://www.btsbioengineering.com/es/products/g-walk-inertial-motion-system/>
- Caliandro, P., Conte, C., Iacovelli, C., Tatarelli, A., Castiglia, S. F., Reale, G., & Serrao, M. (2019). Exploring risk of falls and dynamic unbalance in cerebellar ataxia by inertial sensor assessment. *Sensors*, 19(24), 5571.
- Cámara, J. (2011). Análisis de la marcha: sus fases y variables espacio-temporales. *Entramado*, 7(1), 160-173.

- Camargo, E., Garzón, Y., & Camacho, V. A. (2012). Sistema portátil de captura de movimiento para el análisis cinemático de la marcha humana. *Tecnura*, 16(34), 67-83.
- Cameron, A. C., & Windmeijer, F. A. (1997). An R-squared measure of goodness of fit for some common nonlinear regression models. *Journal of econometrics*, 77(2), 329-342.
- Carrillo, F. M., Jaramillo, F. G., & Castro, E. R. (2010). Desarrollo de un laboratorio de marcha con integración sincrónica mediante una arquitectura en módulos. *Acta biológica colombiana*, 15(3), 235-250.
- Castro Medina, K. G., & Santisteban Pertuz, S. C. (2019). Efecto del Feedback visual sobre la recuperación de la marcha en personas con enfermedad cerebrovascular.
- Choi, T. S., Ryu, B. H., & Lee, S. B. (2020). Effects of Cervical Mobilization and Craniocervical Flexion Exercise on the Dynamic Balance and Gait Variability in Chronic Neck Pain Patients: Randomized Controlled Trial. *Korean Society of Physical Medicine*, 15(2), 31-38.
- Chumanov, E. S., Remy, C. D., & Thelen, D. G. (2010). Computational techniques for using insole pressure sensors to analyse three-dimensional joint kinetics. *Computer methods in biomechanics and biomedical engineering*, 13(5), 505-514.
- Ciaburro, G. (2017). *MATLAB for Machine Learning*. Packt Publishing.

- Collado Vázquez, S. (2004). Análisis de la marcha humana con plataformas dinamométricas: influencia del transporte de carga (Doctoral dissertation, Universidad Complutense de Madrid, Servicio de Publicaciones).
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- Daza Lesmes, J. (2007). Capítulo 11: Examen de la marcha. *Evaluación clínico funcional del movimiento corporal*. Editorial Panamericana, 252-303.
- Demir, Y., & Yildirim, S. (2019). Different walk aids on gait parameters and kinematic analysis of the pelvis in patients with Adult Neuromuscular Disease. *Neurosciences*, 24(1), 36-44.
- Devijver, P. A., & Kittler, J. (1982). *Pattern recognition: A statistical approach*. Prentice hall.
- Dixon, P. C., Bowtell, M. V., & Stebbins, J. (2014). The use of regression and normalisation for the comparison of spatio-temporal gait data in children. *Gait & posture*, 40(4), 521-525.
- Eskofier, B. M., Federolf, P., Kugler, P. F., & Nigg, B. M. (2013). Marker-based classification of young–elderly gait pattern differences via direct PCA feature extraction and SVMs. *Computer methods in biomechanics and biomedical engineering*, 16(4), 435-442.
- GAITRite. (2000). GAITRite. Obtenido de GAITRite: <https://www.gaitrite.com/>

- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation* [Online]. 101 (23), pp. e215–e220.
- Hak, L., Houdijk, H., van der Wurff, P., Prins, M. R., Beek, M. J., & van Dieen, J. H. (2015). Stride frequency and length adjustment in post-stroke individuals: influence on the margins of stability. *Journal of rehabilitation medicine*, 47(2), 126-132.
- Handelman, G. S., Kok, H. K., Chandra, R. V., Razavi, A. H., Huang, S., Brooks, M., ... & Asadi, H. (2019). Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods. *American Journal of Roentgenology*, 212(1), 38-43.
- Hernández, F. (2008). Diseño y construcción de prototipo neumático de prótesis de pierna humana.
- Hincapié, S., & Suárez, D. I. M. (2010). Acercamiento a un diagnóstico fisioterapéutico: análisis de la marcha. *Revista Facultad Ciencias de la Salud: Universidad del Cauca*, 12(4), 40-44.
- Horst, F., Lapuschkin, S., Samek, W., Müller, K. R., & Schöllhorn, W. I. (2019). Explaining the unique nature of individual gait patterns with deep learning. *Scientific reports*, 9(1), 1-13.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.

- Isaacson, B. M., Swanson, T. M., & Pasquina, P. F. (2013). The use of a computer-assisted rehabilitation environment (CAREN) for enhancing wounded warrior rehabilitation regimens. *The journal of spinal cord medicine*, 36(4), 296-299.
- Jena, S., Sakhare, G. M., Panda, S. K., & Thirugnanam, A. (2017). Evaluation and prediction of human gait parameters using univariate, multivariate and stepwise statistical methods. *Journal of Mechanics in Medicine and Biology*, 17(05), 1750076.
- Joyseeree, R., Abou, R. S., & Müller, H. (2015). Applying machine learning to gait analysis data for disease identification. *Studies in health technology and informatics*, 210, 850-854.
- Kim, H. Y., Kim, K. J., Yang, D. S., Jeung, S. W., Choi, H. G., & Choy, W. S. (2015). Screw-home movement of the tibiofemoral joint during normal gait: three-dimensional analysis. *Clinics in orthopedic surgery*, 7(3), 303-309.
- Kim, M. K., & Lee, Y. S. (2013). Kinematic analysis of the lower extremities of subjects with flat feet at different gait speeds. *Journal of physical therapy science*, 25(5), 531-533.
- KISTLER. (2015). KISTLER. Obtenido de KISTLER: <https://www.kistler.com/es/>
- Lake, D. E., Richman, J. S., Griffin, M. P., & Moorman, J. R. (2002). Sample entropy analysis of neonatal heart rate variability. *American Journal of Physiology-Regulatory, Integrative and Comparative Physiology*, 283(3), R789-R797.
- Lehmann, E. L., & Casella, G. (2006). *Theory of point estimation*. Springer Science & Business Media.

- Loh, W. Y. (2011). Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 14-23.
- Martín, D. M. R. (2014). Contribución al análisis del movimiento humano aplicado a la identificación de posturas y bloqueos de la marcha en pacientes con Parkinson (Doctoral dissertation, Universitat Politècnica de Catalunya (UPC)).
- Mikos, V., Yen, S. C., Tay, A., Heng, C. H., Chung, C. L. H., Liew, S. H. X., ... & Au, W. L. (2018). Regression analysis of gait parameters and mobility measures in a healthy cohort for subject-specific normative values. *PloS one*, 13(6), e0199215.
- Mock, M., & Sweeting, K. (2007). Gait and posture - assessment in general practice (Vol. 36). *Australian Family Physician*.
- Moliner, Luis M. (2003), Presentación de datos estadísticos en medicina. Asociación de la Sociedad Española de Hipertensión
- Muniz, A. M. S., Liu, H., Lyons, K. E., Pahwa, R., Liu, W., Nobre, F. F., & Nadal, J. (2010). Comparison among probabilistic neural network, support vector machine and logistic regression for evaluating the effect of subthalamic stimulation in Parkinson disease on ground reaction force during gait. *Journal of biomechanics*, 43(4), 720-726.
- Murdoch, W. J., Singh, C., Kumbier, K., Abbasi-Asl, R., & Yu, B. (2019). Definitions, methods, and applications in interpretable machine learning. *Proceedings of the National Academy of Sciences*, 116(44), 22071-22080.
- NORAXON. (2017). myoResearch Software Platform. Obtenido de NORAXON: <https://www.noraxon.com/our-products/>

- Öberg, T., Karsznia, A., & Öberg, K. (1993). Basic gait parameters: reference data for normal subjects, 10-79 years of age. *Journal of rehabilitation research and development*, 30, 210-210.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Vanderplas, J. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- Pietraszewski, B., Winiarski, S., & Jaroszczuk, S. (2012). Threedimensional human gait pattern—reference data for normal men. *Acta of Bioengineering and Biomechanics*, 14(3), 9-16.
- Plas F, Viel E, Blanc Y. (1996). *La marcha humana*. Barcelona: Masson.
- Rábago, C. A., Dingwell, J. B., & Wilken, J. M. (2015). Reliability and minimum detectable change of temporal-spatial, kinematic, and dynamic stability measures during perturbed gait. *PloS one*, 10(11).
- Rampp, A., Barth, J., Schülein, S., Gaßmann, K. G., Klucken, J., & Eskofier, B. M. (2014). Inertial sensor-based stride parameter calculation from gait sequences in geriatric patients. *IEEE transactions on biomedical engineering*, 62(4), 1089-1097.
- Raschka, S. (2015). *Python Machine Learning*. Packt Publishing.
- Ridao Fernández, M. D. C. (2019). Valoración de la marcha asistida con bastones de antebrazo: diseño de métodos observacional y tecnológico. Análisis innovador de parámetros espaciotemporales del paso.

- Rustom, A. (2012). Estadística descriptiva, probabilidad e inferencia. Santiago: Departamento de Economía Agraria, Facultad de Ciencias Agronómicas, Universidad de Chile.
- Sánchez-Lacuesta JJ, Prat-Pastor JM (1999). Biomecánica de la marcha humana normal y patológica. Valencia: Instituto de Biomecánica de Valencia.
- Sanz, C. (2006). Cinesiología de la marcha humana normal. Links, 1-14.
- Shannon, C. E., (1948). A mathematical theory of communication. The Bell system technical journal, 27(3), 379-423.
- Slout, L. H., Van der Krogt, M. M., & Harlaar, J. (2014). Effects of adding a virtual reality environment to different modes of treadmill walking. Gait & posture, 39(3), 939-945.
- Thomas, M., Jankovic, J., Suteerawattananon, M., Wankadia, S., Caroline, K. S., Vuong, K. D., & Protas, E. (2004). Clinical gait and balance scale (GABS): validation and utilization. Journal of the neurological sciences, 217(1), 89-99.
- Van Gerven, M., & Bohte, S. (2017). Artificial neural networks as models of neural information processing. Frontiers in Computational Neuroscience, 11, 114.
- Van Iersel, M. B., Haitsma, A., Olde Rikkert, M. G., & Benraad, C. E. (2005). Quantitative gait analysis to detect gait disorders in geriatric patients with depression. J Am Geriatr Soc, 53(8), 1441-2.
- Vargas, L. (2017) Sistema para la medición de parámetros de tiempo de la marcha humana. Universidad Pontificia Bolivariana-Seccional Bucaramanga.

