



**UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA**

**FACULTAD DE INGENIERÍA**

**PROYECTO DE INVESTIGACIÓN:**

**ESTIMACIÓN DE LA VELOCIDAD DE MARCHA EN ADULTOS MAYORES MEDIANTE  
TÉCNICAS DE APRENDIZAJE AUTOMÁTICO Y REGRESIÓN LINEAL**

**PREVIO A LA INVESTIDURA DEL TÍTULO DE  
INGENIERÍA EN BIOMÉDICA**

**SUSTENTADO POR:**

**22041056 FÁTIMA ALEJANDRA ALVARADO RODRÍGUEZ**

**ASESOR: KARLA MIRIAM REYES LEIVA Y ANTONIO COBO SÁNCHEZ DE ROJAS**

**MADRID, ESPAÑA**

**DICIEMBRE, 2024**

## DEDICATORIA

A mis papitos, mi mayor ejemplo a seguir. Gracias por creer en mí, incluso más de lo que yo misma lo hice. Por darme la oportunidad de soñar, pero consciente de que ningún sueño es tan grande si se trabaja por él. Por enseñarme a mantener los pies en la tierra para ser fuerte y valiente, pero también para impulsarme a volar, aunque eso signifique estar a miles de kilómetros y no vernos durante meses. Gracias por sostenerme cuando no podía, levantarme cuando me caí e impulsarme cuando me faltaban fuerzas. Espero que algún día se sientan tan orgullosos de ser mis papás como yo lo estoy de ser su hija. A mi "bojotito", por reconstruir lo que se rompió en mi con un "te amo mana". A ese niño en dibujo técnico quien, por ayudarme a terminar una pieza, se convirtió en una fundamental en mi vida. A mis "butuquitos", Gorda y Enano.

Gracias por tanto. Los amo, son la salsita de mi pollo chuco.

## **AGRADECIMIENTOS**

A Diosito, gracias por guiarme y protegerme en esta aventura por descubrir mi camino. Pese a que no siempre tomo las mejores decisiones, me has permitido no solo soñar, sino vivir más de lo que algún día imaginé. Gracias por permitirme crecer en un hogar lleno de amor incondicional, donde todo es posible y si se cuestiona, se hace con miedo. Pero, sobre todo, gracias por permitirme ser, estar y demostrarle a esa fatimita de 5 años que todo es posible, por más loco que parezca; desde soñar con graduarse de "la unisunidad" hasta irse al otro lado del mundo a estudiar.

A mi madre, Brenda Rodríguez, una mujer inexplicable: amiga leal, esposa devota, hermana e hija amorosa; simplemente de otro planeta. Gracias por darle color a mis días grises con tu sonrisa, paz a mi corazón con un abrazo y tranquilidad a mi mente con tus palabras. Admiro tu capacidad para identificar que algo está mal con una sola mirada y esa habilidad de cambiarlo encontrando el lado positivo de la situación, habilidad que dije odiar, pero siempre he admirado.

A mi padre, Christian Alvarado, mi mayor ejemplo de resiliencia, perseverancia y bondad. Siempre he juzgado tu "corazón de pollo", pero esa es tu esencia, una coraza fuerte pero dulce y noble por dentro. Gracias por siempre priorizar mis necesidades, aun si para ello debías trabajar en turnos de quince horas por semanas, lo que no te impidió estar siempre presente. Gracias terroncito de azúcar, hasta el infinito y más allá.

A mi hermanito, Eitan Isaac, por doblegar mis dolencias con su hermoso corazón y enseñarme a perdonar. A mi hermanote, Nixon Rodríguez, por desde siempre enseñarme "lo difícil que es la vida" y ser uno de mis ejemplos a seguir. Gracias por siempre motivarme a luchar por mis sueños y celebrar mis logros con un "era tu responsabilidad". Te quiero, cactus favorito. A mis tías, Tania y Mariely Rodríguez, por enseñarme a ser fuerte, valiente y siempre motivarme a valerme por mí misma.

A Gloria Emilia Zapata Cáceres, mi chicle, mejor amiga y compañera, por reír y llorar conmigo desde el colegio hasta el otro lado del mundo. Por tu cariño, confianza, paciencia y creer en mí. Gracias a Dios hemos tenido la oportunidad de vivir un poco de lo que siempre soñamos y espero podamos continuar así.

A Carlos Aldair Chávez Quiñonez, compañero, amigo y mi persona especial, gracias por tu dedicación, paciencia para estudiar y explicarme por horas, por desvelarte a lo largo de estos años y ser mi constante apoyo. Admiro tu capacidad de ver lo bueno en lo malo, y estaré infinitamente agradecida por lo que has

hecho por mí no solo en este proyecto y estos años de carrera, sino también por enseñarme a ser una mejor persona.

A la Dra. Karla Miriam Reyes Leiva, por marcar la vida de esa niña recién egresada del colegio en una charla de Biomédica. Su apoyo, paciencia, confianza y motivación han sido esenciales en este camino.

Al Dr. Antonio Cobo Sánchez de Rojas, quien me dio la oportunidad de vivir uno de mis más grandes sueños. Siempre estaré agradecida por abrirme las puertas del Centro de Tecnología Biomédica (CTB), por su constante apoyo, paciencia y todos los conocimientos compartidos. De igual forma a todo el equipo del laboratorio de envejecimiento por su colaboración, amabilidad, cariño y por los jueves de compartir tapas.

A la ingeniera Reyna Valle, por desarrollar en mi autoexigencia y formarme no solo como profesional sino también a nivel interpersonal. Gracias por siempre, pese a tener la agenda ajustada, encontrar un hueco para resolver las crisis existenciales de las tres mosqueteras.

A docentes que llevaré por siempre con mucho cariño en mi corazón; Ingeniero Orlando Aguiluz, por enseñarme a dar más de lo que creo ser posible, por regalarme su amistad y siempre aconsejarme con mucho cariño. Ingeniero Stefany García, por su dedicación y paciencia al explicarme 10 veces lo mismo si fuese necesario, por siempre estar dispuesta a ayudar en lo que sea a la hora que sea.

A Nataly Carias, amiga desde primer año a quien admiro mucho por su perseverancia, dedicación y sentido del humor. Valeria Herrera, compañera de carrera y de crisis existenciales. Infinitas gracias a ambas por su constante apoyo, por siempre exigirme más y apoyarme en cada decisión, incluso las erróneas.

A mis compañeros Jorge, Héctor, Willian, Gavarrete, Majo, Cristóbal, José, Carlitos, Jeni, Diego, gracias por las risas, lágrimas y desvelos compartidos a lo largo de estos años.

Un pedacito de este logro es para cada uno de los antes mencionados, consciente que en determinados momentos de esta trayectoria fui una persona difícil de acompañar, gracias por quedarse. De igual forma agradezco a todos aquellos que aportaron con un consejo, una palabra de aliento o buenos deseos, este es uno de muchos logros si Dios lo permite.

## EPÍGRAFE

*"Sventalízalo y te pertenecerá".*

- **CHRISTIAN ALVARADO**

## RESUMEN EJECUTIVO

La fragilidad y el deterioro funcional aumentan significativamente el riesgo de dependencia, caídas y disminución de la calidad de vida en adultos mayores. La velocidad de la marcha es un indicador clave del deterioro funcional y una herramienta valiosa para la detección temprana de la fragilidad. Este estudio tiene como objetivo desarrollar y comparar algoritmos basados en sensores inerciales para la estimación de la velocidad de la marcha, utilizando técnicas de aprendizaje automático y regresión lineal. Se analizaron datos de los proyectos ActiveUP y MOTIVA en un estudio transversal para validar modelos predictivos en una población geriátrica. El rendimiento de los modelos se ha analizado la validez (correlación), la concordancia (SEM y Bland-Altman) y la fiabilidad (ICC). Se han explorado diferentes modelos de regresión para el último paso del algoritmo de Mueller. El modelo SVM mostró el mejor equilibrio en concordancia (SEM = 0.07, MDD = 0.18), mientras que el modelo RF presentó la mayor validez (R = 0.98, IC 95%: 0.98 - 0.99). Estos hallazgos resaltan el potencial de la tecnología de sensores portátiles y el aprendizaje automático para una estimación fiable de la marcha, apoyando la detección temprana de la fragilidad y fomentando estrategias de atención preventiva en adultos mayores. Sin embargo, el tamaño limitado de la muestra subraya la necesidad de realizar más estudios para garantizar la aplicabilidad clínica y una generalización más amplia.

Palabras clave — envejecimiento saludable, estimación de la velocidad de la marcha, IMUs, regresión lineal, aprendizaje automático.

## **ABSTRACT**

Frailty and functional decline significantly increase the risk of dependence, falls, and reduced life quality in older adults. Gait speed is a critical indicator of functional impairment and a valuable tool for the early frailty detection. This study aims to develop and compare inertial sensor-based algorithms for gait speed estimation, employing machine learning and linear regression techniques. Data from the ActiveUP and MOTIVA projects were analyzed in a cross-sectional study to validate predictive models in a geriatric population. Model performance was assessed through correlation analysis, intra-class correlation (ICC), and Bland-Altman. Four models were evaluated, including the adapted Mueller algorithm, linear regression (MOTIVA), support vector machines (SVM), and random forests (RF). The SVM model demonstrated the best balance between validity and reliability (SEM = 0.07, MDD = 0.18), while the RF model showed the highest validity (R = 0.98, 95% CI: 0.98 - 0.99). These findings highlight the potential of wearable sensor technology and machine learning for reliable gait estimation, supporting the early detection of frailty and promoting preventive care strategies in elderly adults. However, the limited sample size highlights the need for further studies to ensure clinical applicability and broader generalization.

Keywords — healthy aging, gait speed estimation, IMUs, linear regression, machine learning.

# ÍNDICE DE CONTENIDO

<b>I.</b>	<b>INTRODUCCIÓN</b> .....	<b>1</b>
<b>II.</b>	<b>ESTADO DEL ARTE</b> .....	<b>3</b>
<b>2.1.</b>	<b>ANTECEDENTES</b> .....	<b>3</b>
<b>2.1.1.</b>	<b>Perspectiva global del envejecimiento saludable</b> .....	<b>6</b>
<b>2.1.2.</b>	<b>Envejecimiento Saludable</b> .....	<b>7</b>
2.1.2.1	Capacidad funcional e intrínseca .....	9
2.1.2.2	Fragilidad .....	10
2.1.2.3	Velocidad de la marcha .....	12
<b>2.1.3.</b>	<b>Enfoque tecnológico</b> .....	<b>13</b>
2.1.3.1.	Sensores inerciales .....	13
2.1.3.2.	Procesamiento de señales inerciales .....	16
<b>2.1.4.</b>	<b>Origen de investigación</b> .....	<b>19</b>
<b>2.1.4.1.</b>	<b>Detección Patrones en la marcha</b> .....	<b>25</b>
<b>2.1.4.2.</b>	<b>Estimación de la velocidad de la marcha</b> .....	<b>29</b>
<b>2.2.</b>	<b>PROBLEMÁTICA</b> .....	<b>34</b>
<b>2.3.</b>	<b>IMAGEN INTEGRADORA</b> .....	<b>37</b>
<b>2.4.</b>	<b>CUADRO DE LIMITACIONES</b> .....	<b>38</b>
<b>III.</b>	<b>OBJETIVOS</b> .....	<b>47</b>
<b>3.1.</b>	<b>OBJETIVO GENERAL</b> .....	<b>47</b>
<b>3.2.</b>	<b>OBJETIVOS ESPECÍFICOS</b> .....	<b>47</b>
<b>IV.</b>	<b>MÉTODOS</b> .....	<b>49</b>
<b>4.1.</b>	<b>ENFOQUE</b> .....	<b>49</b>
<b>4.2.</b>	<b>VARIABLES DE INVESTIGACIÓN</b> .....	<b>50</b>
4.2.1.	Variables Dependientes .....	50
4.2.1.1.	Deteccion de Patrones en marcha .....	51
4.2.1.2.	Estimación Velocidad De La Marcha .....	51
4.2.2.	Variables Independientes .....	51
4.2.2.1.	Deteccion de Patrones en marcha .....	51
4.2.2.2.	Estimación Velocidad De La Marcha .....	52