- Vera, P. (1999). Biomecánica de la marcha humana normal y patológica. Instituto de Biomecánica de Valencia. Cap, 2.
- VICON. (2018). VICON. Obtenido de VICON: <https://www.vicon.com/>
- Villa Moreno, A., Gutiérrez, E., & Pérez Moreno, J. C. (2008). Consideraciones para el análisis de la marcha humana. Técnicas de videogrametría, electromiografía y dinamometría. *Revista ingeniería biomédica*, 2(3), 16-26.
- Vismara, L., Romei, M., Galli, M., Montesano, A., Baccalaro, G., Crivellini, M., & Grugni, G. (2007). Clinical implications of gait analysis in the rehabilitation of adult patients with " Prader-Willi" Syndrome: a cross-sectional comparative study (" Prader-Willi" Syndrome vs matched obese patients and healthy subjects). *Journal of neuroengineering and rehabilitation*, 4(1), 14.
- Wackerly, D., Mendenhall, W., & Scheaffer, R. L. (2014). *Mathematical statistics with applications*. Cengage Learning.
- Wahid, F., Begg, R. K., Hass, C. J., Halgamuge, S., & Ackland, D. C. (2015). Classification of Parkinson's disease gait using spatial-temporal gait features. *IEEE journal of biomedical and health informatics*, 19(6), 1794-1802.
- Wang, K., Lovell, N. H., Del Rosario, M. B., Liu, Y., Wang, J., Narayanan, M. R., ... & Redmond, S. J. (2014, August). Inertial measurements of free-living activities: Assessing mobility to predict falls. In 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (pp. 6892-6895). IEEE.

- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate research*, 30(1), 79-82.
- Wiszomirska, I., Błażkiewicz, M., Kaczmarczyk, K., Brzuszkiewicz-Kuźmicka, G., & Wit, A. (2017). Effect of drop foot on spatiotemporal, kinematic, and kinetic parameters during gait. *Applied bionics and biomechanics*, 2017.
- Zamorano Calvo, J. (2011). *Estadística básica para estudiantes de ciencias*. Universidad Complutense de Madrid.
- Zhuang, Y., Gong, J., Kerrigan, D. C., Bennett, B. C., Lach, J., & Russell, S. (2016, June). Gait tracker shoe for accurate step-by-step determination of gait parameters. In *2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN)* (pp. 13-18). IEEE.
- Stansfield, B. W., Hillman, S. J., Hazlewood, M. E., & Robb, J. E. (2006). Regression analysis of gait parameters with speed in normal children walking at self-selected speeds. *Gait & posture*, 23(3), 288-294.
- Wahid, F., Begg, R., Lythgo, N., Hass, C. J., Halgamuge, S., & Ackland, D. C. (2016). A multiple regression approach to normalization of spatiotemporal gait features. *Journal of applied biomechanics*, 32(2), 128-139.
- Zipp, D., Simpkins, G. P., and Stiskal, S., 2004, "Researchers Explore Functional Implications of Multitask Activities," *Biomech.*, 11, pp. 55–59.

BIBLIOGRAFÍA

- Abdulhay, E., Arunkumar, N., Narasimhan, K., Vellaiappan, E., & Venkatraman, V. (2018). Gait and tremor investigation using machine learning techniques for the diagnosis of Parkinson disease. *Future Generation Computer Systems*, 83, 366-373.
- Aicha, A. N., Englebienne, G., & Kröse, B. (2015, November). Continuous gait velocity analysis using ambient sensors in a smart home. In *European Conference on Ambient Intelligence* (pp. 219-235). Springer, Cham.
- Al-Amri, M., Davies, J., Adamson, P., Button, K., Roos, P., & Van Deursen, R. W. M. (2016). Augmented feedback approach to double-leg squat training for patients with knee osteoarthritis: a preliminary study.
- Albán, O. A. V., Chacón, D. C. V., Guzmán, K. J. Q., & Bonett, V. D. (2020). Estimación de la cinemática de las articulaciones de miembro inferior por medio del filtro de Kalman extendido. *INGE CUC*, 16(1).
- APDM. (2020). RESEARCH-GRADE WEARABLE SENSORS. Obtenido de APDM wearable technologies: <http://www.apdm.com/wearable-sensors>
- Boardman, M., & Trappenberg, T. (2006, July). A heuristic for free parameter optimization with support vector machines. In *The 2006 IEEE International Joint Conference on Neural Network Proceedings* (pp. 610-617). IEEE.
- Catal, C. (2012). Performance evaluation metrics for software fault prediction studies. *Acta Polytechnica Hungarica*, 9(4), 193-206.

- Chang, C. C., & Lin, C. J. (2011). LIBSVM: A library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3), 1-27.
- Chapelle, O., Vapnik, V., Bousquet, O., & Mukherjee, S. (2002). Choosing multiple parameters for support vector machines. *Machine learning*, 46(1-3), 131-159.
- Cherkassky, V., & Ma, Y. (2003). Comparison of model selection for regression. *Neural computation*, 15(7), 1691-1714.
- Cherkassky, V., & Ma, Y. (2004). Practical selection of SVM parameters and noise estimation for SVM regression. *Neural networks*, 17(1), 113-126.
- Christmann, A., & Steinwart, I. (2008). *Support vector machines*.
- Cook, R. E., Schneider, I., Hazlewood, M. E., Hillman, S. J., & Robb, J. E. (2003). Gait analysis alters decision-making in cerebral palsy. *Journal of pediatric orthopaedics*, 23(3), 292-295.
- Debnath, R., & Takahashi, H. (2004, October). An efficient method for tuning kernel parameter of the support vector machine. In *IEEE International Symposium on Communications and Information Technology, 2004. ISCIT 2004*. (Vol. 2, pp. 1023-1028). IEEE.
- Duan, K., Keerthi, S. S., & Poo, A. N. (2003). Evaluation of simple performance measures for tuning SVM hyperparameters. *Neurocomputing*, 51, 41-59.
- G. Keppel. (2004). *Design and analysis: a researcher's handbook*, 4. ed. Upper Saddle River, N.J.: Prentice Hall.
- Gareth, J., Daniela, W., Trevor, H., & Robert, T. (2013). *An introduction to statistical learning: with applications in R*. Springer.

- Hocoma. (2017). Relearning to Walk From the Beginning. Obtenido de Hokoma:
<https://www.hocoma.com/solutions/lokomat/>
- Hyung, E. J., Lee, H. O., & Kwon, Y. J. (2016). Influence of load and carrying method on gait, specifically pelvic movement. *Journal of physical therapy science*, 28(7), 2059-2062.
- Kenney, J. F. (1939). *Mathematics of statistics*. D. Van Nostrand.
- Labruyère, R., Gerber, C. N., Birrer-Brütsch, K., Meyer-Heim, A., & van Hedel, H. J. (2013). Requirements for and impact of a serious game for neuro-pediatric robot-assisted gait training. *Research in developmental disabilities*, 34(11), 3906-3915.
- Leonardi, L., Aceto, M. G., Marcotulli, C., Arcuria, G., Serrao, M., Pierelli, F., ... & Casali, C. (2017). A wearable proprioceptive stabilizer for rehabilitation of limb and gait ataxia in hereditary cerebellar ataxias: a pilot open-labeled study. *Neurological Sciences*, 38(3), 459-463.
- Maathuis, K. G., van der Schans, C. P., van Iperen, A., Rietman, H. S., & Geertzen, J. H. (2005). Gait in children with cerebral palsy: observer reliability of Physician Rating Scale and Edinburgh Visual Gait Analysis Interval Testing scale. *Journal of Pediatric Orthopaedics*, 25(3), 268-272.
- Martin, K., Hoover, D., Wagoner, E., Wingler, T., Evans, T., O'Brien, J., & Zeunik, J. (2009). Development and reliability of an observational gait analysis tool for children with Down syndrome. *Pediatric Physical Therapy*, 21(3), 261-268.

- Milton, J. S. & Arnold, J. C. (2003) Introduction to probability and statistics: principles and applications for engineering and the computing sciences, 4. ed. Boston: McGraw-Hill.
- Moon, S. H., Boo, J. A., & Park, S. E. (2016). Effects of ankle plantar flexors stretching with closed kinetic chain on pelvic movements and gait speed in hemiplegia patients: a case study. *Journal of physical therapy science*, 28(1), 309-313.
- Motek. (2020). All Movement and Balance Systems. Obtenido de Motek:
<https://www.motekmedical.com/solutions/>
- Pàmies Vilà, R., Font Llagunes, J. M., Lugrís, U., & Cuadrado, J. (2012). Estimación de los parámetros del modelo de contacto pie-suelo en la marcha humana. In XIX Congreso nacional de ingeniería mecánica: programa y resúmenes Castellón, 14-16 de noviembre 2010 (pp. 1-8).
- Prakash, C., Kumar, R., & Mittal, N. (2018). Recent developments in human gait research: parameters, approaches, applications, machine learning techniques, datasets and challenges. *Artificial Intelligence Review*, 49(1), 1-40.
- Rastegari, E., Azizian, S., & Ali, H. (2019, January). Machine learning and similarity network approaches to support automatic classification of parkinson's diseases using accelerometer-based gait analysis. In *Proceedings of the 52nd Hawaii International Conference on System Sciences*.
- Riener, R. (2016). Technology of the robotic gait orthosis Lokomat. In *Neurorehabilitation Technology* (pp. 395-407). Springer, Cham.

Shetty, S., & Rao, Y. S. (2016, August). SVM based machine learning approach to identify Parkinson's disease using gait analysis. In 2016 International Conference on Inventive Computation Technologies (ICICT) (Vol. 2, pp. 1-5). IEEE.

Shimmer. (2020). Overview. Obtenido de Shimmer discovery in motion:

<http://www.shimmersensing.com/services/services-for-wearable-technology-and-sensor-manufacture#services-tab>

Tomaszewski, P., Lundberg, L., & Grahn, H. (2005). The accuracy of early fault prediction in modified code. In Fifth conference on software engineering research and practice in Sweden (pp. 57-63).

Wallach, D., & Goffinet, B. (1989). Mean squared error of prediction as a criterion for evaluating and comparing system models. *Ecological modelling*, 44(3-4), 299-306.

Zheng, H., Yang, M., Wang, H., & McClean, S. (2009). Machine learning and statistical approaches to support the discrimination of neuro-degenerative diseases based on gait analysis. In *Intelligent patient management* (pp. 57-70). Springer, Berlin, Heidelberg.

ANEXO A

OPTIMIZACIÓN DE HIPERPARÁMETROS

A.1 Árboles de decisión

Tabla 40

Optimización de hiperparámetros para el GWALK

TODAS LAS CARACTERÍSTICAS			
22 minutos	Cadencia	Velocidad	Zancada
Train Score	0,752	0,923	0,867
Test Score	0,648	0,932	0,918
max_depth	12	6	8
MinSampleLeaf	1	4	3
MinSampleSplit	4	9	8

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
15 minutos	Cadencia	Velocidad	Zancada	14 minutos	Cadencia	Velocidad	Zancada	18 minutos	Cadencia	Velocidad	Zancada
Train Score	0,743	0,921	0,873	Train Score	0,691	0,723	0,752	Train Score	0,772	0,931	0,865
Test Score	0,626	0,93	0,909	Test Score	0,737	0,728	0,738	Test Score	0,709	0,921	0,891
max_depth	13	6	7	max_depth	12	12	12	max_depth	10	14	8
MinSampleLeaf	2	6	1	MinSampleLeaf	6	1	3	MinSampleLeaf	6	1	7
MinSampleSplit	6	2	15	MinSampleSplit	16	9	17	MinSampleSplit	2	13	2

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
11 minutos	Cadencia	Velocidad	Zancada	10 minutos	Cadencia	Velocidad	Zancada	13 minutos	Cadencia	Velocidad	Zancada
Train Score	0,553	0,893	0,765	Train Score	0,394	0,59	0,606	Train Score	0,649	0,882	0,83
Test Score	0,648	0,892	0,784	Test Score	0,351	0,552	0,648	Test Score	0,732	0,898	0,759
max_depth	5	9	6	max_depth	5	8	7	max_depth	9	7	15
MinSampleLeaf	3	5	7	MinSampleLeaf	2	8	1	MinSampleLeaf	3	7	2
MinSampleSplit	16	12	2	MinSampleSplit	13	2	2	MinSampleSplit	15	15	8

Tabla 41*Optimización de hiperparámetros para el sistema IMU*

TODAS LAS CARACTERÍSTICAS			
25 minutos	Cadencia	Velocidad	Zancada
Train Score	0,742	0,809	0,756
Test Score	0,826	0,672	0,794
max_depth	10	5	14
MinSampleLeaf	10	12	1
MinSampleSplit	2	2	11

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
16 minutos	Cadencia	Velocidad	Zancada
Train Score	0,760	0,859	0,785
Test Score	0,840	0,784	0,856
max_depth	13	11	7
MinSampleLeaf	3	8	2
MinSampleSplit	10	17	5

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
13 minutos	Cadencia	Velocidad	Zancada
Train Score	0,671	0,727	0,572
Test Score	0,791	0,608	0,783
max_depth	10	11	6
MinSampleLeaf	3	4	5
MinSampleSplit	8	2	19

Tabla 42*Optimización de hiperparámetros para el sensor IMU izquierdo*

TODAS LAS CARACTERÍSTICAS			
14 minutos	Cadencia	Velocidad	Zancada
Train Score	0,769	0,766	0,688
Test Score	0,805	0,731	0,602
max_depth	13	11	12
MinSampleLeaf	3	2	1
MinSampleSplit	13	18	10

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
14 minutos	Cadencia	Velocidad	Zancada
Train Score	0,726	0,793	0,718
Test Score	0,842	0,781	0,853
max_depth	12	11	10
MinSampleLeaf	4	3	4
MinSampleSplit	18	8	9

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
10 minutos	Cadencia	Velocidad	Zancada
Train Score	0,715	0,719	0,569
Test Score	0,786	0,525	0,575
max_depth	5	12	6
MinSampleLeaf	1	1	3
MinSampleSplit	3	7	14

Tabla 43

Optimización de hiperparámetros para el sensor IMU derecho

TODAS LAS CARACTERÍSTICAS			
14 minutos	Cadencia	Velocidad	Zancada
Train Score	0,781	0,821	0,669
Test Score	0,742	0,764	0,657
max_depth	9	8	9
MinSampleLeaf	5	5	8
MinSampleSplit	2	20	19

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
11 minutos	Cadencia	Velocidad	Zancada
Train Score	0,753	0,797	0,698
Test Score	0,801	0,791	0,676
max_depth	10	9	10
MinSampleLeaf	1	9	6
MinSampleSplit	3	2	15

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
9 minutos	Cadencia	Velocidad	Zancada
Train Score	0,559	0,721	0,531
Test Score	0,508	0,561	0,432
max_depth	9	6	6
MinSampleLeaf	13	3	1
MinSampleSplit	2	12	2

Tabla 44

Optimización de hiperparámetros para el sistema Apple Watch

TODAS LAS CARACTERÍSTICAS			
43 minutos	Cadencia	Velocidad	Zancada
Train Score	0,854	0,711	0,807
Test Score	0,819	0,725	0,887
max_depth	6	6	10
MinSampleLeaf	1	4	1
MinSampleSplit	3	9	9

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
16 minutos	Cadencia	Velocidad	Zancada	16 minutos	Cadencia	Velocidad	Zancada	28 minutos	Cadencia	Velocidad	Zancada
Train Score	0,87	0,714	0,804	Train Score	0,639	0,672	0,718	Train Score	0,841	0,778	0,795
Test Score	0,735	0,803	0,851	Test Score	0,591	0,535	0,552	Test Score	0,849	0,784	0,814
max_depth	7	9	8	max_depth	8	8	18	max_depth	7	8	7
MinSampleLeaf	1	3	1	MinSampleLeaf	1	1	2	MinSampleLeaf	1	1	1
MinSampleSplit	13	8	16	MinSampleSplit	8	10	12	MinSampleSplit	10	3	9

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
16 minutos	Cadencia	Velocidad	Zancada	15 minutos	Cadencia	Velocidad	Zancada	20 minutos	Cadencia	Velocidad	Zancada
Train Score	0,468	0,597	0,559	Train Score	0,321	0,361	0,192	Train Score	0,532	0,518	0,469
Test Score	0,511	0,608	0,428	Test Score	0,396	0,312	0,163	Test Score	0,468	0,554	0,495
max_depth	9	6	11	max_depth	6	6	3	max_depth	7	7	7
MinSampleLeaf	10	4	5	MinSampleLeaf	5	9	19	MinSampleLeaf	19	16	1
MinSampleSplit	2	11	17	MinSampleSplit	13	2	2	MinSampleSplit	2	2	9

Tabla 45

Optimización de hiperparámetros para el Apple Watch izquierdo

TODAS LAS CARACTERÍSTICAS											
25 minutos				Cadencia	Velocidad	Zancada					
Train Score				0,816	0,706	0,772					
Test Score				0,811	0,771	0,88					
max_depth				11	8	11					
MinSampleLeaf				5	8	1					
MinSampleSplit				13	17	12					

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
14 minutos	Cadencia	Velocidad	Zancada	12 minutos	Cadencia	Velocidad	Zancada	16 minutos	Cadencia	Velocidad	Zancada
Train Score	0,778	0,762	0,817	Train Score	0,569	0,598	0,605	Train Score	0,851	0,722	0,805
Test Score	0,482	0,721	0,897	Test Score	0,572	0,615	0,582	Test Score	0,796	0,716	0,902
max_depth	7	7	12	max_depth	9	6	13	max_depth	6	8	7
MinSampleLeaf	1	1	3	MinSampleLeaf	2	1	2	MinSampleLeaf	1	4	3
MinSampleSplit	10	5	15	MinSampleSplit	19	17	7	MinSampleSplit	10	16	15

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
9 minutos	Cadencia	Velocidad	Zancada	9 minutos	Cadencia	Velocidad	Zancada	14 minutos	Cadencia	Velocidad	Zancada
Train Score	0,451	0,524	0,315	Train Score	0,331	0,285	0,311	Train Score	0,498	0,476	0,363
Test Score	0,361	0,433	0,376	Test Score	0,233	0,338	0,305	Test Score	0,382	0,467	0,122
max_depth	5	6	6	max_depth	4	4	4	max_depth	7	10	8
MinSampleLeaf	3	3	13	MinSampleLeaf	19	13	12	MinSampleLeaf	17	11	1
MinSampleSplit	7	20	2	MinSampleSplit	2	2	2	MinSampleSplit	2	2	16

Tabla 46

Optimización de hiperparámetros para el Apple Watch derecho

TODAS LAS CARACTERÍSTICAS					
25 minutos		Cadencia	Velocidad	Zancada	
Train Score			0,732	0,719	0,655
Test Score			0,748	0,761	0,841
max_depth			6	12	11
MinSampleLeaf			2	3	1
MinSampleSplit			17	13	7

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
11 minutos	Cadencia	Velocidad	Zancada	12 minutos	Cadencia	Velocidad	Zancada	18 minutos	Cadencia	Velocidad	Zancada
Train Score	0,825	0,786	0,642	Train Score	0,738	0,641	0,596	Train Score	0,814	0,777	0,645
Test Score	0,791	0,793	0,851	Test Score	0,787	0,505	0,575	Test Score	0,784	0,649	0,783
max_depth	9	14	16	max_depth	8	17	14	max_depth	7	10	8
MinSampleLeaf	4	1	2	MinSampleLeaf	2	2	1	MinSampleLeaf	1	1	12
MinSampleSplit	19	11	5	MinSampleSplit	15	16	18	MinSampleSplit	5	11	2

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
9 minutos	Cadencia	Velocidad	Zancada	13 minutos	Cadencia	Velocidad	Zancada	14 minutos	Cadencia	Velocidad	Zancada
Train Score	0,486	0,539	0,412	Train Score	0,351	0,305	0,263	Train Score	0,421	0,492	0,389
Test Score	0,401	0,441	0,454	Test Score	0,316	0,182	0,206	Test Score	0,407	0,521	0,561
max_depth	8	7	5	max_depth	5	4	8	max_depth	7	5	6
MinSampleLeaf	3	9	1	MinSampleLeaf	4	8	6	MinSampleLeaf	12	3	2
MinSampleSplit	14	2	13	MinSampleSplit	17	20	19	MinSampleSplit	2	8	10

A.2 Bosques aleatorios

Tabla 47

Optimización de hiperparámetros para el GWALK

TODAS LAS CARACTERÍSTICAS			
27 minutos	Cadencia	Velocidad	Zancada
Train Score	0,839	0,959	0,931
Test Score	0,855	0,968	0,962
max_depth	10	20	15
MinSampleLeaf	2	2	2
MinSampleSplit	3	2	2

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
14 minutos	Cadencia	Velocidad	Zancada	14 minutos	Cadencia	Velocidad	Zancada	20 minutos	Cadencia	Velocidad	Zancada
Train Score	0,833	0,957	0,928	Train Score	0,804	0,831	0,831	Train Score	0,853	0,96	0,937
Test Score	0,836	0,963	0,947	Test Score	0,851	0,852	0,874	Test Score	0,867	0,963	0,964
max_depth	20	20	15	max_depth	20	15	20	max_depth	15	20	20
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	3	2	2	MinSampleSplit	2	2	4	MinSampleSplit	2	2	2

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
12 minutos	Cadencia	Velocidad	Zancada	12 minutos	Cadencia	Velocidad	Zancada	15 minutos	Cadencia	Velocidad	Zancada
Train Score	0,708	0,928	0,849	Train Score	0,623	0,773	0,763	Train Score	0,792	0,938	0,889
Test Score	0,798	0,942	0,895	Test Score	0,685	0,818	0,817	Test Score	0,853	0,95	0,922
max_depth	15	10	25	max_depth	25	15	15	max_depth	15	20	10
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	3	2	5	MinSampleSplit	4	2	3	MinSampleSplit	3	2	2

Tabla 48

Optimización de hiperparámetros para el sistema IMU

TODAS LAS CARACTERÍSTICAS			
27 minutos	Cadencia	Velocidad	Zancada
Train Score	0,868	0,902	0,891
Test Score	0,911	0,89	0,907
max_depth	20	20	20
MinSampleLeaf	2	2	2
MinSampleSplit	3	2	2

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
20 minutos	Cadencia	Velocidad	Zancada
Train Score	0,854	0,903	0,893
Test Score	0,911	0,903	0,912
max_depth	20	20	15
MinSampleLeaf	2	2	2
MinSampleSplit	5	5	2

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
16 minutos	Cadencia	Velocidad	Zancada
Train Score	0,787	0,833	0,759
Test Score	0,822	0,819	0,79
max_depth	20	10	15
MinSampleLeaf	2	2	2
MinSampleSplit	3	2	4

Tabla 49*Optimización de hiperparámetros para el sensor IMU izquierdo*

TODAS LAS CARACTERÍSTICAS			
18 minutos	Cadencia	Velocidad	Zancada
Train Score	0,854	0,885	0,855
Test Score	0,899	0,858	0,893
max_depth	15	15	10
MinSampleLeaf	2	2	2
MinSampleSplit	2	3	2

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
15 minutos	Cadencia	Velocidad	Zancada
Train Score	0,834	0,866	0,845
Test Score	0,902	0,886	0,894
max_depth	15	20	15
MinSampleLeaf	2	2	2
MinSampleSplit	2	2	2