<b>4. 3.</b>	<b>INSTRUMENTOS Y TÉCNICAS APLICADOS .....</b>	<b>52</b>
<b>4. 4.</b>	<b>POBLACIÓN .....</b>	<b>56</b>
4.4.1.	Deteccion de Patrones en marcha .....	56
4.4.2.	Estimación Velocidad De La Marcha .....	56
<b>4. 5.</b>	<b>MÉTODO DE ESTUDIO .....</b>	<b>58</b>
4.5.1.	Deteccion de Patrones en marcha .....	58
4.5.2.	Estimación Velocidad De La Marcha .....	59
4.5.2.1.	Revisión de datos .....	60
4.5.2.2.	Preprocesamiento .....	61
4.5.2.3.	Desarrollo y entrenamiento de modelos .....	61
4.5.2.3.1.	Comparativa Mueller y su adaptación .....	62
4.5.2.3.1.1.	Detección de bouts .....	62
4.5.2.3.2.	Regresión Lineal con Mueller .....	63
4.5.2.3.3.	Regresión Lineal con MOTIVA .....	64
4.5.2.3.4.	Árboles de Regresión (Random Forest - RF) .....	64
4.5.2.3.5.	Máquina de soporte vectorial (Support Vector Machine SVM) .....	64
4.5.2.4.	Evaluación de los algoritmos .....	65
<b>4. 6.</b>	<b>METODOLOGÍA DE VALIDACIÓN .....</b>	<b>66</b>
<b>4. 7.</b>	<b>CRONOGRAMA DE ACTIVIDADES.....</b>	<b>69</b>
<b>4. 8.</b>	<b>OPERACIONES DE LAS VARIABLES .....</b>	<b>71</b>
<b>4. 9.</b>	<b>MATRIZ METODOLÓGICA .....</b>	<b>73</b>
<b>V.</b>	<b>RESULTADOS Y ANÁLISIS .....</b>	<b>75</b>
5.1.	Detección de patrones característicos en la marcha .....	75
5.2.	Estimación de la velocidad de la marcha .....	78
<b>VI.</b>	<b>DISCUSIÓN .....</b>	<b>90</b>
<b>VII.</b>	<b>CONCLUSIONES.....</b>	<b>92</b>
7. 1.	CONCLUSIÓN GENERAL .....	92
7. 2.	CONCLUSIONES PARCIALES .....	92
<b>VIII.</b>	<b>LIMITACIONES Y RECOMENDACIONES .....</b>	<b>95</b>
<b>IX.</b>	<b>REFERENCIAS BIBLIOGRÁFICAS.....</b>	<b>97</b>
<b>X.</b>	<b>ANEXOS .....</b>	<b>124</b>

## ÍNDICE DE ILUSTRACIONES

Ilustración 1 Población mayor a nivel mundial. ....	4
Ilustración 2 Cascada de disminución funcional. ....	8
Ilustración 3 Referencia para señales registradas en el centro de masa para los tres ejes. ....	15
Ilustración 4 Etapas procesamiento de señales inerciales. ....	17
Ilustración 5 Proyecto Positive. ....	20
Ilustración 6 Primer prototipo de sensor ....	21
Ilustración 7 Arquitectura de computación del sistema IoT para la recopilación de datos en la vivienda. ....	21
Ilustración 8 Sistema ActiveUP. ....	22
Ilustración 9 Diseño final de dispositivo. ....	22
Ilustración 10 Rueda B de Vivifrail. ....	23
Ilustración 11 Identificación de sensores para prueba SPPB - MOTIVA. ....	24
Ilustración 12 Imagen integradora. ....	37
Ilustración 13 Variables de investigación. ....	52
Ilustración 15 SPPB Prueba de velocidad de la marcha en 3 metros. ....	57
Ilustración 16 Metodología propuesta estudio detección patrones en la marcha. ....	59
Ilustración 17 Método de estudio estimación de la velocidad de la marcha. ....	60
Ilustración 18 Revisión de datos - detección de bouts. ....	60
Ilustración 19 archivos resultantes de preprocesamiento. ....	63
Ilustración 20 Resumen método de estudio estimación de la velocidad de la marcha. ....	65
Ilustración 21 Cronograma de actividades primer parcial. ....	69
Ilustración 22 Cronograma de actividades segundo parcial. ....	70
Ilustración 23 Población ActiveUP. ....	76
Ilustración 24 Incidencia anomalías datos ActiveUP. ....	77
Ilustración 25 Comparación velocidades. ....	82
Ilustración 26 Velocidades por modelo. ....	84
Ilustración 27 Comportamiento de cada modelo. ....	85
Ilustración 28 Distribución de predicciones. ....	87

## ÍNDICE DE TABLAS

Tabla 1 Limitaciones Estudio Detección Patrones de Marcha. ....	38
Tabla 2 Limitaciones Técnicas Estudio Detección Patrones de Marcha. ....	40
Tabla 3 Limitaciones Estudio Estimación De La Velocidad De La Marcha. ....	42
Tabla 4 Limitaciones Técnicas ....	44
Tabla 5 Enfoque estudio detección patrones de la marcha. ....	50
Tabla 6 Enfoque estudio estimación velocidad de la marcha. ....	50
Tabla 7 Operacionalización de variables. ....	71
Tabla 8 Matriz metodológica. ....	73
Tabla 9 Métricas Mueller y su adaptación. ....	79
Tabla 10 Bouts detectados. ....	80
Tabla 11 Sensibilidad por longitud de bout. ....	80
Tabla 12 Promedio de sensibilidad y precisión según la longitud de bout. ....	81
Tabla 13 Validez de Modelos ....	82
Tabla 14 Concordancia entre modelos. ....	83
Tabla 15 Fiabilidad de modelos. ....	86

## ÍNDICE DE ANEXOS

Anexo 1 Sensor Vestible ActiveUP .....	124
Anexo 2. Dispositivo Final ActiveUP y MOTIVA.....	124
Anexo 3 Comparación Velocidades por Bouts - Paciente 0001.....	125
Anexo 4 Comparación Velocidades por Bouts - Paciente 0002.....	125
Anexo 5 Comparación Velocidades por Bouts - Paciente 0003.....	126
Anexo 6 Comparación Velocidades por Bouts - Paciente 0004.....	126
Anexo 7 Comparación Velocidades por Bouts - Paciente 0005.....	127
Anexo 8 Comparación Velocidades por Bouts - Paciente 0007.....	127
Anexo 9 Comparación Velocidades por Bouts - Paciente 0009.....	128
Anexo 10 Comparación Velocidades por Bouts - Paciente 5001.....	128
Anexo 11 Comparación Velocidades por Bouts - Paciente 5002.....	129
Anexo 12 Comparación Velocidades por Bouts - Paciente 5003.....	129
Anexo 13 Comparación Velocidades por Bouts - Paciente 5004.....	130
Anexo 14 Comparación Velocidades por Bouts - Paciente 5006.....	130
Anexo 15 Comparación Velocidades por Bouts - Paciente 5007.....	131
Anexo 16 Comparación Velocidades por Bouts - Paciente 5008.....	131
Anexo 17 Registro de 1 Bout Paciente 5009.....	132
Anexo 18 Comparación Velocidades por Bouts - Paciente 5009.....	132
Anexo 19 Comparación Velocidades por Bouts - Paciente 5010.....	132
Anexo 20 Comparación Velocidades por Bouts - Paciente 5011.....	133
Anexo 21 Comparación Velocidades por Bouts - Paciente 5012.....	133
Anexo 22 Comparación Velocidades por Bouts - Paciente 5013.....	134
Anexo 23 Comparación Velocidades por Bouts - Paciente 5014.....	134
Anexo 24 Comparación Velocidades por Bouts - Paciente 5015.....	135
Anexo 25 Comparación Velocidades por Bouts - Paciente 5016.....	135
Anexo 26 Comparación Velocidades por Bouts - Paciente 5017.....	136
Anexo 27 Comparación Velocidades por Bouts - Paciente 5018.....	136
Anexo 28 Comparación Velocidades por Bouts - Paciente 5019.....	137
Anexo 29 Comparación Velocidades por Bouts - Paciente 5020.....	137
Anexo 30 Comparación Velocidades por Bouts - Paciente 5021.....	138
Anexo 31 Comparación Velocidades por Bouts - Paciente 5022.....	138
Anexo 33 Comparación Velocidades por Bouts - Paciente 5023.....	139
Anexo 32 Comparación Velocidades por Bouts - Paciente 5024.....	139
Anexo 34 Comparación Velocidades por Bouts - Paciente 5025.....	140

## LISTA DE SIGLAS

<b>ABVD</b>	Actividades Básicas de la Vida Diaria
<b>ActiveUP</b>	Envejecimiento Activo con Monitorización Personalizada y No obstructiva
<b>AIVD</b>	Actividades Instrumentales de la Vida Diaria
<b>CTB</b>	Centro de Tecnología Biomédica
<b>ICC</b>	Coefficiente de Correlación Intraclase
<b>IMUs</b>	Unidades de Medición Inercial (Inertial Measurement Units)
<b>INE</b>	Instituto Nacional de Estadística (España)
<b>IoT</b>	Internet de las Cosas (Internet of Things)
<b>MOTIVA</b>	Ecosistema Computacional que combina Apoyo Emocional y Evaluación Funcional
<b>ONU</b>	Organización de las Naciones Unidas
<b>OMS</b>	Organización Mundial de la Salud
<b>RTC</b>	Real Time Clock (Reloj en Tiempo Real)
<b>RF</b>	Bosques Aleatorios (Random Forest)
<b>SPPB</b>	Short Physical Performance Battery
<b>SVM</b>	Máquina de Soporte Vectorial (Support Vector Machine)
<b>TVM</b>	Test de Velocidad de la Marcha
<b>VM</b>	Velocidad de Marcha

## GLOSARIO

**Fragilidad** – “Estado de mayor vulnerabilidad a resultados adversos debido a una reducción en la capacidad de responder a factores estresantes” (Fried et al., 2001).

**Fenotipo de Fried** – “Desarrollado por Fried et al. (2001), este modelo identifica la fragilidad basada en cinco criterios físicos: pérdida de peso involuntaria, agotamiento, baja actividad física, velocidad de marcha lenta y debilidad” (M. Li et al., 2020).

**Deterioro Funcional** – “Es la disminución de la capacidad de una persona para realizar actividades de la vida diaria (AVD) de manera independiente, lo que puede incluir tareas básicas como vestirse, bañarse, comer y moverse” (Ocampo-Chaparro et al., 2021).

**Capacidad funcional** – “Habilidad de una persona para realizar actividades de la vida diaria, lo que incluye tanto actividades básicas como complejas, crucial para mantener la independencia y la calidad de vida en la vejez” (Calvo Higuera & Gómez Carrillo, 2023).

**Capacidad Intrínseca** – “Combinación de capacidades físicas, mentales y psicosociales que permiten a una persona llevar a cabo sus actividades cotidianas y participar en la vida social” (Ribera Casado, 2021).

**Análisis de la marcha** – “Se centra en la observación y medición de diversos parámetros que caracterizan el movimiento durante la marcha” (Buran Sevik et al., 2024).

**FRAIL** – “Escala diagnóstica utilizada para identificar individuos en riesgo de progresar hacia la discapacidad” (Bertolazzi et al., 2024).

**ActiveUP** – “Proyecto que propone un sistema de monitorización domiciliar mediante un sensor inercial acoplado al cinturón que registra continuamente los movimientos sin interferir en las actividades diarias” Memoria Proyecto ActiveUP.

**MOTIVA** – “Proyecto que busca fomentar la independencia funcional de adultos mayores mediante un ecosistema computacional motivacional” Memoria Proyecto MOTIVA.

**Sensores inerciales (IMUs)** – “Dispositivos electrónicos que permiten medir la aceleración y la rotación de un objeto en movimiento, proporcionando información crucial sobre su posición y orientación en el espacio” (Dugarte Jerez et al., 2024a).

**Velocidad de la marcha** – “Indicador clave del deterioro funcional” (Kobsar et al., 2020), “refleja el funcionamiento de múltiples sistemas en el cuerpo humano; el sistema musculoesquelético, nervioso, cardiovascular, respiratorio y la capacidad sensorial” (Santafé Caiza & Latta Sanchez, 2024).

**Autoencoders** – “Tipo de red neuronal de aprendizaje profundo, diseñadas para reducir la dimensionalidad y detectar anomalías. Su estructura se compone de un codificador y un decodificador, que comprimen y luego reconstruyen la información, permitiendo extraer características intrínsecas y relevantes de los datos” (Bank et al., 2020).

**Regresión Lineal** – “Técnica estadística utilizada para modelar la relación entre una variable dependiente y una o más variables independientes, se basa en la suposición de que existe una relación lineal entre las variables, es decir, que el cambio en la variable dependiente puede representarse como una combinación lineal de las variables independientes más un término de error” (Roustaei, 2024).

**Aprendizaje Automático (Machine Learning)** – “Subdisciplina de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos que permiten a las máquinas aprender de los datos y mejorar su rendimiento en tareas específicas sin ser programadas explícitamente para cada una de ellas. Se basa en la idea de que, a través de la exposición a grandes volúmenes de datos, los sistemas pueden identificar patrones y hacer predicciones o decisiones basadas en la información aprendida” (Quiroz et al., 2022).

**SPPB** – “Es una herramienta ampliamente utilizada para evaluar el rendimiento físico en adultos mayores compuesto por tres pruebas clave: equilibrio, tiempo para levantarse de una silla cinco veces, y velocidad de la marcha en un trayecto de 3 a 4 metros” (Hanada et al., 2020).

## I. INTRODUCCIÓN

El envejecimiento poblacional representa un desafío crítico para los sistemas de salud, particularmente en la monitorización de problemas asociados con la movilidad y el deterioro funcional, entendido como la reducción de la capacidad de una persona para llevar a cabo actividades de la vida diaria (Ocampo-Chaparro et al., 2021). Según el informe de Perspectivas Demográficas del Envejecimiento Poblacional en la Región de las Américas emitido por la Organización Mundial De La Salud (2023) se estima que para 2030, aproximadamente 1 de cada 6 personas en el mundo tendrá más de 60 años, esto representa un aumento significativo en la proporción de personas mayores. El Informe Mundial sobre el Envejecimiento y la Salud, emitido en octubre del 2015 por la OMS; destaca que la asistencia y el cuidado de los adultos mayores debe centrarse en mantener la autonomía funcional, en lugar de tratar o curar una enfermedad.