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
11 minutos	Cadencia	Velocidad	Zancada
Train Score	0,788	0,815	0,735
Test Score	0,794	0,781	0,751
max_depth	25	10	10
MinSampleLeaf	2	2	2
MinSampleSplit	5	2	3

Tabla 50*Optimización de hiperparámetros para el sensor IMU derecho*

TODAS LAS CARACTERÍSTICAS			
17 minutos	Cadencia	Velocidad	Zancada
Train Score	0,858	0,885	0,857
Test Score	0,895	0,881	0,872
max_depth	25	15	25
MinSampleLeaf	2	2	2
MinSampleSplit	6	2	2

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
13 minutos	Cadencia	Velocidad	Zancada
Train Score	0,863	0,888	0,866
Test Score	0,889	0,899	0,894
max_depth	25	25	25
MinSampleLeaf	2	2	2
MinSampleSplit	4	2	5

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
12 minutos	Cadencia	Velocidad	Zancada
Train Score	0,715	0,803	0,677
Test Score	0,741	0,732	0,629
max_depth	20	15	10
MinSampleLeaf	2	2	2
MinSampleSplit	3	3	2

Tabla 51

Optimización de hiperparámetros para el sistema Apple Watch

TODAS LAS CARACTERÍSTICAS			
47 minutos	Cadencia	Velocidad	Zancada
Train Score	0,897	0,877	0,855
Test Score	0,867	0,897	0,919
max_depth	15	10	15
MinSampleLeaf	2	2	2
MinSampleSplit	2	2	2

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
20 minutos	Cadencia	Velocidad	Zancada	20 minutos	Cadencia	Velocidad	Zancada	30 minutos	Cadencia	Velocidad	Zancada
Train Score	0,902	0,869	0,867	Train Score	0,791	0,812	0,793	Train Score	0,911	0,884	0,882
Test Score	0,864	0,887	0,938	Test Score	0,788	0,819	0,799	Test Score	0,879	0,890	0,929
max_depth	10	15	15	max_depth	10	15	15	max_depth	15	15	20
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	2	2	3	MinSampleSplit	6	2	2	MinSampleSplit	5	2	5

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
15 minutos	Cadencia	Velocidad	Zancada	15 minutos	Cadencia	Velocidad	Zancada	21 minutos	Cadencia	Velocidad	Zancada
Train Score	0,704	0,739	0,649	Train Score	0,611	0,602	0,511	Train Score	0,731	0,746	0,676
Test Score	0,746	0,779	0,726	Test Score	0,616	0,657	0,556	Test Score	0,776	0,806	0,763
max_depth	15	15	50	max_depth	10	15	15	max_depth	15	25	25
MinSampleLeaf	2	2	2	MinSampleLeaf	3	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	2	2	3	MinSampleSplit	6	3	2	MinSampleSplit	5	2	2

Tabla 52

Optimización de hiperparámetros para el Apple Watch izquierdo

TODAS LAS CARACTERÍSTICAS			
27 minutos	Cadencia	Velocidad	Zancada
Train Score	0,883	0,825	0,819
Test Score	0,895	0,849	0,892
max_depth	15	15	25
MinSampleLeaf	2	2	2
MinSampleSplit	5	2	2

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
14 minutos	Cadencia	Velocidad	Zancada	14 minutos	Cadencia	Velocidad	Zancada	20 minutos	Cadencia	Velocidad	Zancada
Train Score	0,833	0,836	0,853	Train Score	0,742	0,765	0,783	Train Score	0,885	0,828	0,855
Test Score	0,824	0,850	0,917	Test Score	0,783	0,749	0,779	Test Score	0,889	0,848	0,905
max_depth	10	10	15	max_depth	10	15	15	max_depth	15	15	15
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	3	3	2	MinSampleSplit	2	2	2	MinSampleSplit	5	4	2

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
12 minutos	Cadencia	Velocidad	Zancada	12 minutos	Cadencia	Velocidad	Zancada	16 minutos	Cadencia	Velocidad	Zancada
Train Score	0,666	0,663	0,577	Train Score	0,561	0,553	0,438	Train Score	0,707	0,695	0,593
Test Score	0,631	0,723	0,676	Test Score	0,504	0,604	0,512	Test Score	0,698	0,727	0,67
max_depth	25	25	25	max_depth	20	25	10	max_depth	15	25	20
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	3	3	4	MinSampleSplit	2	3	2	MinSampleSplit	5	5	4

Tabla 53

Optimización de hiperparámetros para el Apple Watch derecho

TODAS LAS CARACTERÍSTICAS			
29 minutos	Cadencia	Velocidad	Zancada
Train Score	0,866	0,869	0,799
Test Score	0,836	0,886	0,858
max_depth	15	25	25
MinSampleLeaf	2	2	2
MinSampleSplit	5	2	5

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
14 minutos	Cadencia	Velocidad	Zancada	14 minutos	Cadencia	Velocidad	Zancada	20 minutos	Cadencia	Velocidad	Zancada
Train Score	0,878	0,871	0,784	Train Score	0,752	0,749	0,698	Train Score	0,881	0,889	0,821
Test Score	0,846	0,888	0,902	Test Score	0,788	0,748	0,718	Test Score	0,862	0,906	0,882
max_depth	25	15	15	max_depth	10	20	20	max_depth	20	20	15
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	2	2	2	MinSampleSplit	2	2	2	MinSampleSplit	2	2	3

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
12 minutos	Cadencia	Velocidad	Zancada	12 minutos	Cadencia	Velocidad	Zancada	16 minutos	Cadencia	Velocidad	Zancada
Train Score	0,659	0,655	0,577	Train Score	0,530	0,503	0,398	Train Score	0,708	0,712	0,624
Test Score	0,690	0,669	0,652	Test Score	0,547	0,572	0,475	Test Score	0,709	0,746	0,740
max_depth	15	15	20	max_depth	25	15	25	max_depth	25	20	20
MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2	MinSampleLeaf	2	2	2
MinSampleSplit	2	4	3	MinSampleSplit	3	3	4	MinSampleSplit	3	2	2

A.3 Máquinas de soporte vectorial

Tabla 54

Optimización de hiperparámetros para el GWALK

TODAS LAS CARACTERÍSTICAS			
23 minutos	Cadencia	Velocidad	Zancada
Train Score	0,921	0,976	0,957
Test Score	0,917	0,979	0,967
C	100	1	10
Degree	1	1	1
Epsilon	0,0001	0,0001	0,01
Gamma	scale	auto	auto
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
5 minutos	Cadencia	Velocidad	Zancada	3 minutos	Cadencia	Velocidad	Zancada	9 minutos	Cadencia	Velocidad	Zancada
Train Score	0,874	0,960	0,944	Train Score	0,799	0,794	0,787	Train Score	0,909	0,969	0,954
Test Score	0,898	0,968	0,954	Test Score	0,841	0,783	0,795	Test Score	0,918	0,979	0,968
C	100	1	1	C	100	1	1	C	100	10	1
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	1	0,01	0,01	Epsilon	1	0,01	0,0001	Epsilon	0,1	0,01	0,01
Gamma	scale	scale	scale	Gamma	scale	scale	scale	Gamma	scale	auto	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
4 minutos	Cadencia	Velocidad	Zancada	3 minutos	Cadencia	Velocidad	Zancada	7 minutos	Cadencia	Velocidad	Zancada
Train Score	0,702	0,930	0,855	Train Score	0,726	0,833	0,808	Train Score	0,843	0,946	0,918
Test Score	0,746	0,945	0,901	Test Score	0,771	0,829	0,808	Test Score	0,838	0,950	0,911
C	100	10	1	C	100	1	1	C	100	1	1
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	1	0,01	0,01	Epsilon	1	0,01	0,01	Epsilon	1	0,0001	0,001
Gamma	scale	auto	scale	Gamma	scale	scale	scale	Gamma	scale	auto	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

Tabla 55*Optimización de hiperparámetros para el sistema IMU*

TODAS LAS CARACTERÍSTICAS			
16 minutos	Cadencia	Velocidad	Zancada
Train Score	0,914	0,920	0,895
Test Score	0,926	0,931	0,916
C	100	1	100
Degree	2	1	1
Epsilon	1	0,01	0,01
Gamma	scale	scale	scale
Kernel	poly	rbf	rbf

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
6 minutos	Cadencia	Velocidad	Zancada
Train Score	0,894	0,901	0,895
Test Score	0,931	0,929	0,915
C	100	1	10
Degree	1	1	1
Epsilon	1	0,01	0,01
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
5 minutos	Cadencia	Velocidad	Zancada
Train Score	0,808	0,816	0,722
Test Score	0,793	0,850	0,799
C	100	1	1
Degree	1	1	1
Epsilon	1	0,001	0,001
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

Tabla 56*Optimización de hiperparámetros para el sensor IMU izquierdo*

TODAS LAS CARACTERÍSTICAS			
6 minutos	Cadencia	Velocidad	Zancada
Train Score	0,884	0,886	0,841
Test Score	0,917	0,902	0,879
C	100	1	1
Degree	1	1	1
Epsilon	0,5	0,01	0,01
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
3 minutos	Cadencia	Velocidad	Zancada
Train Score	0,821	0,870	0,846
Test Score	0,890	0,880	0,877
C	100	1	10
Degree	1	1	1
Epsilon	0,05	0,01	0,01
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
3 minutos	Cadencia	Velocidad	Zancada
Train Score	0,781	0,761	0,642
Test Score	0,770	0,754	0,672
C	100	1	1
Degree	1	1	1
Epsilon	0,5	0,01	0,05
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

Tabla 57

Optimización de hiperparámetros para el sensor IMU derecho

TODAS LAS CARACTERÍSTICAS			
6 minutos	Cadencia	Velocidad	Zancada
Train Score	0,881	0,882	0,825
Test Score	0,886	0,904	0,881
C	100	10	10
Degree	1	1	1
Epsilon	1	0,01	0,01
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS ESPACIALES			
Velocidad Angular			
3 minutos	Cadencia	Velocidad	Zancada
Train Score	0,833	0,878	0,828
Test Score	0,825	0,907	0,877
C	100	10	10
Degree	1	1	1
Epsilon	1	0,05	0,01
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES			
Velocidad Angular			
3 minutos	Cadencia	Velocidad	Zancada
Train Score	0,713	0,773	0,635
Test Score	0,656	0,764	0,661
C	100	1	1
Degree	1	1	1
Epsilon	1	0,01	0,05
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

Tabla 58

Optimización de hiperparámetros para el sistema Apple Watch

TODAS LAS CARACTERÍSTICAS			
74 minutos	Cadencia	Velocidad	Zancada
Train Score	0,883	0,900	0,869
Test Score	0,861	0,896	0,886
C	100	100	100
Degree	1	1	1
Epsilon	0,05	0,0001	0,0001
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
7 minutos	Cadencia	Velocidad	Zancada	7 minutos	Cadencia	Velocidad	Zancada	22 minutos	Cadencia	Velocidad	Zancada
Train Score	0,861	0,862	0,846	Train Score	0,715	0,809	0,768	Train Score	0,867	0,901	0,884
Test Score	0,842	0,894	0,878	Test Score	0,735	0,818	0,825	Test Score	0,836	0,902	0,902
C	100	1	1	C	100	1	1	C	100	1	1
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	0,5	0,01	0,001	Epsilon	1	0,01	0,01	Epsilon	0,1	0,01	0,001
Gamma	scale	scale	scale	Gamma	scale	scale	scale	Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
5 minutos	Cadencia	Velocidad	Zancada	5 minutos	Cadencia	Velocidad	Zancada	15 minutos	Cadencia	Velocidad	Zancada
Train Score	0,768	0,751	0,686	Train Score	0,690	0,677	0,579	Train Score	0,820	0,812	0,735
Test Score	0,734	0,749	0,704	Test Score	0,662	0,689	0,621	Test Score	0,781	0,792	0,764
C	100	1	10	C	100	1	1	C	100	100	1
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	1	0,01	0,05	Epsilon	1	0,01	0,05	Epsilon	0,5	0,01	0,01
Gamma	scale	scale	scale	Gamma	scale	scale	scale	Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

Tabla 59

Optimización de hiperparámetros para el Apple Watch izquierdo

TODAS LAS CARACTERÍSTICAS			
19 minutos	Cadencia	Velocidad	Zancada
Train Score	0,854	0,853	0,809
Test Score	0,827	0,877	0,835
C	100	1	100
Degree	1	1	1
Epsilon	0,1	0,01	0,01
Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
4 minutos	Cadencia	Velocidad	Zancada	3 minutos	Cadencia	Velocidad	Zancada	7 minutos	Cadencia	Velocidad	Zancada
Train Score	0,774	0,836	0,790	Train Score	0,633	0,692	0,649	Train Score	0,839	0,833	0,794
Test Score	0,792	0,854	0,815	Test Score	0,688	0,762	0,753	Test Score	0,840	0,862	0,833
C	100	10	10	C	100	10	10	C	100	1	10
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	1	0,05	0,01	Epsilon	1	0,01	0,01	Epsilon	1	0,0001	0,01
Gamma	scale	scale	scale	Gamma	scale	scale	scale	Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
4 minutos	Cadencia	Velocidad	Zancada	3 minutos	Cadencia	Velocidad	Zancada	5 minutos	Cadencia	Velocidad	Zancada
Train Score	0,722	0,677	0,595	Train Score	0,550	0,497	0,426	Train Score	0,724	0,727	0,640
Test Score	0,613	0,641	0,563	Test Score	0,544	0,499	0,431	Test Score	0,691	0,746	0,670
C	100	10	100	C	100	1	1	C	100	1	10
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	1	0,05	0,05	Epsilon	1	0,05	0,05	Epsilon	1	0,0001	0,01
Gamma	scale	scale	scale	Gamma	auto	scale	scale	Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

Tabla 60

Optimización de hiperparámetros para el Apple Watch derecho

TODAS LAS CARACTERÍSTICAS			
19 minutos	Cadencia	Velocidad	Zancada
Train Score	0,879	0,863	0,812
Test Score	0,851	0,846	0,828
C	100	1	100
Degree	1	1	4
Epsilon	0,5	0,01	0,01
Gamma	scale	scale	auto
Kernel	rbf	rbf	poly

CARACTERÍSTICAS ESPACIALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
4 minutos	Cadencia	Velocidad	Zancada	3 minutos	Cadencia	Velocidad	Zancada	7 minutos	Cadencia	Velocidad	Zancada
Train Score	0,812	0,734	0,714	Train Score	0,627	0,677	0,564	Train Score	0,832	0,853	0,804
Test Score	0,771	0,786	0,801	Test Score	0,646	0,667	0,599	Test Score	0,858	0,832	0,819
C	100	1	1	C	100	1	1	C	100	1	1
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	0,5	0,0001	0,0001	Epsilon	0,1	0,01	0,05	Epsilon	0,5	0,01	0,01
Gamma	scale	scale	scale	Gamma	scale	scale	scale	Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

CARACTERÍSTICAS NO LINEALES											
Aceleración Lineal				Velocidad Angular				AMBAS			
4 minutos	Cadencia	Velocidad	Zancada	3 minutos	Cadencia	Velocidad	Zancada	5 minutos	Cadencia	Velocidad	Zancada
Train Score	0,680	0,670	0,623	Train Score	0,556	0,544	0,359	Train Score	0,770	0,734	0,660
Test Score	0,660	0,623	0,575	Test Score	0,527	0,587	0,468	Test Score	0,705	0,747	0,709
C	10	1	1	C	10	1	1	C	10	1	1
Degree	1	1	1	Degree	1	1	1	Degree	1	1	1
Epsilon	1	0,05	0,05	Epsilon	0,5	0,005	0,05	Epsilon	0,5	0,01	0,05
Gamma	scale	scale	scale	Gamma	scale	scale	scale	Gamma	scale	scale	scale
Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf	Kernel	rbf	rbf	rbf

ANEXO B

TABLAS DE DESEMPEÑO

B.1 Regresión lineal múltiple

Tabla 61

Desempeño del GWALK

	Cadencia								Velocidad								Longitud de Zancada							
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
GWALK	0,776	-0,073	3,466	5,225	13,280	52,446	2,437	3,154	0,699	0,501	0,092	0,104	0,009	0,015	0,065	0,073	0,552	-0,094	0,103	0,140	0,011	0,036	0,074	0,087
GWALKAcLinealEspacial	0,513	0,208	5,250	5,818	28,130	34,528	4,180	4,627	0,921	0,923	0,047	0,046	0,002	0,002	0,039	0,039	0,765	0,725	0,074	0,080	0,006	0,007	0,061	0,066
GWALKVelAngularEspacial	0,105	0,048	7,099	6,728	51,374	46,377	5,618	5,218	0,034	0,196	0,166	0,150	0,028	0,023	0,138	0,119	0,133	0,271	0,143	0,131	0,021	0,018	0,119	0,106
GWALKEspacial	0,621	0,386	4,586	5,207	21,349	27,848	3,628	4,070	0,928	0,860	0,045	0,060	0,002	0,004	0,036	0,044	0,810	0,727	0,066	0,080	0,004	0,007	0,052	0,060
GWALKAcLinealNoLineal	0,513	0,397	5,240	5,190	27,593	27,235	4,127	4,196	0,886	0,883	0,058	0,055	0,003	0,003	0,047	0,044	0,751	0,757	0,077	0,075	0,006	0,006	0,060	0,060
GWALKVelAngularNoLineal	0,429	0,484	5,669	4,804	32,642	23,572	4,384	3,687	0,662	0,699	0,098	0,092	0,010	0,009	0,076	0,074	0,528	0,571	0,104	0,101	0,011	0,010	0,085	0,084
GWALKNoLineal	0,606	0,584	4,706	4,191	22,274	17,943	3,646	3,260	0,909	0,901	0,051	0,051	0,003	0,003	0,041	0,039	0,800	0,782	0,068	0,070	0,005	0,005	0,054	0,055

Tabla 62

Desempeño del sistema IMU

	Cadencia								Velocidad								Longitud de Zancada							
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
IMU	0,776	-0,073	3,466	5,225	13,280	52,446	2,437	3,154	0,699	0,501	0,092	0,104	0,009	0,015	0,065	0,073	0,552	-0,094	0,103	0,140	0,011	0,036	0,074	0,087
IMUVelAngularEspacial	0,603	0,149	4,586	5,507	22,213	35,786	3,460	3,788	0,589	0,416	0,107	0,111	0,013	0,017	0,075	0,079	0,390	0,048	0,119	0,139	0,016	0,030	0,084	0,095
IMUVelAngularNoLineal	0,659	0,573	4,380	4,393	19,326	19,880	3,416	3,385	0,665	0,455	0,098	0,119	0,010	0,015	0,077	0,094	0,432	0,247	0,116	0,135	0,014	0,019	0,090	0,109
IMUL	0,733	-0,281	3,801	5,598	14,636	65,141	3,024	3,389	0,600	-0,912	0,106	0,169	0,012	0,059	0,083	0,107	0,329	-2,234	0,124	0,212	0,016	0,114	0,095	0,123
IMULVelAngularEspacial	0,472	-1,141	5,473	7,628	30,160	105,340	4,462	4,950	0,463	-2,657	0,124	0,205	0,016	0,114	0,098	0,120	0,240	-1,314	0,134	0,194	0,019	0,080	0,104	0,122
IMULVelAngularNoLineal	0,590	0,547	4,793	4,547	23,095	21,207	3,882	3,576	0,602	0,433	0,107	0,124	0,012	0,016	0,086	0,102	0,342	0,180	0,125	0,142	0,016	0,021	0,101	0,117
IMUR	0,715	0,643	3,980	3,887	16,284	15,639	2,992	3,023	0,650	0,597	0,101	0,104	0,011	0,011	0,075	0,080	0,451	0,393	0,116	0,118	0,014	0,014	0,086	0,092
IMURVelAngularEspacial	0,551	0,431	5,017	4,943	25,427	24,921	3,912	3,828	0,505	0,603	0,120	0,105	0,015	0,011	0,087	0,085	0,353	0,448	0,126	0,114	0,017	0,014	0,093	0,091
IMURVelAngularNoLineal	0,610	0,489	4,677	4,761	22,053	22,919	3,665	3,827	0,594	0,412	0,109	0,124	0,012	0,016	0,083	0,098	0,314	0,217	0,128	0,138	0,017	0,020	0,099	0,112