Partiendo de dicha premisa, el Laboratorio de Envejecimiento Saludable del Centro de Tecnología Biomédica de la Universidad Politécnica de Madrid se centra en abordar uno de los principales problemas relacionados con la salud de las personas mayores, la discapacidad; y su principal factor de riesgo, la fragilidad. Síndrome, caracterizado por una disminución de la fuerza física, resistencia y en la capacidad de los adultos mayores para enfrentar factores estresantes, incrementa considerablemente el riesgo de dependencia, hospitalización y mortalidad si no es detectado a tiempo (Fried et al., 2001). Se estima que afecta entre el 5% y el 17% de los mayores (Eidam et al., 2024), lo que destaca la necesidad de una detección temprana para facilitar intervenciones preventivas.

En España, herramientas diagnósticas como la escala de FRAIL y el fenotipo de Fried han permitido identificar a individuos en riesgo de progresar hacia la discapacidad (Bertolazzi et al., 2024). La capacidad funcional, definida como las habilidades necesarias para realizar actividades diarias (Beard et al., 2022), y la velocidad de la marcha se han consolidado como un indicador clave del deterioro funcional (Kobsar et al., 2020). Dado que refleja el funcionamiento de múltiples sistemas en el cuerpo humano; el sistema musculoesquelético, nervioso, cardiovascular, respiratorio y la capacidad sensorial (Santafé Caiza & Latta Sanchez, 2024). Por esta razón, una marcha lenta puede indicar debilidad muscular, problemas de equilibrio o disminución en la

capacidad aeróbica, factores que influyen directamente en la fragilidad, según el modelo fenotípico de Linda Fried (Latta Sánchez et al., 2022; Villalba Mora et al., 2015).

El análisis de la marcha, realizado tanto en entornos controlados como no controlados, ofrece una comprensión integral del estado funcional del paciente (Maity et al., 2024). Los entornos controlados permiten mediciones estandarizadas, mientras que los no controlados, como el hogar, revelan patrones más representativos de la vida diaria (Dias et al., 2023) o patrones que podrían no ser evidentes en un entorno de laboratorio (Xuan et al., 2023). Por lo tanto, el análisis de la marcha en ambos tipos de entornos es crucial para una evaluación integral de la funcionalidad y la salud del paciente, así como para el desarrollo de intervenciones personalizadas y efectivas (Sethi et al., 2024).

Las tecnologías portátiles, como sensores inerciales (IMUs) y aplicaciones móviles, han demostrado ser herramientas valiosas para la evaluación de la marcha en escenarios cotidianos (Maas et al., 2024). En este contexto, el proyecto ActiveUP propone un sistema de monitorización domiciliaria mediante un sensor inercial acoplado al cinturón que registra continuamente los movimientos sin interferir en las actividades diarias, mientras que el proyecto MOTIVA busca fomentar la independencia funcional de adultos mayores mediante un ecosistema computacional motivacional. Ambos proyectos se centran en la estimación precisa de parámetros espaciotemporales y en la detección temprana de patrones de deterioro funcional, con el objetivo de realizar evaluaciones funcionales continuas y no intrusivas (Liu et al., 2022).

Este estudio tiene como objetivo desarrollar y comparar algoritmos basados en sensores inerciales para estimar la velocidad de la marcha, empleando técnicas de aprendizaje automático y regresión lineal, con el fin de optimizar la detección del deterioro funcional en personas mayores. Para ello, se utilizarán series temporales obtenidas de los proyectos ActiveUP y MOTIVA.

El presente documento se organiza en siete capítulos. El primero analiza el estado del arte, proporcionando los fundamentos teóricos y contexto del problema. El segundo capítulo detalla los objetivos. Seguidamente, en el tercero, se detalla la metodología a emplear para alcanzar dichos objetivos. Los resultados obtenidos se presentan en el cuarto capítulo y son analizados en el quinto. Finalmente, los capítulos seis y siete contienen las conclusiones, recomendaciones y propuestas para futuras investigaciones.

## **II. ESTADO DEL ARTE**

En la actualidad el envejecimiento es contemplado como uno de los temas más relevantes en a nivel internacional. Esto es debido a que en las últimas cinco décadas los avances en las ciencias médicas, las acciones encaminadas a la salud pública y, de manera general, al progreso en el desarrollo económico han permitido que la esperanza de vida se incremente (Gálvez, E., Cruz, P. y Cruz, G., 2022). Es en este contexto, que la Organización de las Naciones Unidas (ONU), en concordancia con los Objetivos del Desarrollo Sostenible, ha promulgado la Década del Envejecimiento Saludable (2021-2030) (Keating et al., 2021). Cuya finalidad es hacer un llamado a todas las naciones en el mundo, para que estructuren planes y estrategias encaminadas para edificar sociedades más incluyentes y receptivas para todos los grupos de edad (Comisión Económica para América Latina y el Caribe, 2021)

El envejecimiento a nivel mundial representa una problemática creciente, pues una proporción significativa de la población alcanzará edades avanzadas en las próximas décadas, lo que incrementa la demanda de soluciones efectivas para garantizar una calidad de vida óptima y un envejecimiento saludable. La marcha se considera un indicador clave en la evaluación de la salud en personas mayores, refleja no solo el estado funcional y la movilidad, sino también posibles riesgos asociados al deterioro físico y cognitivo.

A continuación, se presenta el estado actual de la temática los avances tecnológicos en el monitoreo de la salud. Se aborda, por un lado, la detección de patrones de marcha asociados al deterioro funcional, utilizando autoencoders y aprendizaje no supervisado, y por otro, la estimación precisa de la velocidad de la marcha, mediante modelos de regresión y aprendizaje automático con IMUs. Además, se sintetiza la problemática por ser abordada, una visión panorámica a través de una imagen integradora y se condensa información referente a las limitaciones de cada estudio en una tabla.

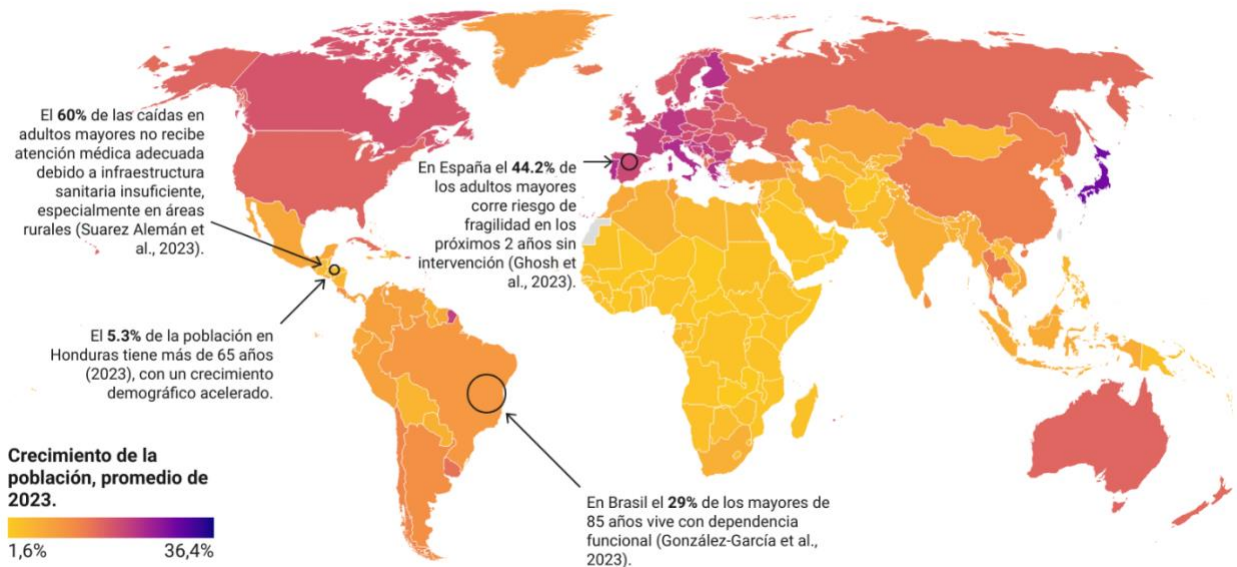
### **2. 1. ANTECEDENTES**

La vejez se considera desde un punto de vista antropológico como una noción de carácter inconcreta que hace referencia a un periodo de la vida de una persona (Cantú-Martínez, 2022). Por lo que es un fenómeno global que presenta numerosos desafíos en términos de salud

funcional, especialmente con relación en la movilidad de los adultos mayores. Desde la configuración biológica, a medida que las personas evolucionan, experimentan una serie de cambios que con frecuencia es en la disminución del aspecto funcional y por ende el aspecto fisiológico y de capacidad mental. Estos cambios incluyen la disminución de la masa muscular, la reducción de la densidad ósea y el deterioro de la función cardiovascular, lo que aumenta el riesgo de caídas y lesiones (Betances Reinoso et al., 2020). Además, los problemas de equilibrio son cada vez más comunes en esta población. La investigación de Reinoso et al. (2020) concluyó que, ante ello, los adultos mayores tienden a desarrollar estrategias compensatorias durante la marcha, como acortar los pasos y desacelerar, para mantener la estabilidad.

Según la Organización Mundial de la Salud (OMS), se estima que para el año 2050, la población de personas mayores de 60 años alcanzará los 2 mil millones, lo que representa un aumento del 200% en comparación con 2019 (Song et al., 2020). Este crecimiento demográfico, tal como se muestra en la Ilustración 1, plantea preocupaciones sobre el aumento de enfermedades crónicas, discapacidades y la necesidad de servicios de salud adecuados. Tomando lo mencionado en consideración, también representa un desafío significativo para la salud pública, especialmente en lo que respecta a la calidad de vida de los adultos mayores.

### **Población mundial de 65 años de edad o más**



**Ilustración 1 Población mayor a nivel mundial.**

Fuente: Elaboración Propia. Basado en Estimaciones del Banco Mundial Previsiones Demográficas Mundiales de la División de Población de las Naciones Unidas.

Un estudio realizado en el Reino Unido destaca que el 25% de los adultos mayores experimentan problemas de movilidad que afectan su capacidad para realizar actividades diarias (Elsayed et al., 2024). En el análisis de datos de la Encuesta Nacional de Salud en Estados Unidos, se encontró que el 30% de los adultos mayores reportaron limitaciones en su movilidad, lo que subraya la necesidad de intervenciones efectivas que aborden estos desafíos (Chia et al., 2023). Estos problemas de movilidad están asociados con un mayor riesgo de caídas, que son una de las principales causas de lesiones y hospitalizaciones en esta población (Qin et al., 2021).

En Ecuador, estudio reveló que el 60% de los adultos mayores presentaban sobrepeso u obesidad, condiciones que están asociadas con un mayor riesgo de enfermedades crónicas como la diabetes y enfermedades cardiovasculares (Barahona et al., 2021). Estas condiciones no solo afectan la salud general, sino que también impactan directamente en la movilidad y la capacidad funcional de los adultos mayores. La obesidad, por ejemplo, puede provocar una disminución en la velocidad de marcha y un aumento en la fatiga, lo que limita aún más la actividad física y la independencia (Reinoso et al., 2020).

Tal es el caso de Tailandia, donde se reveló que la actividad física regular está correlacionada con una mejor salud mental y bienestar social entre los adultos mayores (Kaewsuphan et al., 2023). Este hallazgo es crucial, dado que la falta de actividad física no solo contribuye a problemas de movilidad, sino que también está relacionada con un aumento en los síntomas de depresión y ansiedad en esta población (Gąska et al., 2020). Por ejemplo, un estudio en Corea del Sur demostró que los adultos mayores con enfermedades periodontales tenían una calidad de vida significativamente menor, lo que sugiere que la salud bucal y la movilidad están interrelacionadas (Bazrafkan et al., 2022).

Además, se ha observado que el aumento de estrés y la ansiedad ha tenido un impacto desproporcionado en la salud de los adultos mayores, lo que ha afectado su movilidad y bienestar general (Bastani & Haghani, 2022). Un estudio en Irán encontró que el miedo y estrés causado por enfermedades, como el COVID-19, estaba asociado con un aumento en los problemas de movilidad entre los ancianos, lo que resalta la necesidad de abordar no solo los aspectos físicos de la salud, sino también los factores psicológicos que afectan a esta población (Namazi, 2020).

La relación entre el envejecimiento y la salud pública también se ve afectada por factores socioeconómicos. En China, un estudio mostró que el aumento de la dependencia de la población anciana ha llevado a un incremento en los gastos de salud, lo que representa una carga significativa para los hogares urbanos (Ertem, 2021). Este fenómeno es preocupante, dado que la presión sobre los sistemas de salud puede limitar el acceso a servicios esenciales para los adultos mayores, exacerbando aún más los problemas de movilidad y salud en general (Horch, 2021).

La combinación de enfermedades crónicas, problemas de salud mental y factores socioeconómicos crea un panorama complejo que requiere un enfoque integral para mejorar la calidad de vida de esta población. La implementación de programas de promoción de la salud, el uso de tecnologías de monitoreo, intervenciones para mejorar la movilidad y el acceso a servicios de salud son esenciales para abordar estos desafíos y garantizar la independencia de esta población promoviendo un envejecimiento saludable.