Tabla 63

Desempeño del sistema Apple Watch

	Cadencia								Velocidad								Longitud de Zancada								
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	
AW	0,716	-3,254	3,918	11,230	16,058	216,842	2,909	6,731	0,722	0,384	0,088	0,130	0,008	0,017	0,067	0,108	-0,025	-1,107	0,136	0,194	0,025	0,043	0,084	0,142	
AWAcLinealEspacial	0,593	0,289	4,764	5,683	23,119	36,051	3,703	3,966	0,487	-0,186	0,120	0,137	0,015	0,031	0,089	0,090	0,306	-0,538	0,126	0,145	0,017	0,027	0,095	0,101	
AWVelAngularEspacial	-0,092	-0,871	6,815	7,595	60,457	92,112	4,544	5,188	-0,930	0,116	0,172	0,143	0,060	0,023	0,100	0,110	-1,471	-1,355	0,177	0,171	0,064	0,044	0,105	0,123	
AWEspacial	-0,827	0,942	6,796	6,471	99,694	45,924	3,826	4,871	-4,858	-1,822	0,234	0,185	0,184	0,069	0,100	0,105	-6,849	-1,113	0,251	0,205	0,205	0,085	0,110	0,119	
AWAcLinealNoLineal	0,526	0,279	5,197	5,761	27,415	34,832	4,047	4,581	0,547	0,529	0,115	0,113	0,013	0,013	0,092	0,089	0,380	0,450	0,121	0,115	0,015	0,014	0,095	0,088	
AWVelAngularNoLineal	0,521	0,320	5,137	5,405	26,945	29,843	4,167	4,343	0,504	0,319	0,120	0,136	0,015	0,019	0,096	0,113	0,297	0,180	0,129	0,141	0,017	0,021	0,100	0,113	
AWNoLineal	0,642	0,410	4,480	5,049	20,233	26,209	3,585	4,187	0,667	0,617	0,098	0,101	0,010	0,010	0,077	0,080	0,467	0,483	0,112	0,111	0,013	0,013	0,086	0,085	
AWL	0,579	0,238	4,713	5,596	23,264	35,944	3,908	4,169	0,595	0,113	0,107	0,127	0,012	0,022	0,079	0,087	0,168	-0,159	0,134	0,135	0,020	0,023	0,092	0,094	
AWLAcLinealEspacial	0,473	0,390	5,443	5,369	29,742	29,373	4,311	4,202	0,502	0,510	0,119	0,114	0,015	0,013	0,090	0,091	0,339	0,378	0,123	0,122	0,016	0,015	0,094	0,095	
AWLVelAngularEspacial	-3,763	-0,155	10,254	7,121	259,248	55,190	5,461	5,185	-1,606	0,103	0,203	0,154	0,081	0,024	0,122	0,120	-6,604	0,191	0,168	0,135	0,041	0,018	0,114	0,107	
AWLEspacial	-2,839	0,527	8,977	4,677	213,896	22,300	4,673	3,738	-3,817	-1,699	0,222	0,171	0,151	0,065	0,105	0,102	-3,194	-3,407	0,209	0,188	0,109	0,077	0,107	0,112	
AWLAcLinealNoLineal	0,350	0,163	6,040	6,223	36,877	39,734	4,742	5,069	0,454	0,423	0,126	0,125	0,016	0,016	0,103	0,100	0,328	0,364	0,126	0,124	0,016	0,016	0,098	0,093	
AWLVelAngularNoLineal	0,331	0,245	6,052	5,872	37,183	35,076	4,793	4,789	0,293	0,231	0,144	0,146	0,021	0,022	0,117	0,122	0,200	0,187	0,138	0,141	0,019	0,021	0,108	0,111	
AWLNoLineal	0,469	0,266	5,360	5,774	29,202	34,425	4,171	4,712	0,513	0,408	0,119	0,125	0,014	0,016	0,095	0,098	0,362	0,351	0,123	0,123	0,015	0,016	0,095	0,093	
AWR	0,665	0,001	4,318	6,494	19,338	50,374	3,292	4,519	0,689	0,065	0,095	0,134	0,009	0,024	0,074	0,096	0,463	-1,868	0,114	0,181	0,013	0,048	0,088	0,122	
AWRAcLinealEspacial	0,490	0,264	5,399	5,875	29,767	36,880	4,234	4,507	0,371	0,395	0,135	0,129	0,019	0,017	0,101	0,100	0,222	0,182	0,136	0,139	0,019	0,020	0,105	0,109	
AWRVelAngularEspacial	0,388	0,107	5,903	6,313	35,245	42,465	4,779	5,135	0,385	-0,743	0,134	0,197	0,018	0,046	0,105	0,148	0,172	-1,885	0,142	0,207	0,020	0,057	0,113	0,151	
AWREspacial	0,570	-0,066	4,939	6,436	25,242	52,665	3,812	4,793	0,510	0,118	0,120	0,147	0,014	0,023	0,091	0,112	0,319	-0,928	0,129	0,172	0,017	0,038	0,098	0,124	
AWRAcLinealNoLineal	0,455	0,230	5,591	5,921	31,856	37,963	4,352	4,691	0,432	0,409	0,129	0,127	0,017	0,017	0,105	0,106	0,279	0,364	0,131	0,124	0,018	0,016	0,105	0,099	
AWRVelAngularNoLineal	0,420	0,214	5,726	5,972	33,379	36,726	4,637	5,002	0,389	0,225	0,133	0,145	0,018	0,021	0,110	0,110	0,128	0,128	0,021	0,145	0,154	0,022	0,024	0,118	0,128
AWRNoLineal	0,552	0,294	5,052	5,494	25,840	32,857	3,958	4,372	0,600	0,571	0,108	0,107	0,012	0,012	0,086	0,087	0,399	0,465	0,120	0,112	0,015	0,013	0,093	0,092	

B.2 Árboles de decisión

Tabla 64

Desempeño del GWALK

	Cadencia								Velocidad								Longitud de Zancada							
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
GWALK	0,752	0,310	3,753	4,954	14,534	28,623	2,411	3,438	0,923	0,854	0,047	0,060	0,002	0,004	0,036	0,045	0,867	0,762	0,053	0,072	0,003	0,006	0,038	0,051
GWALKAcLinealEspacial	0,743	0,104	3,737	6,042	14,618	39,274	2,390	4,068	0,921	0,890	0,047	0,053	0,002	0,003	0,036	0,039	0,873	0,780	0,054	0,067	0,003	0,005	0,038	0,048
GWALKVelAngularEspacial	0,691	0,222	4,123	5,690	17,545	34,878	2,726	4,200	0,723	0,416	0,087	0,122	0,008	0,016	0,059	0,083	0,752	0,424	0,074	0,111	0,006	0,013	0,046	0,077
GWALKEspacial	0,772	0,325	3,497	5,104	12,481	27,254	2,365	3,732	0,931	0,895	0,044	0,052	0,002	0,003	0,033	0,039	0,865	0,698	0,053	0,079	0,003	0,007	0,038	0,057
GWALKAcLinealNoLineal	0,553	0,283	5,017	5,463	25,501	31,232	3,635	3,777	0,893	0,812	0,054	0,070	0,003	0,005	0,040	0,053	0,765	0,694	0,074	0,083	0,006	0,007	0,055	0,062
GWALKVelAngularNoLineal	0,394	0,061	5,837	6,306	34,724	41,100	4,380	4,565	0,590	0,352	0,105	0,135	0,011	0,019	0,077	0,101	0,606	0,326	0,096	0,126	0,009	0,016	0,065	0,090
GWALKNoLineal	0,649	0,242	4,423	5,440	20,514	31,286	3,068	3,713	0,882	0,837	0,058	0,066	0,003	0,004	0,043	0,052	0,830	0,674	0,064	0,083	0,004	0,007	0,046	0,062

Tabla 65

Desempeño del sistema IMU

	Cadencia								Velocidad								Longitud de Zancada							
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
IMU	0,742	0,645	3,647	3,990	13,692	16,927	2,566	2,958	0,809	0,721	0,074	0,087	0,006	0,008	0,053	0,067	0,756	0,514	0,075	0,100	0,006	0,012	0,048	0,065
IMUVelAngularEspacial	0,760	0,593	3,621	4,219	13,580	18,491	2,354	2,807	0,859	0,524	0,063	0,106	0,004	0,013	0,047	0,075	0,785	0,583	0,070	0,095	0,005	0,010	0,047	0,066
IMUVelAngularNoLineal	0,671	0,236	4,081	5,983	17,510	37,824	2,749	3,977	0,727	0,611	0,089	0,101	0,008	0,011	0,060	0,071	0,572	0,423	0,097	0,112	0,010	0,013	0,067	0,087
IMUL	0,769	0,709	3,498	3,671	12,999	14,503	2,420	2,418	0,766	0,569	0,082	0,107	0,007	0,012	0,056	0,072	0,688	0,596	0,085	0,092	0,008	0,009	0,052	0,062
IMULVelAngularEspacial	0,726	0,609	3,878	4,066	15,277	17,892	2,410	2,948	0,793	0,545	0,077	0,106	0,006	0,013	0,055	0,072	0,718	0,439	0,079	0,109	0,007	0,015	0,051	0,076
IMULVelAngularNoLineal	0,715	0,300	3,839	5,592	15,143	33,229	2,868	4,022	0,719	0,571	0,088	0,109	0,008	0,012	0,064	0,077	0,569	0,331	0,100	0,121	0,010	0,015	0,072	0,091
IMUR	0,781	0,484	3,441	4,711	12,116	22,727	2,419	3,321	0,821	0,409	0,072	0,128	0,005	0,017	0,051	0,085	0,669	0,549	0,085	0,101	0,007	0,010	0,061	0,074
IMURVelAngularEspacial	0,753	0,446	3,659	4,768	14,569	23,533	2,409	3,156	0,797	0,532	0,075	0,113	0,006	0,013	0,055	0,082	0,698	0,579	0,079	0,097	0,007	0,010	0,056	0,070
IMURVelAngularNoLineal	0,559	0,368	4,775	5,244	23,637	27,823	3,633	4,036	0,721	0,383	0,088	0,127	0,008	0,017	0,063	0,090	0,530	0,177	0,103	0,137	0,011	0,019	0,070	0,101

Tabla 66

Desempeño del sistema Apple Watch

	Cadencia								Velocidad								Longitud de Zancada							
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
AW	0,854	0,373	2,793	5,203	8,099	30,363	2,031	3,341	0,711	0,552	0,091	0,108	0,009	0,012	0,060	0,075	0,807	0,570	0,067	0,101	0,005	0,011	0,047	0,066
AWAcLinealEspacial	0,870	0,439	2,631	4,841	7,094	24,565	1,886	3,273	0,714	0,720	0,088	0,086	0,008	0,008	0,058	0,059	0,804	0,557	0,067	0,094	0,005	0,010	0,045	0,066
AWVelAngularEspacial	0,639	0,156	4,294	5,821	20,210	36,181	2,640	4,065	0,672	0,467	0,094	0,118	0,009	0,015	0,062	0,086	0,718	0,416	0,082	0,117	0,007	0,014	0,054	0,082
AWEspacial	0,840	0,595	2,967	4,207	8,928	19,719	2,064	2,865	0,778	0,669	0,079	0,092	0,007	0,009	0,054	0,061	0,795	0,593	0,069	0,097	0,005	0,010	0,048	0,065
AWAcLinealNoLineal	0,468	0,203	5,431	6,015	30,049	39,879	3,896	4,603	0,597	0,281	0,104	0,139	0,011	0,020	0,073	0,101	0,559	0,355	0,102	0,120	0,011	0,016	0,072	0,091
AWVelAngularNoLineal	0,321	0,040	6,203	6,609	39,309	45,035	4,508	4,785	0,360	0,314	0,137	0,136	0,019	0,020	0,097	0,107	0,192	0,058	0,141	0,151	0,021	0,023	0,105	0,115
AWNNoLineal	0,532	0,131	5,128	6,349	26,993	42,484	3,816	4,924	0,518	0,244	0,118	0,144	0,014	0,022	0,087	0,111	0,469	0,225	0,113	0,136	0,013	0,019	0,080	0,091
AWL	0,816	0,463	3,151	4,935	10,221	26,358	2,151	3,141	0,706	0,415	0,091	0,121	0,009	0,016	0,058	0,086	0,772	0,741	0,073	0,079	0,006	0,006	0,050	0,055
AWAcLinealEspacial	0,778	0,347	3,452	5,196	12,099	29,042	2,370	3,552	0,762	0,645	0,083	0,095	0,007	0,010	0,056	0,064	0,817	0,690	0,065	0,081	0,005	0,007	0,043	0,056
AWLVelAngularEspacial	0,569	0,036	4,776	6,684	23,498	48,863	3,223	4,800	0,598	0,221	0,109	0,143	0,012	0,022	0,073	0,105	0,605	0,203	0,097	0,133	0,010	0,019	0,063	0,089
AWLEspacial	0,851	0,494	2,768	4,868	8,097	25,475	1,965	3,165	0,722	0,423	0,089	0,121	0,008	0,016	0,058	0,085	0,805	0,764	0,068	0,074	0,005	0,006	0,046	0,054
AWAcLinealNoLineal	0,451	0,070	5,566	6,341	31,082	41,636	4,110	4,906	0,524	0,184	0,117	0,148	0,014	0,022	0,083	0,108	0,315	0,057	0,127	0,152	0,016	0,025	0,090	0,113
AWLVelAngularNoLineal	0,330	-0,001	6,142	6,666	38,386	44,906	4,797	5,275	0,285	0,271	0,144	0,141	0,021	0,021	0,110	0,115	0,310	0,019	0,129	0,154	0,017	0,025	0,095	0,120
AWLNoLineal	0,498	0,240	5,275	5,877	28,161	35,268	3,881	4,580	0,476	0,289	0,121	0,139	0,015	0,020	0,087	0,109	0,363	-0,129	0,122	0,163	0,015	0,028	0,084	0,111
AWR	0,730	0,202	3,824	6,063	15,419	39,337	2,730	4,023	0,719	0,547	0,088	0,107	0,008	0,013	0,059	0,074	0,655	0,410	0,089	0,117	0,009	0,014	0,059	0,079
AWRAcLinealEspacial	0,825	0,331	3,141	5,538	10,164	32,563	2,278	3,914	0,786	0,387	0,076	0,125	0,006	0,017	0,053	0,086	0,642	0,560	0,092	0,101	0,009	0,011	0,059	0,065
AWRVelAngularEspacial	0,738	0,201	3,843	5,896	15,353	36,143	2,522	4,199	0,641	0,288	0,100	0,131	0,011	0,019	0,064	0,095	0,596	0,131	0,095	0,133	0,010	0,019	0,062	0,093
AWREspacial	0,814	0,278	3,235	5,760	11,115	34,569	2,307	3,929	0,777	0,509	0,079	0,113	0,006	0,014	0,055	0,080	0,645	0,448	0,092	0,113	0,009	0,014	0,064	0,085
AWRAcLinealNoLineal	0,486	0,176	5,364	6,173	29,323	40,599	3,824	4,499	0,539	0,324	0,115	0,138	0,013	0,020	0,087	0,105	0,412	0,231	0,116	0,136	0,014	0,019	0,087	0,097
AWRVelAngularNoLineal	0,351	0,185	6,038	6,035	37,127	39,166	4,574	4,608	0,305	0,062	0,141	0,160	0,020	0,026	0,111	0,125	0,263	-0,203	0,131	0,170	0,017	0,030	0,098	0,132
AWRNoLineal	0,421	0,123	5,628	6,399	32,503	44,574	4,086	4,758	0,492	0,132	0,121	0,153	0,015	0,024	0,088	0,113	0,389	0,390	0,120	0,119	0,015	0,015	0,086	0,083