#### 2.1.1. Perspectiva global del envejecimiento saludable

El concepto o percepción del envejecimiento saludable varía significativamente según el contexto cultural y geográfico. Un estudio realizado por Chowdhury et al. (2023) en Canadá reveló que, para los adultos mayores sudasiáticos, el bienestar espiritual y las conexiones religiosas juegan un papel crucial en la percepción de un envejecimiento saludable, reflejando la importancia de los factores culturales en esta etapa de la vida. Tal es el caso del estudio de Ghazali et al. (2023) donde se demostró que la religiosidad fue el factor más asociado con el envejecimiento saludable. En contraste, en países como Estados Unidos, el envejecimiento saludable se asocia principalmente con la autonomía funcional y la capacidad de realizar actividades diarias de manera independiente (Dev et al., 2020). A pesar de estas diferencias, la salud física sigue siendo un componente esencial, aunque se ve influenciada por las expectativas y normas sociales específicas de cada cultura (Silva et al., 2023). Esto evidencia que un enfoque que no considere las creencias y valores locales puede limitar la efectividad de las estrategias para promover un envejecimiento saludable.

Además de los aspectos culturales, las políticas públicas también influyen en la promoción del envejecimiento saludable. En Europa, por ejemplo, la iniciativa European Innovation Partnership on Active and Healthy Ageing (EIP on AHA) fomenta la colaboración entre gobiernos

e instituciones para crear entornos que promuevan la salud física y la participación comunitaria de los adultos mayores (Bousquet et al., 2015). Estas políticas buscan asegurar que los mayores tengan acceso a programas de ejercicio y a actividades que mejoren su calidad de vida. En Corea, al contrario, se proyecta que, en 2025, el 20.3% de la población será mayor de 65 años, lo que llevará al país a ser una "sociedad súper envejecida". Requiriendo con mayor necesidad, políticas de salud pública enfocadas en el envejecimiento saludable para reducir los altos costos de atención médica (Bertolazzi et al., 2024).

En China, un estudio encontró que el 42.83% de los adultos mayores con discapacidades experimentan bajos niveles de envejecimiento saludable debido a necesidades no satisfechas de asistencia en actividades de la vida diaria (Cao et al., 2023). Lo que es todo lo contrario en el caso de Estados Unidos, pues se ha observado que las actividades comunitarias tienen un impacto positivo en la salud emocional de los mayores, contribuyendo a su calidad de vida (Dev et al., 2020). Además, en un estudio realizado en la costa este de Malasia, la prevalencia del envejecimiento saludable entre ancianos que viven en la comunidad en Terengganu (14,1%) es comparable a las tasas de envejecimiento saludable ancianos de Noruega (14,5%) (Bosnes et al., 2019), pero ligeramente superior mayores de Corea (13,3%) (Jang, 2020), sin embargo, inferior a las registradas entre las personas mayores de Singapur (28,6%) (P. Zhang et al., 2023). Cualquier intervención debe reconocer el papel de la interacción social y ajustarse a las formas en que se genera en cada cultura, en vista de que los contextos locales influyen en la percepción y los resultados del envejecimiento saludable.

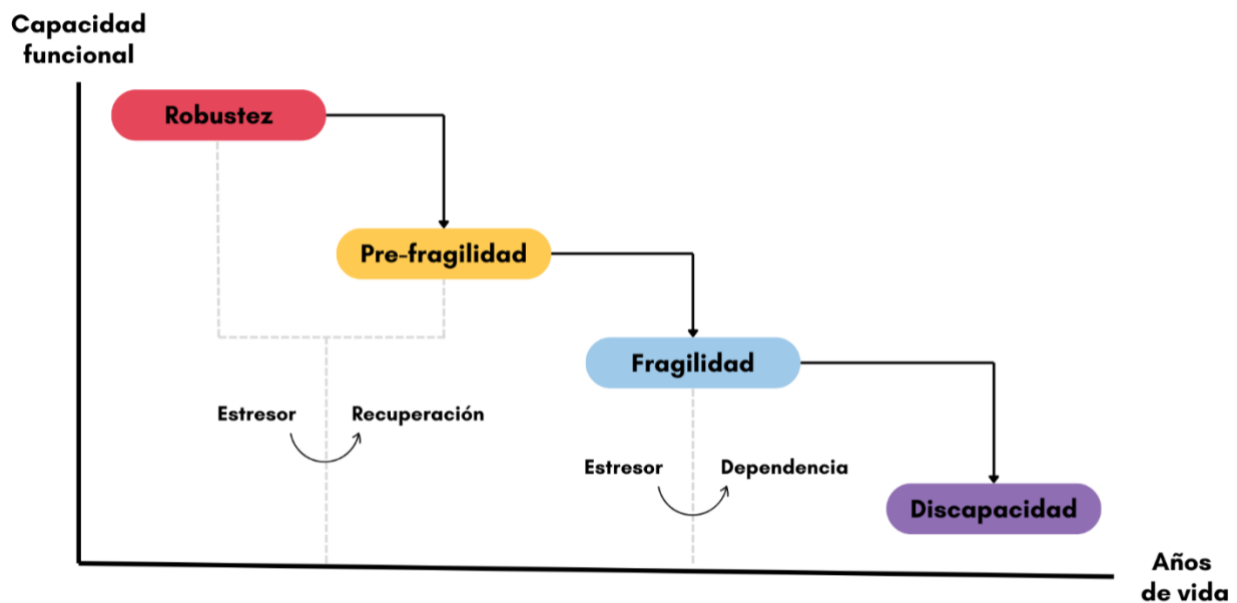
### 2.1.2. Envejecimiento Saludable

El concepto de envejecimiento saludable se ha abordado desde múltiples enfoques, todas convergentes en la búsqueda de bienestar en la vejez. Según Menassa et al. (2023) existen dos perspectivas principales: una que se enfoca en las dimensiones cognitivas, físicas, sociales y psicológicas, entendidas como la ausencia de enfermedad, y otra, que resalta la interacción dinámica entre la persona y su entorno a lo largo de la vida. Wahl (2020) coincide, añadiendo que estas dimensiones evolucionan según el contexto y la época.

La OMS define el envejecimiento saludable como "el proceso de desarrollar y mantener la capacidad funcional que permite el bienestar en la vejez" (Rudnicka et al., 2020).

Enfatizando así que el concepto va más allá de la ausencia de enfermedad, incluyendo el bienestar físico, mental y social (Cesari et al., 2015). Implica mantener la independencia y la funcionalidad, lo que a su vez contribuye a una mejor calidad de vida (Dabove, 2023). Integrando tanto la capacidad intrínseca; aspectos cognitivos, psicológicos, sensoriales, locomotores y de vitalidad, como el apoyo del entorno (Adhikari, 2020).

A medida que las personas envejecen, es común que experimenten una disminución en sus capacidades físicas y cognitivas, lo que puede resultar en una mayor vulnerabilidad a enfermedades y discapacidades (Quispe Montalvo et al., 2024). Esa transición es visible en la Ilustración 2, cómo las personas robustas suelen recuperarse tras eventos estresantes, mientras las frágiles avanzan hacia la discapacidad, especialmente ante nuevos episodios de estrés (Cristofori et al., 2023).



**Ilustración 2 Cascada de disminución funcional.**

Fuente: Elaboración Propia. Basado en Vargas-Del-Valle et al. (2021) y Dent et al. (2019).

La discapacidad, según la OMS, se refiere a deficiencias, limitaciones de actividad y restricciones en la participación, afectando a más de mil millones de personas en todo el mundo, de las cuales aproximadamente 200 millones enfrentan dificultades significativas en su funcionalidad (Tipán Espinoza, 2022). El desarrollo de esas discapacidades pueden ser el resultado de múltiples factores, incluyendo enfermedades crónicas, fragilidad y deterioro funcional. Por ejemplo, un estudio en Brasil reveló que el 10.5% de las personas mayores de 65 años se

encuentran en situación de dependencia funcional, cifra que aumenta al 29% en aquellos mayores de 85 años (González-García et al., 2023).

Indicando un número significativo, situación se traduce en una dependencia funcional que afecta la calidad de vida de los adultos mayores y genera una presión significativa sobre los recursos de atención médica y social (Andrade Farfán & Balda Zambrano, 2022). Las personas que no participan en actividades físicas regulares o que no reciben el apoyo social adecuado son más propensas a desarrollar discapacidades (Sirgo Álvarez, 2022). Lo que es alarmante pues conllevar a un ciclo de dependencia que es difícil de romper y que a su vez afecta su capacidad funcional e intrínseca. Por lo tanto, es crucial que las políticas públicas y los programas de salud se enfoquen en la prevención de la dependencia a través de la promoción de estilos de vida saludables y el acceso a servicios de atención adecuados (Ramírez Arellano & Mendoza-Núñez, 2022).

#### 2.1.2.1 Capacidad funcional e intrínseca

La capacidad funcional y la capacidad intrínseca son dos conceptos interrelacionados y fundamentales para comprender el envejecimiento saludable. La capacidad funcional se refiere a la habilidad de una persona para realizar actividades de la vida diaria, lo que incluye tanto actividades básicas como complejas, crucial para mantener la independencia y la calidad de vida en la vejez (Calvo Higuera & Gomez Carrillo, 2023). Por otro lado, la capacidad intrínseca se define como la combinación de capacidades físicas, mentales y psicosociales que permiten a una persona llevar a cabo sus actividades cotidianas y participar en la vida social (Ribera Casado, 2021). Por ejemplo, una persona con la capacidad intrínseca de caminar podría ver limitada su capacidad funcional si vive en un lugar con escaleras empinadas y sin características de accesibilidad o apoyo social (Tarbert & Singhatat, 2023).

Lo que Pilotto et al. (2020) corroboran pues concluyeron que la creación de entornos accesibles no solo mejora la capacidad funcional de los mayores, sino también reduce el riesgo de caídas y fragilidad, dos de las principales causas de discapacidad en esta población. Así mismo (Zhao et al., 2023) quienes confirman que los entornos accesibles, junto con la integración de servicios de salud, son esenciales.

Lo que es digno de considerar dado que la disminución en cualquiera de las capacidades mencionadas puede llevar a un deterioro en la calidad de vida y aumentar el riesgo de dependencia (Ruiz-Ruiz et al., 2021).

A medida que disminuye la capacidad intrínseca, la capacidad funcional también puede verse afectada, generando dificultades para realizar actividades diarias (Luo et al., 2021). A la inversa, intervenciones dirigidas a mejorar la capacidad intrínseca impactan positivamente la capacidad funcional, mejorando la salud en adultos mayores (Yan, 2023). Tal como concluyeron Muneera et al. (2023) al observar que los adultos mayores con alta capacidad intrínseca tenían una prevalencia significativamente menor de dificultades en actividades de la vida diaria, como vestirse y alimentarse (12,26% frente a 22,38%), y en actividades instrumentales como manejar dinero y cuidar del hogar (31,13% frente a 49,52%), en comparación con aquellos con baja capacidad intrínseca. Además, reportaron menor incidencia de caídas (9,42% frente a 13,34%), lesiones relacionadas con caídas (4,10% frente a 6,06%) y caídas múltiples (3,46% frente a 6,16%). La discapacidad puede ir precedida de varios años por un estado de mayor vulnerabilidad conocido como fragilidad (Fried et al., 2001).

#### 2.1.2.2 Fragilidad

La fragilidad es un concepto multifacético y dinámico que ha evolucionado significativamente en la literatura científica, pasando de una visión exclusivamente física a un enfoque multidimensional que integra aspectos psicológicos y sociales (Carrasco Diaz & Araya, 2023). Hay dos enfoques principales, por un lado, el modelo de acumulación de déficit de Rockwood define el índice de fragilidad (FI) como el número de déficits de salud observados en un individuo dividido por el número total de variables de salud bajo estudio (Cobo et al., 2021). Por otro lado, el modelo más aceptado, propuesto por Fried et al. (2001), define la fragilidad física en función de cinco criterios: pérdida de peso involuntaria, agotamiento, baja actividad física, velocidad de marcha lenta y debilidad (M. Li et al., 2020). Concepto que involucra diferentes sistemas biológicos (nerviosos, endocrinos, inmunes y musculoesqueléticos) (Clegg et al., 2013).

Este modelo, el fenotipo de Fried, es una de las herramientas más utilizadas para evaluar la fragilidad. Permite clasificar a los adultos mayores; aquellos que cumplen tres o más de estos

criterios son clasificados como frágiles; quienes cumplen uno o dos, como pre-frágiles; y quienes no cumplen ninguno, como robustos (Rodríguez Mañas et al., 2018).

No obstante, su conceptualización se amplió con el modelo de déficit acumulativo de Kenneth Rockwood y el enfoque de J.E. Morley, consolidándola como un área clave en la geriatría a nivel mundial. Definiéndose como un síndrome geriátrico que afecta entre el 5% y el 17% de los adultos mayores (Allison et al., 2021). Como herramientas ante ello, además del fenotipo de Fried, se ha propuesto el uso de escalas multidimensionales que consideran factores físicos, cognitivos y sociales para identificar a quienes están en riesgo de progresar hacia la discapacidad (Prasanth et al., 2021). Cabe destacar que la fragilidad es una característica más abstracta que no se puede medir directamente. En estos casos, se utiliza el análisis estadístico para establecer asociaciones entre los parámetros de los sensores y la fragilidad, o bien se entrenan modelos de aprendizaje automático para transformar esos parámetros en estimaciones útiles (Cobo et al., 2021).

Este índice se ha utilizado en diversas poblaciones, tal es el caso de Santamaría Peláez et al. (2021) donde demostraron que es efectivo para predecir resultados adversos en salud, como hospitalizaciones y mortalidad. Así mismo, estudios como (Cunha et al., 2023) han demostrado que el aumento en la actividad física no solo ayuda a prevenir la fragilidad, sino que también puede revertir su estado en personas que ya la presentan. Fernández-Revelles et al. (2023) concuerdan pues en su estudio se mostró que los adultos mayores que participaron en un programa de ejercicio multicomponente experimentaron mejoras significativas en su fuerza muscular, resistencia y capacidad funcional. Por lo que se concluye que aunque inicialmente se consideraba como un estado irreversible, con intervenciones adecuadas, es posible revertir (Alonso Bouzón & Rodríguez Mañas, 2021), ralentizar o detener la fragilidad a lo largo de los cuatro estados en la cascada de la disminución funcional en la Ilustración 2 (Vargas-Del-Valle et al., 2021).

Por lo que la fragilidad es un estado cambiante y no unidireccional (Acosta-Benito & Martín-Lesende, 2022). No obstante, una vez alcanzado el estado de discapacidad, revertirlo se vuelve más complicado e incluso puede considerarse imposible (Acosta-Benito & Martín-Lesende, 2022). Mientras que una persona robusta puede regresar a su estado anterior tras una

enfermedad, en personas frágiles la tendencia es a volverse dependientes y no recuperar su estado previo tras un episodio de enfermedad (Cristofori et al., 2023).

Además de la fragilidad física, se reconoce cada vez más la importancia de las dimensiones social y cognitiva. La fragilidad social, caracterizada por el aislamiento social y la falta de apoyo social, ha demostrado exacerbar los efectos de la fragilidad física y contribuir a resultados adversos en la salud (Wang et al., 2024). La fragilidad cognitiva, que combina el deterioro cognitivo y fragilidad física, destaca la necesidad de un enfoque integral en la evaluación y manejo de la fragilidad (Jiao et al., 2023). Identificar y abordarla es crucial para implementar intervenciones adecuadas que mejoren los resultados de salud y la calidad de vida de los adultos mayores. Especialmente en regiones como España, donde hasta el 44,2% de la población mayor corre el riesgo de volverse frágil en los próximos dos años si no se toman medidas preventivas (Ghosh et al., 2023).

El análisis de la marcha ha surgido como un aspecto clave para la evaluación de la fragilidad, destacando especialmente la velocidad de la marcha debido a su capacidad para proporcionar información directa sobre el nivel de funcionamiento de la persona. Convirtiéndose así en una herramienta valiosa como medida preventiva.

### 2.1.2.3 Velocidad de la marcha

Los parámetros de la marcha son métricas esenciales para evaluar la locomoción humana, especialmente en entornos clínicos y de rehabilitación. Estos parámetros se dividen en dos categorías principales: los parámetros espaciotemporales y los parámetros cinemáticos. Los espaciotemporales describen los aspectos espaciales y temporales de la marcha. Entre los más importantes se encuentran la velocidad de la marcha, que es la tasa de movimiento, generalmente medida en metros por segundo (m/s) (Usami et al., 2022). Se ha convertido en un indicador importante de la salud funcional en adultos mayores, pues se ha demostrado que una disminución en la velocidad de marcha no solo está relacionada con un mayor riesgo de caídas, sino que también puede estar asociada con el deterioro funcional y cognitivo (Cigarroa et al., 2020). La investigación sugiere que una velocidad de marcha inferior a 1 m/s puede ser un marcador de fragilidad y deterioro cognitivo (Calderón-Campos et al., 2019). Debido a su importancia, se busca obtener información de forma constante para su análisis.

Sin embargo, los sistemas sanitarios enfrentan desafíos significativos en el seguimiento continuo de este parámetro debido a la falta de recursos. Razón por la cual la atención a esta población a menudo se limita a entornos clínicos, lo que tiende a resultar en una falta de evaluación funcional regular y adecuada (Buran Sevik et al., 2024). Aspecto crítico dado que muchos pueden no tener acceso a servicios de salud regulares, lo que conlleva a un deterioro de funcionalidad y calidad de vida no detectado. Por lo tanto, surge la necesidad de desarrollar nuevos modelos de cuidado que permitan realizar evaluaciones funcionales fuera de los entornos clínicos y sin la necesidad de supervisión profesional constante (Sanchez-Cárdenas et al., 2021).

La implementación de estos nuevos enfoques no solo podría mejorar la calidad de la atención, sino que también podría optimizar el uso de recursos en los sistemas de salud (Maia et al., 2021). A su vez, procurando que se mantenga un nivel adecuado de funcionalidad y calidad de vida a medida que envejecen (Álvaro Elices Acero, 2023).

### 2.1.3. Enfoque tecnológico

El uso de tecnología en medicina ha crecido significativamente, y la capacidad de medir la fragilidad de forma no invasiva y con mínima incomodidad para el paciente es clave para su evaluación y prevención (García, 2020). Los sensores inerciales portátiles (IMU), los acelerómetros y los giroscopios, se han convertido en soluciones ampliamente utilizadas para la evaluación más precisa y continua de la marcha en adultos mayores (Jung et al., 2020). Estos dispositivos pueden proporcionar datos en tiempo real sobre la marcha y el equilibrio, lo que facilita la identificación temprana de problemas y la personalización de las intervenciones (Castellanos-Ruiz et al., 2020).

#### 2.1.3.1. Sensores inerciales

Los sensores inerciales son dispositivos que permiten medir la aceleración y la rotación de un objeto en movimiento, proporcionando información crucial sobre su posición y orientación en el espacio. Estos sensores son componentes integrales de los IMUs, que combinan estos elementos para proporcionar datos de movimiento completos (Dugarte Jerez et al., 2024a).

Los acelerómetros funcionan midiendo la fuerza de la gravedad y la aceleración que actúa sobre ellos, lo que les permite calcular la aceleración lineal en uno o tres ejes (X, Y y Z), al detectar la fuerza que actúa sobre una pequeña masa dentro del sensor (Realpe Muñoz et al., 2023). Mientras que los giroscopios, funcionan principalmente mediante el principio de la fuerza de


Coriolis, el cual establece que cuando un objeto en rotación se desplaza perpendicularmente a su eje de rotación, se genera una fuerza de Coriolis que se puede medir y convertir en una señal eléctrica. Esa señal resultante refleja la velocidad angular del objeto, lo que es crucial para medir su orientación y estabilidad (Ranji et al., 2022).

Una de sus características es que pueden compensar las limitaciones de los acelerómetros, que pueden ser afectados por la gravedad y otros factores externos (Peñaloza-Mendoza et al., 2024). Así mismo, en algunos casos, estos sensores incluyen magnetómetros que puede proporcionar información adicional sobre la dirección, orientación relativa al campo magnético de la Tierra (Benesha et al., 2020).

Utiliza principios físicos como la magnetorresistencia y el efecto Hall para detectar campos magnéticos, aprovechando las propiedades de materiales magneto sensibles (Jaramillo & Montealegre Mesa, 2023).

La combinación de datos de magnetómetros con información de acelerómetros y giroscopios permite mejorar la precisión de la navegación inercial. Según (Gamonal Puerto et al., 2021), esta fusión de datos es fundamental para compensar las limitaciones inherentes a cada tipo de sensor. Por ejemplo, mientras que los acelerómetros pueden ser afectados por la gravedad y los giroscopios pueden sufrir de deriva, los magnetómetros proporcionan una referencia estable que ayuda a corregir estas inexactitudes (Reina et al., 2022). Esto es especialmente relevante en aplicaciones donde se requiere un seguimiento preciso, como el de actividad física.

Al medir la aceleración y la rotación, permiten la obtención de parámetros de marcha de manera precisa y en tiempo real, lo que es crucial para la evaluación y rehabilitación de la movilidad (Werner et al., 2021). Sin embargo, obtener información sobre los ejes medio lateral y anteroposterior son clave para analizar la estabilidad postural y la movilidad en adultos mayores. Con ello en mente, la Sociedad Internacional de Biomecánica ISB, se recomienda una orientación específica (Wu & Cavanagh, 1995), tal como se muestra en la Ilustración 3. El eje medio lateral refleja el equilibrio lateral, mostrando mayor variabilidad en personas frágiles, mientras que el anteroposterior mide el control del avance, asociado a la fuerza y coordinación.



### **Ilustración 3 Referencia para señales registradas en el centro de masa para los tres ejes.**

Fuente: Wu & Cavanagh (1995) y Aznielle Rodríguez et al. (2023).

Cambios en estos ejes permiten identificar fragilidad y riesgo de caídas, facilitando el monitoreo del estado funcional y el diseño de intervenciones personalizadas para mejorar la movilidad y prevenir accidentes (S.-H. Chen et al., 2021). Integrados en dispositivos portátiles, estos sensores ofrecen múltiples beneficios al evaluar parámetros de la marcha y detectar problemas de movilidad. Son compactos, económicos, brindan información muy importante y pueden colocarse fácilmente en diversas partes del cuerpo, lo que las hace adecuadas tanto para entornos clínicos como para el uso cotidiano.

Reyes Leiva et al. (2021) afirman que su aplicación facilita la medición precisa de la zancada y la velocidad de marcha, permitiendo evaluaciones detalladas de las características de la marcha. Asimismo, Ruiz-Ruiz et al. (2021) respaldan su efectividad al señalar que estos sensores permiten la monitorización de parámetros como la velocidad de marcha, cadencia y fases de balanceo y apoyo incluso en entornos no controlados, ofreciendo una perspectiva realista y continua de los patrones de movilidad diarios. Sin embargo, aunque muestran una precisión de moderada a buena, los resultados pueden variar en función de las condiciones individuales y las complejidades de la marcha, por lo que requiere una validación sólida (Kirk et al., 2024).

En cuanto a su fiabilidad, estudios han mostrado que proporcionan datos consistentes para evaluar parámetros espaciotemporales de la marcha, mostrando alta concordancia con los métodos tradicionales y validándose en poblaciones con condiciones específicas, como esclerosis múltiple, donde pueden detectar alteraciones sutiles que otros métodos pasan por alto (Zahn et al., 2023).

Además, se utilizan cada vez más para evaluar el riesgo de caídas y fragilidad en adultos mayores, identificando mediante el análisis de la marcha a aquellos con mayor riesgo y facilitando intervenciones tempranas (Baba et al., 2023). También se están explorando para detectar cambios en la marcha asociados con el deterioro cognitivo; se han desarrollado sistemas automáticos que, a través de biomarcadores de la marcha, permiten identificar deterioro cognitivo leve en el hogar (Zhou et al., 2023). Debido a la evolución tecnológica, se ha comprobado que, mediante el uso de algoritmos sofisticados y métodos de aprendizaje automático, los IMU son capaces de ofrecer mediciones precisas y en tiempo real de los parámetros de la marcha, incluso en entornos reales. Diversas investigaciones han evidenciado la efectividad de las IMU para estimar la velocidad de la marcha y otros parámetros espaciotemporales con gran precisión (Pérez Molinet et al., 2021).

#### 2.1.3.2. Procesamiento de señales inerciales

El procesamiento se refiere a la manipulación sistemática de datos para extraer información significativa, particularmente en el contexto de señales inerciales de sensores. Este enfoque es esencial para asegurar que los datos recogidos sean interpretados con corrección, especialmente en aplicaciones de navegación y análisis de movimiento. Según Huang et al. (2021), la limpieza inicial de las señales inerciales es crucial para eliminar el ruido y los datos irrelevantes. Además, Abramov et al. (2022) destacan que la aplicación de técnicas avanzadas, como el filtrado por transformación discreta de cosenos, permite suprimir el ruido mientras se preserva la integridad de la señal. En este sentido, la extracción de características significativas también juega un papel clave, identificando vectores del ciclo de marcha en el análisis de movimiento.

Otro paso fundamental es la fusión de datos, que implica combinar múltiples características, como la velocidad angular y la aceleración. Esta fusión se realiza mediante métodos como PCA-CCA, que mejoran la precisión del reconocimiento (Huang et al., 2021). Por otro lado, la calibración continua de los sensores es vital para asegurar una salida precisa, utilizando algoritmos matemáticos que procesan tríadas de acelerómetros y giroscopios (Zasukhin et al., 2022).