B.3 Bosques aleatorios

Tabla 67

Desempeño del GWALK

	Cadencia							Velocidad							Longitud de Zancada									
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
GWALK	0.839	0.688	2,967	3,621	8,941	13,629	2,075	2,726	0.959	0.936	0.035	0.039	0.001	0.002	0.026	0.031	0.930	0.879	0.039	0.052	0.002	0.003	0.030	0.039
GWALKAcLinealEspecial	0.833	0.597	3,064	4,038	9,662	17,334	2,145	3,051	0.957	0.937	0.035	0.040	0.001	0.002	0.027	0.031	0.928	0.861	0.040	0.055	0.002	0.003	0.030	0.041
GWALKVelAngularEspecial	0.804	0.486	3,338	4,874	11,362	24,694	2,455	3,553	0.831	0.679	0.070	0.093	0.005	0.009	0.051	0.070	0.831	0.686	0.061	0.083	0.004	0.007	0.042	0.062
GWALKAcLinealNoLineal	0.853	0.669	2,875	3,714	8,368	14,497	2,005	2,862	0.960	0.937	0.034	0.040	0.001	0.002	0.026	0.031	0.937	0.873	0.037	0.053	0.001	0.003	0.028	0.040
GWALKVelAngularNoLineal	0.708	0.561	4,041	4,243	16,464	18,981	2,855	3,142	0.928	0.897	0.045	0.051	0.002	0.003	0.035	0.040	0.849	0.791	0.059	0.067	0.004	0.005	0.044	0.051
GWALKAcLinealEspecial	0.623	0.495	4,584	4,762	21,570	23,435	3,375	3,455	0.773	0.661	0.081	0.097	0.007	0.010	0.061	0.073	0.763	0.676	0.075	0.087	0.006	0.008	0.056	0.066
GWALKNoLineal	0.792	0.656	3,404	3,859	11,713	15,407	2,449	2,849	0.938	0.904	0.043	0.049	0.002	0.003	0.032	0.039	0.890	0.829	0.051	0.062	0.003	0.004	0.038	0.047

Tabla 68

Desempeño del sistema IMU

	Cadencia							Velocidad							Longitud de Zancada									
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
IMU	0.868	0.801	2,691	3,001	7,403	9,457	1,856	2,250	0.902	0.849	0.053	0.063	0.003	0.004	0.038	0.047	0.891	0.776	0.051	0.072	0.003	0.006	0.038	0.053
IMUVelAngularEspecial	0.854	0.777	2,804	3,085	8,066	9,848	1,966	2,281	0.903	0.779	0.053	0.074	0.003	0.006	0.039	0.054	0.893	0.782	0.051	0.070	0.003	0.006	0.037	0.051
IMUVelAngularNoLineal	0.787	0.642	3,387	3,986	11,590	16,562	2,363	2,918	0.830	0.778	0.069	0.077	0.005	0.006	0.048	0.056	0.759	0.659	0.075	0.090	0.006	0.009	0.056	0.069
IMUL	0.854	0.799	2,814	3,059	8,118	9,797	1,909	2,298	0.885	0.817	0.057	0.070	0.003	0.005	0.040	0.052	0.856	0.742	0.059	0.076	0.004	0.007	0.040	0.056
IMUVelAngularEspecial	0.834	0.764	2,996	3,237	9,180	10,824	2,065	2,395	0.866	0.743	0.062	0.080	0.004	0.007	0.045	0.059	0.845	0.733	0.061	0.077	0.004	0.007	0.040	0.056
IMUVelAngularNoLineal	0.788	0.646	3,368	4,043	11,479	16,934	2,463	3,054	0.815	0.735	0.072	0.085	0.005	0.008	0.053	0.065	0.735	0.622	0.078	0.093	0.006	0.009	0.060	0.074
IMUR	0.858	0.743	2,791	3,331	8,018	11,513	2,014	2,538	0.886	0.790	0.057	0.075	0.003	0.006	0.042	0.054	0.857	0.760	0.059	0.075	0.004	0.006	0.042	0.057
IMURVelAngularEspecial	0.863	0.729	2,753	3,348	7,817	11,580	1,971	2,562	0.888	0.802	0.056	0.073	0.003	0.005	0.041	0.057	0.866	0.774	0.056	0.073	0.003	0.006	0.040	0.055
IMURVelAngularNoLineal	0.715	0.569	3,926	4,325	15,867	19,200	2,869	3,206	0.803	0.636	0.074	0.098	0.006	0.010	0.054	0.071	0.677	0.558	0.088	0.104	0.008	0.011	0.064	0.083

Tabla 69

Desempeño del sistema Apple Watch

	Cadencia							Velocidad							Longitud de Zancada									
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
AW	0.897	0.884	2,358	3,812	5,742	16,146	1,720	2,815	0.877	0.764	0.059	0.080	0.004	0.007	0.044	0.061	0.854	0.774	0.059	0.074	0.004	0.006	0.042	0.054
AWAcLinealEspecial	0.902	0.727	2,259	3,611	5,278	13,606	1,637	2,606	0.869	0.822	0.061	0.069	0.004	0.005	0.043	0.052	0.867	0.793	0.056	0.071	0.003	0.005	0.040	0.052
AWVelAngularEspecial	0.790	0.536	3,442	4,667	12,028	22,606	2,447	3,636	0.812	0.674	0.074	0.094	0.006	0.009	0.054	0.073	0.793	0.701	0.070	0.083	0.005	0.007	0.048	0.062
AWAcLinealNoLineal	0.910	0.739	2,203	3,544	4,964	13,203	1,618	2,645	0.884	0.802	0.058	0.073	0.003	0.006	0.042	0.054	0.882	0.801	0.054	0.069	0.003	0.005	0.038	0.050
AWVelAngularNoLineal	0.704	0.543	4,108	4,584	17,199	23,196	3,081	3,412	0.739	0.585	0.086	0.107	0.008	0.012	0.066	0.082	0.649	0.599	0.090	0.098	0.008	0.010	0.068	0.075
AWNoLineal	0.611	0.463	4,704	4,999	22,759	25,875	3,610	3,901	0.602	0.494	0.107	0.116	0.012	0.015	0.079	0.095	0.511	0.408	0.108	0.120	0.012	0.015	0.078	0.096
AWL	0.730	0.618	3,937	4,206	15,704	19,188	2,973	3,238	0.745	0.629	0.087	0.101	0.008	0.010	0.065	0.078	0.675	0.603	0.088	0.097	0.008	0.010	0.065	0.077
AWLAcLinealEspecial	0.883	0.711	2,549	3,723	6,678	14,517	1,835	2,739	0.825	0.672	0.070	0.092	0.005	0.009	0.050	0.067	0.818	0.734	0.065	0.080	0.005	0.007	0.045	0.057
AWLVelAngularEspecial	0.833	0.731	3,004	3,570	9,198	13,348	2,076	2,644	0.836	0.750	0.068	0.082	0.005	0.007	0.047	0.060	0.853	0.793	0.059	0.071	0.004	0.005	0.041	0.050
AWLAcLinealNoLineal	0.742	0.438	3,784	5,137	14,493	27,698	2,639	3,819	0.765	0.584	0.082	0.106	0.007	0.012	0.060	0.082	0.783	0.568	0.071	0.101	0.005	0.011	0.051	0.076
AWLVelAngularNoLineal	0.885	0.735	2,512	3,582	6,537	13,419	1,771	2,604	0.828	0.713	0.070	0.087	0.005	0.008	0.048	0.063	0.854	0.772	0.059	0.074	0.004	0.006	0.041	0.052
AWNoLineal	0.666	0.394	4,353	5,269	19,222	28,252	3,304	4,047	0.663	0.541	0.099	0.111	0.010	0.013	0.074	0.085	0.578	0.421	0.102	0.116	0.011	0.015	0.074	0.085
AWR	0.561	0.307	4,993	5,670	25,338	32,536	3,841	4,423	0.533	0.440	0.116	0.122	0.014	0.016	0.088	0.099	0.438	0.403	0.115	0.119	0.014	0.016	0.083	0.094
AWRAcLinealEspecial	0.707	0.520	4,087	4,671	16,901	22,141	3,123	3,528	0.695	0.543	0.094	0.110	0.009	0.013	0.069	0.083	0.593	0.438	0.098	0.115	0.010	0.014	0.070	0.085
AWRVelAngularEspecial	0.866	0.610	2,743	4,206	7,836	20,175	2,114	3,079	0.869	0.745	0.062	0.084	0.004	0.007	0.047	0.065	0.798	0.724	0.069	0.082	0.005	0.007	0.050	0.064
AWRAcLinealNoLineal	0.878	0.570	2,624	4,513	7,218	21,352	1,960	3,350	0.872	0.732	0.061	0.085	0.004	0.007	0.046	0.064	0.785	0.743	0.071	0.080	0.005	0.007	0.049	0.059
AWRVelAngularNoLineal	0.752	0.530	3,768	4,690	14,532	23,087	2,725	3,690	0.750	0.611	0.085	0.102	0.007	0.011	0.061	0.083	0.698	0.527	0.085	0.104	0.008	0.011	0.061	0.080
AWREspecial	0.881	0.641	2,592	4,098	6,950	18,341	1,936	3,152	0.889	0.770	0.057	0.079	0.003	0.006	0.043	0.061	0.821	0.724	0.066	0.083	0.005	0.007	0.047	0.061
AWRAcLinealNoLineal	0.659	0.470	4,391	4,919	19,705	27,099	3,373	3,756	0.655	0.532	0.099	0.113	0.010	0.013	0.076	0.088	0.578	0.543	0.099	0.105	0.010	0.011	0.076	0.079
AWRVelAngularNoLineal	0.530	0.452	5,149	5,038	26,956	26,832	3,888	3,989	0.503	0.357	0.120	0.134	0.014	0.018	0.093	0.105	0.398	0.240	0.120	0.135	0.015	0.018	0.093	0.110
AWRNoLineal	0.708	0.532	4,077	4,641	16,967	23,858	3,036	3,462	0.712	0.605	0.092	0.105	0.009	0.011	0.070	0.081	0.625	0.590	0.095	0.098	0.009	0.010	0.072	0.076