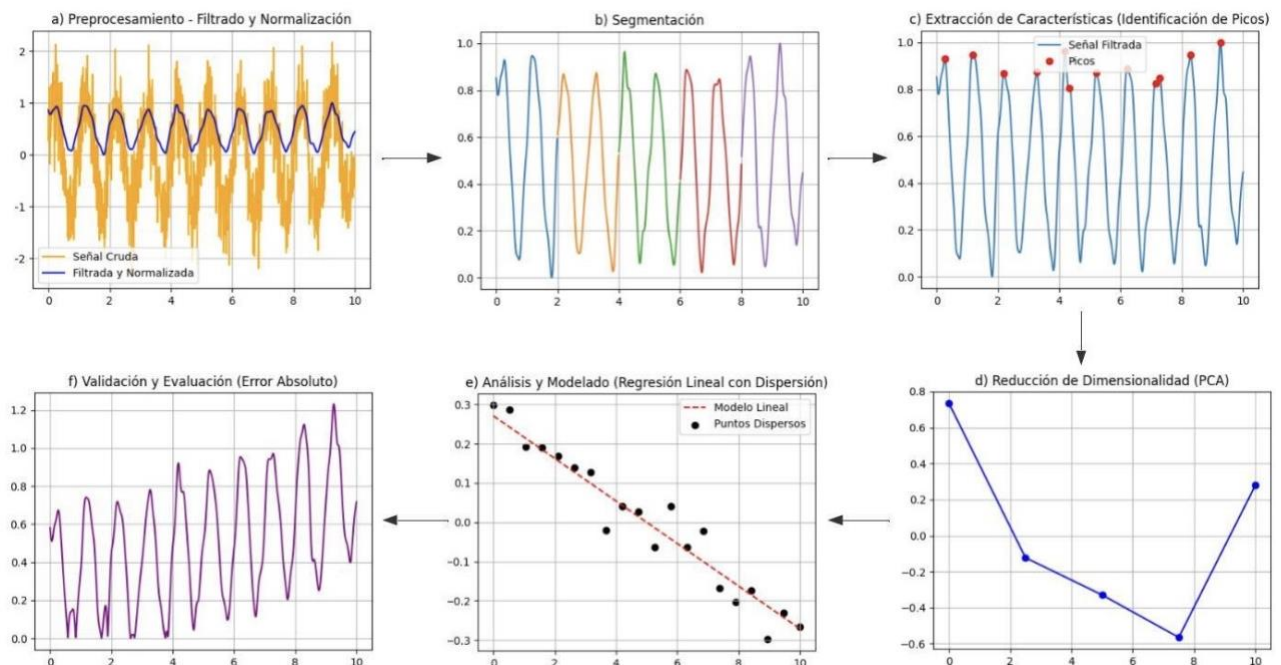
Sin embargo, el procesamiento de señales inerciales es un proceso complejo que se compone de múltiples etapas fundamentales, Ilustración 4, cada una de las cuales desempeña un papel crucial en la mejora de la calidad y la utilidad de los datos obtenidos de sensores inerciales.

Estas etapas incluyen el preprocesamiento, la segmentación, la extracción de características y la reducción de dimensiones.

#### a. Preprocesamiento

El preprocesamiento es la primera etapa crítica en el procesamiento de señales inerciales. Esta fase implica la limpieza de los datos crudos para eliminar el ruido y las interferencias que pueden afectar la calidad de la señal. Se utilizan diversas técnicas de filtrado, como la transformada wavelet, que permite descomponer la señal en diferentes componentes y eliminar el ruido sin perder información relevante (Antofie et al., 2023).

Además, puede incluir la normalización de los datos para asegurar que las señales sean comparables y consistentes (Joseph & Jayaraman, 2024). Esto es esencial para asegurar que las mediciones sean consistentes y comparables. Por ejemplo, se pueden aplicar algoritmos de corrección de errores que ajustan las lecturas de los sensores para compensar las desviaciones sistemáticas que pueden ocurrir debido a factores como la temperatura o el desgaste del sensor (Han et al., 2020). Este paso es fundamental para garantizar que los datos sean precisos antes de proceder a la extracción de características.



**Ilustración 4 Etapas procesamiento de señales inerciales.**

Fuente: Elaboración Propia.

#### b. Segmentación

La segmentación implica dividir las señales en segmentos más pequeños y manejables que pueden ser analizados individualmente. Esta etapa es crucial para identificar patrones específicos en los datos, como eventos de interés o cambios en el comportamiento (Heydarian et al., 2020). Por ejemplo, en aplicaciones de reconocimiento de gestos, los datos inerciales pueden segmentarse en función de la duración y la intensidad de los movimientos detectados, lo que facilita el análisis posterior (Tan & Xie, 2021).

#### c. Extracción de características

La extracción de características es una etapa donde se identifican y cuantifican las propiedades relevantes de las señales segmentadas. Esto puede incluir la identificación de patrones de movimiento, la detección de picos de aceleración o cambios en la velocidad (Heydarian et al., 2020). Las características extraídas son esenciales para el análisis posterior y pueden ser utilizadas en modelos de aprendizaje automático para clasificar o predecir comportamientos. Por ejemplo, se pueden utilizar técnicas de aprendizaje profundo, como redes neuronales convolucionales (CNN), para procesar las características extraídas y mejorar la precisión de las predicciones (H. Chen et al., 2022).

#### d. Reducción de dimensionalidad

La reducción de dimensiones es una técnica que se utiliza para simplificar los datos sin perder información significativa. Esto es especialmente importante en el procesamiento de señales inerciales, donde los datos pueden ser de alta dimensionalidad. Métodos como el Análisis de Componentes Principales (PCA) o técnicas basadas en autoencoders pueden ser aplicados para reducir la complejidad de los datos y facilitar su análisis (Amrani et al., 2022a). La reducción de dimensiones ayuda a mejorar la eficiencia computacional y puede aumentar la precisión de los modelos de aprendizaje automático al eliminar características redundantes o irrelevantes (Joseph & Jayaraman, 2024).

#### e. Análisis y modelado

Además de las etapas mencionadas, el análisis y modelado de los datos procesados es una fase crítica que implica la interpretación de los resultados y la construcción de modelos predictivos. Esto puede incluir el uso de modelos estadísticos o algoritmos de aprendizaje

automático para clasificar los patrones de movimiento y hacer predicciones sobre el comportamiento futuro (Cao et al., 2023). En aplicaciones de navegación, por ejemplo, se pueden integrar las señales inerciales con datos de sistemas de navegación global por satélite (GNSS) para mejorar la precisión de la localización (Y. Li et al., 2024).

#### f. Validación y evaluación

Como etapa final se encuentra la validación y evaluación de los modelos y algoritmos desarrollados es una etapa final que asegura que los resultados obtenidos sean precisos y fiables. Esto puede implicar la comparación de los resultados con datos de referencia o la realización de pruebas en condiciones controladas para evaluar el rendimiento de los sistemas de procesamiento de señales inerciales (Jain et al., 2022). La retroalimentación obtenida en esta etapa puede ser utilizada para ajustar y mejorar los algoritmos y modelos utilizados en el procesamiento.

#### 2.1.4. Origen de investigación

El Laboratorio de Envejecimiento Saludable fue creado en 2015 por el Centro de Tecnología Biomédica (CTB) en conjunto con el Hospital Universitario de Getafe. Según el Informe Mundial sobre el Envejecimiento y la Salud emitido en octubre del 2015 por la Organización Mundial de la Salud; la asistencia y el cuidado de los ancianos deben centrarse en mantener la autonomía funcional en lugar de tratar o curar una enfermedad. Con eso en mente, Ageing Lab se centra en uno de los principales problemas relacionados con la salud de las personas mayores, la discapacidad; y su principal factor de riesgo, la fragilidad.

El presente proyecto, aborda este análisis desde dos perspectivas complementarias: la detección de patrones característicos de la marcha y la estimación de la velocidad de la marcha, ambos fundamentados en el marco de los proyectos ActiveUP y MOTIVA.

##### 2.1.4.1 Proyecto ActiveUP

Con el internet de las cosas como línea de investigación y el objetivo de crear una tecnología capaz de recopilar toda la información relevante para analizar la capacidad funcional de las personas mayores a través de la monitorización; ActiveUp fue creado. Surge como factor en búsqueda de mejorar la fragilidad por medio de la intervención. Específicamente intervención no farmacológica, es decir, por medio de la actividad física y nutrición, considerando que la actividad física es una herramienta eficaz para tratar y prevenir el deterioro funcional y la

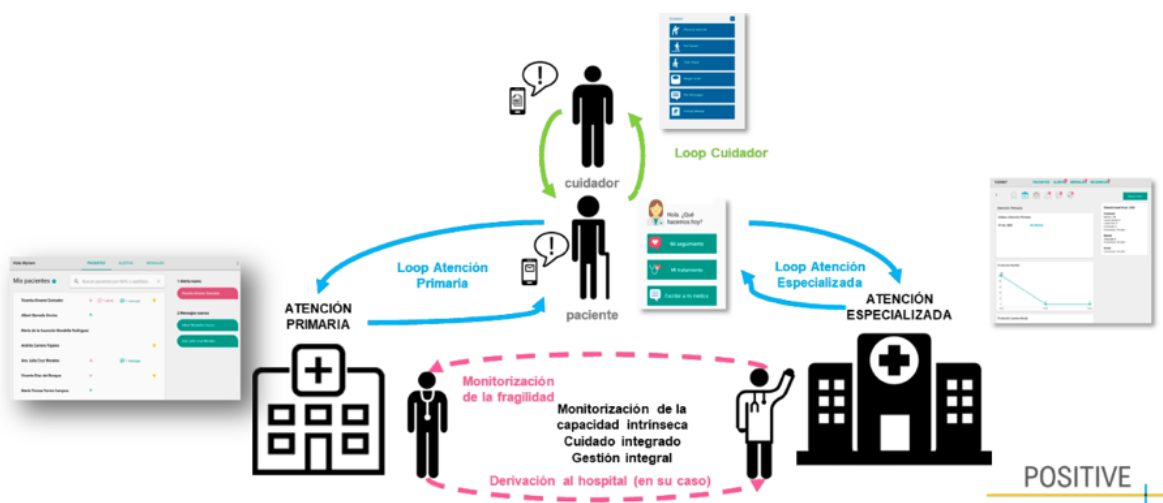
fragilidad. Se basa en los resultados de los proyectos FACET y POSTIVE, ambos proyectos financiados por el Instituto Europeo de Tecnología a través de la red EIT-Health.

a Proyecto FACET

Frailty Care And Well Function, por sus siglas en inglés FACET. En el mismo se desarrolló un sistema de atención domiciliar para el monitoreo y la gestión de la fragilidad. Compuesto por un kit de monitoreo de fragilidad capaz de detectar cambios en las dos variables funcionales más informativas, la velocidad de la marcha y la fuerza de las extremidades inferiores. También un sensor de velocidad de la marcha, un sensor de fuerza de las extremidades inferiores y una aplicación móvil para controlar ambos. Además, la aplicación móvil admitió la autoadministración de los cuestionarios habituales de Evaluación Geriátrica Integral (CGA), así mismo permitió a los pacientes recibir y realizar distintas actividades que el profesional prescribía. Una de sus características es que la aplicación *Homecare* fue desarrollada para realizar las prescripciones por parte del profesional y revisar la evolución del paciente (Gonzales, 2019).

b Proyecto POSITIVE

Consiste en establecer un nuevo modelo de organización para el cuidado del paciente en casa en el que se incluyan hospitales y centros de salud, tal como se aprecia en la Ilustración 5. Cabe destacar que, con lo mencionado anteriormente, implementa FACET para la monitorización del paciente, Vivifrail para la estimulación funcional, Mind Frail para recomendaciones nutricionales y la plataforma de caídas desarrollada en el Hospital de Getafe (Victoria Herrera, 2016).



**Ilustración 5 Proyecto Positive.**

Fuente: TFG Ismael Gonzalez (2019).

c Proyecto ActiveUp

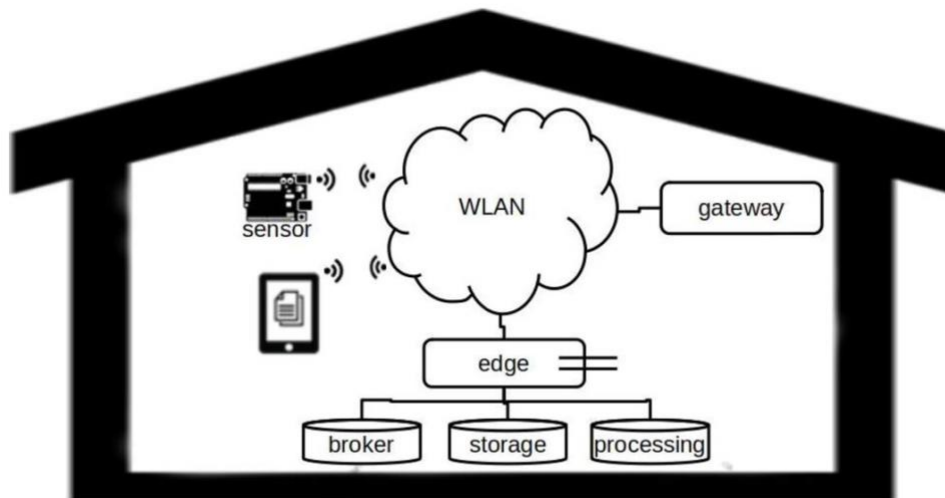
El proyecto Envejecimiento Activo con Monitorización Personalizada y No Obtrusiva, (ActiveUP) por sus siglas en inglés, es un sistema de monitorización continua del movimiento de personas mayores como solución a las necesidades insatisfechas de los servicios de gestión de personas frágiles, para todos los usuarios implicados: las personas frágiles y sus cuidadores formales e informales.



**Ilustración 6 Primer prototipo de sensor**

Fuente: Informe Proyecto ActiveUP.

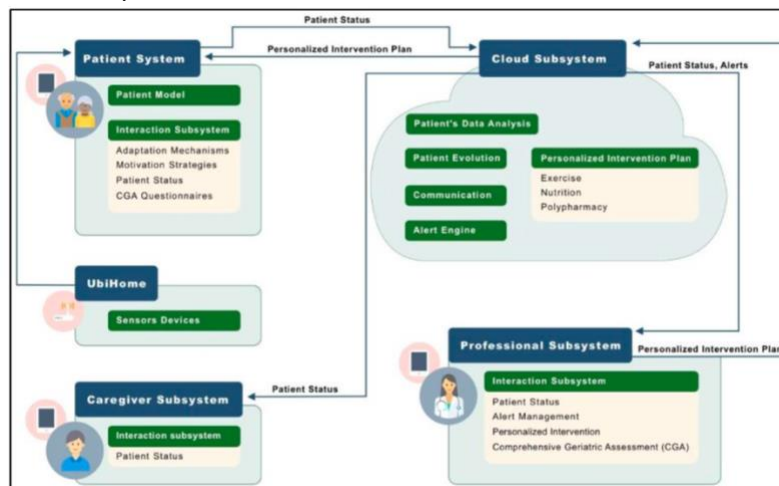
El sistema de recopilación de datos en la vivienda consiste en la implementación de un sistema de Internet de las cosas IoT (del inglés Internet of Things) sobre la arquitectura de computación en el extremo (del inglés, Edge Computing) de la ilustración 7.



**Ilustración 7 Arquitectura de computación del sistema IoT para la recopilación de datos en la vivienda.**

Fuente: Informe Proyecto ActiveUP.

El sensor actúa como fuente de datos registrando el movimiento del sujeto y publica los datos, tanto basados en los sensores como en las aplicaciones móviles que los mismos pacientes controlan, en el agente de mensajería de la red de área local del domicilio. La misma los encamina a los consumidores de datos suscritos que son el servicio de procesamiento de señal (para calcular la velocidad de la marcha de cada uno de los periodos en los que el sujeto haya caminado de manera sostenida) y el servicio de almacenamiento local (para guardar los datos y poder utilizarlos para refinar el algoritmo de procesamiento).



**Ilustración 8 Sistema ActiveUP.**

Fuente: Informe Proyecto ActiveUP.

El presente proyecto de investigación se desarrolla específicamente en el apartado de UbiHome del sistema de ActiveUP de la Ilustración 8, pues son los dispositivos encargados de la recopilación de datos. Se busca desarrollar un algoritmo que permita el procesamiento de dichos datos para detectar patrones característicos en la marcha en la marcha y evaluar el deterioro funcional con el fin de prevenir la fragilidad o la discapacidad.



**Ilustración 9 Diseño final de dispositivo.**

Fuente: Elaboración Propia.

### 2.1.4.2 Proyecto MOTIVA

El proyecto MOTIVA es financiado por el Ministerio de Ciencia e Innovación, en él participan el Centro de Tecnología Biomédica (CTB) de la Universidad Politécnica de Madrid (UPM) y la Fundación para la Investigación Biomédica del Hospital Universitario de Getafe (FIBHUG).

MOTIVA es un ecosistema computacional con apoyo motivacional, evaluación funcional y de desempeño para un programa de ejercicio autónomo que busca mejorar la función de adultos mayores robustos y prefrágiles, prolongando su independencia y, por tanto, reducir la utilización de los servicios de atención médica. Una iniciativa innovadora centrada en el diseño de herramientas tecnológicas que facilitan la evaluación autónoma del estado funcional y la ejecución de programas de ejercicio físico, como VIVIFRAIL, para personas mayores. El mismo es un programa de ejercicio multicomponente que se basa en la premisa de que la actividad física regular puede contrarrestar los efectos del envejecimiento y la inactividad, especialmente en poblaciones vulnerables como los adultos mayores (Dent et al., 2023).




**Ilustración 10 Rueda B de Vivifrail.**

Fuente: Sitio web Proyecto Vivifrail.

Para ello les asignan diferentes configuraciones del programa VIVIFRAIL dependiendo de sus resultados en la prueba SPPB (Puntuación 4-6 Rueda B; Puntuación 7-9 Rueda C; Puntuación 10-12 Rueda D). La rueda B, Ilustración 10, está diseñada para personas mayores que presentan fragilidad o pre-fragilidad, con el objetivo de mejorar su fuerza, equilibrio y velocidad de marcha.

El SPPB comprende tres pruebas diferentes: una prueba de velocidad de la marcha de 4 metros (4mWT) (aunque también está validado para una prueba de 3 metros), una prueba de fuerza consistente en levantarse 5 veces de una silla (5STS) y una prueba de equilibrio (Guralnik et al., 1994).

A través del uso de sensores inerciales que miden aceleración y velocidad angular durante las pruebas físicas y ejercicios, MOTIVA aborda el desafío de fomentar la actividad física y prevenir la fragilidad en adultos mayores. El objetivo es mejorar la independencia, la capacidad funcional y la salud cognitiva, superando las limitaciones de programas previos que carecían de retroalimentación y apoyo motivacional. Se utiliza el sensor vestibular de MOTIVA, un dispositivo compacto de 10,5 x 7 x 3,5 cm que integra un IMU con seis grados de libertad registrando variaciones durante el ejercicio y almacenando los datos en una memoria interna, físicamente se ve como el sensor de ActiveUP, en la Ilustración 9.



**Ilustración 11 Identificación de sensores para prueba SPPB - MOTIVA.**

Fuente: Elaboración Propia.

Dependiendo del tipo de prueba o ejercicio, los sensores se colocan en diferentes partes del cuerpo. Tal como se muestra en la Ilustración 11, se incluye el antebrazo derecho e izquierdo (ID 4-5), la pantorrilla derecha e izquierda (ID 8-9), y la cintura (ID 1), utilizando cinturones o bandas elásticas. La recolección de estos datos es crucial para calibrar los algoritmos de evaluación, lo que permitirá analizar el progreso y la adherencia al programa VIVIFRAIL.

Además, una aplicación móvil registra los resultados y eventos clave durante las sesiones, garantizando un seguimiento detallado y estructurado del desempeño de cada participante.

El interés no es el estudio de diversas características biomecánicas de la marcha durante pruebas de marcha con dichos sensores. Se centra en el valor de la velocidad. El proyecto aborda la necesidad de fomentar la actividad física en adultos mayores para prevenir la fragilidad y mejorar la independencia, la capacidad funcional y la salud cognitiva. MOTIVA pretende superar las limitaciones de programas previos, como la falta de retroalimentación y apoyo motivacional en las aplicaciones de ejercicio. A través de la colocación de sensores en diversas partes del cuerpo durante la realización de pruebas como el Short Physical Performance Battery (SPPB) y los ejercicios del programa VIVIFRAIL, se busca capturar datos de movimiento que luego serán procesados por algoritmos de inteligencia artificial para evaluar el desempeño del participante.

#### 2.1.4.1. Detección Patrones en la marcha

El análisis de la marcha utilizando IMUs ha aumentado su relevancia en el ámbito de la fisioterapia y la rehabilitación, dado que permite un análisis detallado y objetivo del movimiento humano (De Araújo et al., 2020). Dada la importancia del procesamiento de los datos, Vivas Albán et al. (2020) describe el uso del filtro de Kalman extendido para identificar parámetros cinemáticos de la marcha humana a bajo costo mediante IMUs. Este enfoque permite obtener un modelo matemático que se adapta a las características del movimiento humano, lo que resulta en una evaluación más precisa de los parámetros de marcha. Además, el trabajo de Jerez destaca el desarrollo de un sistema de bajo costo que utiliza IMUs para estudiar los cambios de movimiento en pacientes, lo que demuestra la viabilidad de estos dispositivos en entornos clínicos y de investigación (Dugarte Jerez et al., 2024b)

Tal es el caso del estudio de Arshad et al. (2023) donde el sensor colocado en la cintura permitió monitorear variables clave de marcha, la falta de diversidad en la muestra limitó la generalización a distintas poblaciones. De manera similar, Digo et al. (2023) encontraron dificultades al intentar extrapolar sus resultados a entornos no controlados debido a la variabilidad en el uso del sensor. Malik (2021) también señala que su limitación son las muestras en sus estudios, lo que impacta la precisión en la detección de patrones anormales de marcha. Así mismo Huertas-Hoyas et al. (2023) quienes utilizaron regresión logística para analizar los datos (obtenidos del sistema G-STRIDE), identificando variables como la velocidad y el tiempo de

balanceo y su relación con el estado de fragilidad (robusto, prefrágil o frágil) y con el riesgo de caídas.

Por otro lado, hay estudios que utilizaron de machine learning, una subdisciplina de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender de los datos y hacer predicciones o decisiones sin ser programadas explícitamente para cada tarea específica (Jones- Ortiz & Guzmán – Seraquive, 2022). Este enfoque se ha vuelto esencial en el análisis de grandes volúmenes de datos, ya que permite identificar patrones y relaciones complejas que son difíciles de discernir mediante métodos tradicionales de análisis (Andrade Vera et al., 2024). Se ha demostrado que el machine learning puede ser utilizado para clasificar diferentes tipos de marcha y detectar patrones que podrían indicar problemas de salud, como caídas o trastornos del equilibrio (Otamendi et al., 2022).

Como el caso de Arom Gómez Arias et al. (2024), donde utilizaron modelos de clasificación basados en Random Forest y Support Vector Machine junto con IMUs para analizar la biomecánica de la marcha en entornos no clínicos. Sin embargo, la variabilidad en el uso de los sensores y la diversidad en los participantes dificultaron la precisión de los modelos, limitando su capacidad para capturar con exactitud la biomecánica en la vida cotidiana. Hauth et al. (2021) también emplearon IMUs pero con el algoritmo BiLSTM para modelar la marcha, encontrando que, aunque el modelo fue efectivo en condiciones controladas, mostró una menor precisión en entornos naturales debido a su sensibilidad a las variaciones de patrones de marcha. Esto debido a que al utilizar deep learning o aprendizaje profundo, subcategoría del machine learning que utiliza redes neuronales artificiales con múltiples capas para modelar y resolver problemas complejo (Nakano et al., 2020), debido a la presencia de ruido o valores perdidos la precisión de los modelos puede verse afectada (Urra-González, 2023).

En un contexto experimental, Zeng et al. (2020) utilizaron redes convolucionales profundas con datos de aceleración de IMUs para estudiar la marcha de adultos jóvenes; sin embargo, la falta de diversidad en la población estudiada limita la capacidad del modelo para generalizar los hallazgos en personas mayores o con movilidad reducida. Estos estudios enfatizan que, aunque los IMUs ofrecen datos precisos de movimiento, es crucial incluir muestras variadas y optimizar los modelos para mejorar su aplicabilidad en diversos contextos.

En este contexto, los autoencoders son un tipo de red neuronal de aprendizaje profundo, diseñadas para reducir la dimensionalidad y detectar anomalías. Su estructura se compone de un codificador y un decodificador, que comprimen y luego reconstruyen la información, permitiendo extraer características intrínsecas y relevantes de los datos (Bank et al., 2020). Este proceso hace a los autoencoders ideales para analizar datos complejos y ruidosos al aprender patrones de los datos (Tziolas et al., 2022), lo que resulta útil en diversas aplicaciones, incluyendo la detección de anomalías en la marcha (Esmaeili et al., 2023). Factor validado en estudios como Chen et al. (2023) donde se destaca la utilidad de los autoencoders en combinación con IMUs para modelar la biomecánica de la marcha, especialmente para la detección de anomalías en adultos mayores. Aunque en el modelo realizado se vio limitado por una muestra reducida que disminuyó la representatividad de los resultados, Contreras Carrasco (2021) afirma que los autoencoders limpian los datos y extraen representaciones significativas.

Se ha demostrado su efectividad para detectar anomalías en la marcha, en estudios como Yoon et al. (2024) donde lograron identificar patrones desviados, pero la falta de datos de anomalías en entornos reales limita la robustez del modelo ante eventos complejos. Así mismo, Ahmed et al. (2023) enfatizan que sin ajustes profundos y datos supervisados, los autoencoders pueden no captar variaciones sutiles indicativas de problemas tempranos. Concordando con Chen et al. (2022) pues también mostró limitaciones en una muestra reducida, indicando la necesidad de mayor diversidad y precisión en el ajuste del modelo.

Existen diversas variantes de autoencoders que han sido desarrolladas para mejorar la detección de anomalías. Por ejemplo, los autoencoders convolucionales han demostrado ser efectivos en la detección de anomalías en imágenes, mientras que los autoencoders recurrentes son útiles para datos secuenciales, como series temporales (Esmaeili et al., 2023). Además, se han propuesto métodos híbridos que combinan autoencoders con otros algoritmos de detección de anomalías, como el Isolation Forest, para mejorar la precisión y reducir los falsos positivos (Almansoori & Telek, 2023). Un ejemplo es el estudio Arshad et al. (2022), donde utilizaron un modelo híbrido CNN-BiGRU-Att para detectar eventos de marcha, como el golpe del talón (HS) y el despegue del dedo (TO), utilizando un único sensor inercial colocado en la pelvis, logrando una

precisión del 99.73%, pero su aplicación en condiciones reales se limita debido a falta de pruebas en entornos no controlados.

También, se han desarrollado autoencoders variacionales, que no solo buscan reconstruir los datos, sino que también aprenden una distribución probabilística de los mismos, lo que permite generar nuevos datos similares a los de entrenamiento (Hore et al., 2023). Además, las redes neuronales profundas permiten clasificar automáticamente diferentes tipos de marcha, como normal, analgésica y atáxica, al entrenar modelos con ejemplos específicos de cada categoría, lo que permite a los modelos distinguir con precisión entre ellas y facilita su aplicación en análisis biomecánicos (Janiesch et al., 2021). Lo que se llevó a cabo en el estudio de Shi et al. (2023) donde desarrollaron un modelo específicamente CNN unidimensional y LSTM bidireccional (SConvLSTM), extrayendo automáticamente características espaciales y temporales de las señales, pero presenta limitaciones al clasificar actividades similares, como estar sentado o de pie, y depende de datos de longitud fija, lo que dificulta analizar actividades irregulares propias del envejecimiento.