B.4 Máquinas de soporte vectorial

Tabla 70

Desempeño del GWALK

	Cadencia												Velocidad												Longitud de Zancada											
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE													
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test												
GWALK	0.922	0.843	2.096	2.586	4.474	7.042	1.548	1.963	0.976	0.955	0.026	0.034	0.001	0.001	0.020	0.027	0.957	0.927	0.031	0.040	0.001	0.002	0.023	0.032												
GWALKAcLinealEspacial	0.876	0.759	2.657	3.192	7.136	10.712	1.960	2.365	0.960	0.947	0.034	0.037	0.001	0.001	0.025	0.027	0.944	0.912	0.035	0.044	0.001	0.002	0.026	0.033												
GWALKVelAngularEspacial	0.803	0.674	3.307	3.737	11.189	14.780	2.439	2.852	0.798	0.677	0.075	0.093	0.006	0.009	0.057	0.071	0.790	0.710	0.069	0.082	0.005	0.007	0.050	0.061												
GWALKEspacial	0.910	0.846	2.248	2.573	5.124	6.962	1.616	1.934	0.969	0.954	0.029	0.035	0.001	0.001	0.021	0.026	0.955	0.935	0.031	0.038	0.001	0.002	0.023	0.029												
GWALKAcLinealNoLineal	0.702	0.594	4.061	4.284	16.688	19.211	2.935	3.190	0.931	0.889	0.044	0.055	0.002	0.003	0.034	0.041	0.854	0.839	0.058	0.060	0.003	0.004	0.043	0.047												
GWALKVelAngularNoLineal	0.723	0.648	3.952	4.021	16.148	16.782	3.006	3.134	0.832	0.790	0.070	0.075	0.005	0.006	0.053	0.059	0.807	0.735	0.068	0.078	0.005	0.006	0.051	0.062												
GWALKNoLineal	0.842	0.731	2.989	3.441	9.007	12.162	2.366	2.679	0.946	0.917	0.039	0.047	0.002	0.002	0.031	0.035	0.917	0.833	0.043	0.061	0.002	0.004	0.033	0.049												

Tabla 71

Desempeño del sistema IMU

	Cadencia												Velocidad												Longitud de Zancada											
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE													
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test												
IMU	0.912	0.845	2.225	2.640	5.092	7.156	1.692	1.978	0.928	0.857	0.046	0.061	0.002	0.004	0.035	0.044	0.897	0.820	0.048	0.065	0.002	0.004	0.036	0.049												
IMUVelAngularEspacial	0.904	0.866	2.307	2.446	5.462	6.101	1.703	1.854	0.910	0.843	0.051	0.065	0.003	0.004	0.038	0.050	0.897	0.815	0.048	0.067	0.002	0.005	0.035	0.050												
IMUVelAngularNoLineal	0.810	0.717	3.225	3.540	10.486	13.237	2.419	2.684	0.814	0.753	0.073	0.080	0.005	0.007	0.053	0.060	0.721	0.636	0.081	0.091	0.007	0.009	0.060	0.069												
IMUL	0.890	0.857	2.467	2.517	6.219	6.813	1.773	1.880	0.889	0.868	0.056	0.060	0.003	0.004	0.042	0.045	0.841	0.824	0.061	0.063	0.004	0.004	0.045	0.047												
IMULVelAngularEspacial	0.821	0.785	3.145	3.116	10.069	10.010	2.182	2.331	0.870	0.794	0.061	0.073	0.004	0.006	0.047	0.056	0.844	0.769	0.060	0.072	0.004	0.005	0.045	0.054												
IMULVelAngularNoLineal	0.782	0.656	3.433	3.927	11.917	16.487	2.559	3.010	0.762	0.708	0.083	0.089	0.007	0.008	0.062	0.068	0.604	0.528	0.096	0.104	0.009	0.011	0.074	0.080												
IMUR	0.884	0.751	2.523	3.252	6.453	11.007	1.847	2.413	0.884	0.811	0.057	0.072	0.003	0.005	0.044	0.055	0.826	0.737	0.064	0.079	0.004	0.006	0.047	0.061												
IMURVelAngularEspacial	0.833	0.650	3.070	3.735	9.477	14.722	2.303	2.736	0.878	0.791	0.060	0.075	0.004	0.006	0.046	0.058	0.828	0.689	0.063	0.084	0.004	0.007	0.046	0.063												
IMURVelAngularNoLineal	0.709	0.441	4.000	4.892	16.091	24.184	2.948	3.632	0.769	0.613	0.082	0.100	0.007	0.010	0.060	0.074	0.634	0.452	0.094	0.112	0.009	0.013	0.071	0.090												

Tabla 72

Desempeño del sistema Apple Watch

	Cadencia												Velocidad												Longitud de Zancada											
	R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE		R2		RMSE		MSE		MAE													
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test												
AW	0.891	0.779	2.457	3.198	6.374	10.587	1.771	2.398	0.903	0.847	0.053	0.064	0.003	0.004	0.040	0.051	0.873	0.810	0.054	0.067	0.003	0.005	0.041	0.053												
AWAcLinealEspacial	0.863	0.706	2.752	3.506	7.917	13.708	1.969	2.498	0.864	0.822	0.063	0.068	0.004	0.005	0.047	0.052	0.851	0.802	0.058	0.068	0.004	0.005	0.043	0.052												
AWVelAngularEspacial	0.728	0.564	3.936	4.498	15.699	21.225	2.815	3.508	0.812	0.728	0.074	0.085	0.006	0.007	0.056	0.069	0.773	0.712	0.072	0.079	0.005	0.007	0.052	0.064												
AWEspacial	0.880	0.733	2.587	3.449	6.953	12.610	1.822	2.489	0.905	0.848	0.051	0.062	0.003	0.004	0.038	0.048	0.890	0.834	0.050	0.061	0.003	0.004	0.037	0.047												
AWAcLinealNoLineal	0.767	0.669	3.621	3.836	13.376	15.272	2.811	3.011	0.748	0.658	0.085	0.095	0.007	0.009	0.066	0.072	0.685	0.576	0.087	0.101	0.008	0.011	0.068	0.075												
AWVelAngularNoLineal	0.690	0.463	4.156	4.970	17.564	25.156	3.282	4.044	0.676	0.433	0.096	0.124	0.009	0.016	0.075	0.099	0.577	0.336	0.100	0.126	0.010	0.016	0.078	0.102												
AWNoLineal	0.821	0.678	3.150	3.863	10.166	15.457	2.448	2.968	0.812	0.753	0.074	0.082	0.006	0.007	0.058	0.062	0.734	0.704	0.079	0.083	0.006	0.007	0.061	0.064												
AWL	0.861	0.723	2.789	3.525	7.892	12.813	2.083	2.649	0.854	0.772	0.065	0.076	0.004	0.006	0.049	0.059	0.810	0.711	0.066	0.081	0.004	0.007	0.051	0.062												
AWLAcLinealEspacial	0.776	0.612	3.538	4.065	12.629	17.456	2.670	3.023	0.836	0.746	0.069	0.082	0.005	0.007	0.053	0.064	0.792	0.705	0.070	0.083	0.005	0.007	0.054	0.063												
AWLVelAngularEspacial	0.644	0.484	4.458	4.832	20.644	25.283	3.071	3.672	0.707	0.603	0.091	0.104	0.009	0.011	0.068	0.085	0.654	0.533	0.089	0.105	0.008	0.011	0.066	0.083												
AWLEspacial	0.855	0.714	2.852	3.627	8.215	13.996	2.121	2.770	0.835	0.770	0.068	0.078	0.005	0.006	0.049	0.061	0.786	0.729	0.069	0.080	0.005	0.007	0.052	0.063												
AWLAcLinealNoLineal	0.726	0.496	3.939	4.727	15.794	23.411	3.001	3.672	0.669	0.624	0.098	0.101	0.010	0.010	0.075	0.079	0.587	0.529	0.098	0.106	0.010	0.012	0.076	0.083												
AWLVelAngularNoLineal	0.545	0.404	5.011	5.234	25.462	28.018	3.930	4.232	0.498	0.376	0.119	0.131	0.014	0.018	0.093	0.105	0.430	0.324	0.114	0.127	0.013	0.017	0.089	0.102												
AWLNoLineal	0.724	0.474	3.913	4.791	15.573	23.355	2.994	3.792	0.727	0.670	0.088	0.094	0.008	0.009	0.066	0.075	0.641	0.574	0.090	0.100	0.008	0.010	0.069	0.075												
AWR	0.879	0.715	2.566	3.634	6.963	14.297	1.939	2.706	0.863	0.793	0.063	0.074	0.004	0.006	0.047	0.057	0.811	0.785	0.067	0.070	0.005	0.005	0.052	0.055												
AWRAcLinealEspacial	0.811	0.598	3.163	4.325	10.845	20.712	2.293	3.190	0.735	0.643	0.085	0.097	0.007	0.010	0.061	0.071	0.718	0.690	0.079	0.084	0.007	0.008	0.057	0.061												
AWRVelAngularEspacial	0.632	0.561	4.581	4.509	20.860	30.294	3.623	4.682	0.522	0.522	0.097	0.115	0.010	0.013	0.073	0.091	0.567	0.433	0.102	0.112	0.011	0.013	0.078	0.088												
AWREspacial	0.834	0.692	2.972	3.774	9.605	15.243	2.060	2.981	0.854	0.754	0.065	0.081	0.004	0.007	0.048	0.061	0.808	0.744	0.067	0.075	0.005	0.006	0.051	0.055												
AWRAcLinealNoLineal	0.675	0.453	4.280	5.018	18.665	26.867	3.285	3.906	0.669	0.546	0.098	0.111	0.010	0.012	0.077	0.088	0.625	0.572	0.095	0.100	0.009	0.010	0.074	0.079												
AWRVelAngularNoLineal	0.554	0.295	5.008	5.743	25.376	34.244	3.920	4.611	0.540	0.221	0.115	0.146	0.014	0.022	0.089	0.117	0.359	0.195	0.123	0.137	0.016	0.019	0.094	0.109												
AWRNoLineal	0.768	0.536	3.594	4.582	13.117	22.366	2.757	3.536	0.732	0.616	0.088	0.101	0.008	0.011	0.068	0.077	0.660	0.580	0.090	0.099	0.008	0.010	0.070	0.077												