De manera similar, el trabajo de Zheng et al. (2023) implementó IMUs junto con la técnica SHAP para interpretar los patrones biomecánicos de la marcha en un modelo explicativo, aunque la intensidad computacional de SHAP y la falta de un estándar para evaluar la calidad de las explicaciones limitaron su aplicabilidad práctica. Finalmente, el estudio de Mulas et al. (2021) utilizó un enfoque analítico transversal basado en la extracción de características de parámetros de marcha mediante IMUs, pero se encontraron limitaciones tecnológicas para capturar patrones complejos debido a la falta de algoritmos avanzados de aprendizaje profundo. En conjunto, estos estudios subrayan la importancia de adaptar y diversificar los métodos IMU en la modelización biomecánica para abordar las complejidades de la marcha en poblaciones con diferentes características y condiciones de movilidad.

En cuanto a las métricas de evaluación en la detección de anomalías, la precisión, el recall y el F1-score son fundamentales para medir el rendimiento de los modelos. La precisión indica la proporción de verdaderos positivos sobre el total de positivos predichos, mientras que el recall refleja la proporción de verdaderos positivos sobre el total de positivos reales (Chen et al., 2021). El F1-score, que es la media armónica entre la precisión y el recall, proporciona una única métrica

que considera tanto la precisión como la exhaustividad del modelo (Nicholaus et al., 2021). Estas métricas son esenciales para evaluar la efectividad de los autoencoders en la detección de anomalías, ya que permiten entender no solo cuántas anomalías se detectan correctamente, sino también cuántas se pasan por alto o se identifican erróneamente como anómalas (Battikh & Lenskiy, 2021).

#### 2.1.4.2. Estimación de la velocidad de la marcha

Anteriormente se mencionó la velocidad de la marcha como indicador de la movilidad y funcionalidad de una persona y su relación con el deterioro cognitivo. La detección de “bouts” o episodios de marcha es fundamental para estimar justamente dicha velocidad (Narváez & Aranda, 2021). La velocidad de la marcha puede ser evaluada tanto en entornos controlados como no controlados, cada uno con características y consideraciones específicas. En los entornos controlados, las pruebas instrumentadas son herramientas fundamentales aplicadas en laboratorios o clínicas. Entre los métodos más utilizados se encuentran el Timed Up and Go (TUG), el Test de Velocidad de la Marcha (TVM) y la Short Physical Performance Battery (SPPB), las cuales permiten evaluar no solo la velocidad, sino también la capacidad funcional y el riesgo de caídas (Bitencourt et al., 2020).

El TUG se utiliza para evaluar la movilidad funcional al medir el tiempo que una persona tarda en levantarse de una silla, caminar una distancia específica, girar y regresar a la silla (Palacios Freire et al., 2024). Por otro lado, el TVM se utiliza para medir la velocidad a la que una persona puede caminar una distancia determinada, generalmente 10 metros, y se ha asociado con la predicción de caídas y deterioro funcional (Kim & Choi, 2024). En cuanto al SPPB, es una herramienta ampliamente utilizada para evaluar el rendimiento físico en adultos mayores compuesto por tres pruebas clave: equilibrio, tiempo para levantarse de una silla cinco veces, y velocidad de la marcha en un trayecto de 3 a 4 metros (Hanada et al., 2020).

Los valores de referencias para el SPPB, como los estudiados por Lee et al. (2021), indican que los puntajes disminuyen con la edad. Un SPPB  $\leq 11$  puntos se considera un indicador útil para detectar limitaciones funcionales significativas y fragilidad, mientras que un SPPB  $\geq 10$  puntos sugiere ausencia de fragilidad y recomienda un monitoreo periódico para la detección precoz tras eventos significativos de salud (Metanmo et al., 2023). Tanto (Yang et al., 2022) como (Pavlin et al.,

2022) concluyeron que un puntaje bajo en la subprueba de velocidad de marcha puede indicar deterioro en la marcha y el equilibrio. Justamente la detección de esos bouts lentos o irregulares funcionan como un marcador para evaluar el riesgo de deterioro y las mejoras en los puntajes del SPPB y en la velocidad de marcha se asocian con una reducción en eventos adversos como caídas y re-hospitalizaciones (Gustavson et al., 2022)

Aunque estas pruebas son actividades diarias habituales (levántese, camina, gira y siéntate) y son efectivas en entornos controlados, su capacidad para reflejar la funcionalidad real en la vida diaria puede ser limitada (Rast et al., 2022). Por ejemplo, las condiciones de laboratorio pueden sobreestimar las capacidades funcionales de los individuos, ya que los pacientes tienden a desempeñarse mejor en estos entornos. Esto se ve agravado por el estrés o ansiedad que puede inducir un entorno clínico, como lo reportaron (Palacios Freire et al., 2024). Comparaciones entre entornos controlados y no supervisados, como las realizadas por (Ma, 2022), han demostrado que la velocidad de marcha y la variabilidad del ritmo son mayores durante el TVM en comparación con las condiciones de vida diaria.

En los últimos años, la integración de tecnologías como teléfonos inteligentes ya son capaces de rastrear la velocidad de las personas con alta fiabilidad (Obuchi et al., 2018). Un claro ejemplo es el estudio de (P.-A. Lee et al., 2023), utilizaron sensores inerciales integrados en teléfonos móviles para estimar la velocidad de marcha mediante un modelo basado en el "inverted pendulum" , demostrando su validez y confiabilidad tanto en entornos supervisados como no supervisados. De manera similar, los IMUs colocados en diferentes puntos del cuerpo, como tobillos, cintura o cabeza, han mejorado la capacidad de obtener datos detallados y precisos sobre la marcha (Tedesco et al., 2023). Caso del estudio de Tasca et al. (2024) donde evaluaron un modelo basado en aprendizaje profundo para detectar ciclos de marcha y estimar la velocidad utilizando un sensor inercial colocado en la cabeza, el cual presento una alta precisión en condiciones del mundo real, con errores medios absolutos inferiores a 0.08 m/s.

La velocidad de la marcha es una variable funcional que puede estimarse directamente a partir de las lecturas de un acelerómetro, como lo explicaron (Takayanagi et al., 2019). Este enfoque permite comparar los valores estimados por el sensor con mediciones de referencia para calcular su precisión y error (Cobo et al., 2021). Sin embargo, hay dos principales desafíos en la

cuantificación de las medidas de marcha utilizando sensores inerciales, por un lado, hay que identificar en qué momentos el anciano está caminando (bouts) y por otro lado hay que hacer la estimación en sí para cada bout. Esto es fundamental para asegurar que los datos recolectados sean representativos de la actividad real del paciente y no de movimientos no relacionados con la marcha (Ullrich et al., 2020).

Si bien es cierto, los datos crudos obtenidos por estos sensores son procesados mediante algoritmos avanzados y métodos de aprendizaje automático, permitiendo estimar métricas clave como la velocidad de marcha de forma confiable y eficiente (Pérez Molinet et al., 2021). Pero determinar los bouts en los ciclos de la marcha es necesario para obtener medidas precisas y significativas de la marcha (Kirk et al., 2023). Por lo que la validación de esos algoritmos que detectan y segmentan "bouts" de marcha es esencial para garantizar la fiabilidad de las mediciones obtenidas a través de los dispositivos (O'Brien et al., 2022).

Teufl et al. (2021), Vavasour et al. (2021) y Kang et al. (2021) coinciden en la importancia de la velocidad de marcha como biomarcador clave para evaluar patologías y fragilidad en adultos mayores. Teufl utilizó un modelo One-Class Support Vector Machine (OCSVM) para identificar patrones patológicos mediante características como el rango de movimiento y la asimetría articular, logrando una AUC de 0.96. Por su parte, Vavasour utilizando IMUs y Random Forest en la prueba 6MWT, destacando la velocidad de marcha y parámetros como tamaño del paso y distancia total caminada, con un AUC de 0.93, aunque excluyó a personas con movilidad reducida. Kang, en un enfoque complementario, demostró que el cinturón inteligente WELT permite estimar velocidades de marcha diarias asociadas a sarcopenia, observando variaciones según la masa muscular, edad y el momento del día. El algoritmo permitió estimar mediante la detección de picos en eventos de golpe del talón, pero la falta de validación del algoritmo y la exclusión de mujeres o personas con movilidad reducida limitan la generalización de los resultados y pueden introducir errores en patrones de marcha atípicos.

Soltani et al. (2021) desarrollaron un modelo combinado "cALL", que integró múltiples algoritmos y mejoró significativamente la precisión de las estimaciones de velocidad de marcha en condiciones controladas al reducir el RMSE de 0.10 a 0.32 m/s. Sin embargo, su dependencia a entornos controlados y la exclusión de factores dinámicos como giros destaca la necesidad de

validaciones en contextos reales y con poblaciones más diversas. Aspectos abordados por Mueller et al. (2019), donde utilizaron sensores inerciales en la cintura para monitorear continuamente la velocidad de marcha en adultos mayores frágiles tanto en entornos clínicos como reales, logrando una precisión destacada (error estándar < 0.1 m/s). El algoritmo procesa la señal de aceleración de cada eje dividiéndola en ventanas solapadas de 2.5 segundos, luego verifica la validez de las ventanas analizando la frecuencia dominante y la inclinación del tronco. Posteriormente aplica una transformada de Hilbert en cada eje y estima la velocidad de la marcha utilizando los valores de amplitud obtenidos mediante el modelo de regresión lineal previamente entrenado. Sin embargo, se identificó diferencias significativas entre las velocidades medidas en escenarios reales y clínicos, lo que resaltó la necesidad de métodos que capturen la complejidad de la marcha diaria.

Considerando lo anterior, Cobo et al. (2023) evaluó la validez y confiabilidad del algoritmo de Mueller et al. (2019) junto con el de Czech et al. (2020) y Urbanek et al. (2018) para estimar la velocidad de marcha de adultos mayores en condiciones reales, utilizando el sensor portátil ActiveUP. Pero debido a que algunos pasos del algoritmo no estaban detallados con precisión en la descripción original de Mueller, desarrollaron su propia adaptación. Donde el uso de ventanas de 2.5 segundos con solapamiento del 50%, la selección de la frecuencia dominante en cada ventana, el descarte de frecuencias menores a 0.5 Hz y la eliminación del filtro Butterworth; permitieron lograr una alta validez ( $r = 0.837$  en tramos cortos) y confiabilidad ( $ICC = 0.935$  en tramos largos). No obstante, resaltaron la necesidad de evaluar la capacidad de generalización de dicho algoritmo mediante distintas muestras y desarrollar un algoritmo que identifique intervalos de caminata (bouts).

Shah et al. (2020) complementó estos avances al demostrar, mediante modelos de análisis de curvas de crecimiento, que la longitud de los intervalos de marcha afecta las métricas de marcha. Identificando que intervalos cortos (<12 pasos) son más frecuentes en la vida diaria y proporcionan mediciones más fiables y discriminativas para detectar alteraciones de la marcha. Por su parte, Soliman et al. (2022) desarrolló un modelo de regresión lineal combinado con análisis de componentes principales (PCA) para estimar las fases de la marcha en entornos no supervisados logrando un error promedio de 2.21%. Proporcionando así una base para relacionar

las fases con patrones de velocidad, pero con limitaciones operativas que restringen su uso en condiciones reales.

El uso de algoritmos como SVM y RF ha revolucionado la estimación de parámetros de marcha, permitiendo alta precisión tanto en contextos normativos como clínicos. Chan et al. (2024), emplearon SVM para analizar datos de acelerómetros de muñeca de 92,022 adultos, logrando estimaciones confiables de velocidades máximas (1.49 m/s) y habituales (1.15 m/s), lo que permitió establecer valores normativos de marcha diaria (7,749 pasos diarios). Sin embargo, su generalización se vio limitada por el sesgo poblacional, con predominio de mujeres y adultos mayores con niveles socioeconómicos altos. Davis et al. (2021), por su parte, utilizaron Gradient Boosted Trees para identificar predictores de velocidad habitual (UGS), máxima (MGS) y reserva de marcha (GSR) en 3925 adultos mayores del estudio TILDA donde factores como la edad, fuerza de agarre y tiempo para levantarse de una silla resultaron ser determinantes.

Complementando estos enfoques, Phan et al. (2020) exploró Random Forest Regression para analizar la ataxia de la marcha, identificando métricas avanzadas como la irregularidad de velocidad (Fuzzy Entropy) y la amplitud de frecuencia de resonancia (FFT), logrando correlaciones altas con evaluaciones clínicas ( $r = 0.81$ ). Kraus et al. (2022) también aplicó RF con plantillas sensoriales para identificar fragilidad física, superando herramientas tradicionales como el TUG Test con un AUROC de 0.919. De manera similar, García-de-Villa et al. (2024) optimizó un modelo SVM con Grid Search para clasificar riesgos de caída, identificando 16 parámetros significativos de la marcha y superando al Gait Speed Test (77.0%) y al TUG Test (65.6%).

Por otro lado, Soltani (2020) y Hwang et al. (2024) destacan el potencial de combinar estos algoritmos avanzados para el análisis de la marcha. Soltani empleó SVM con datos de IMUs en muñeca y parte baja de la espalda, para clasificar eventos de marcha y estimar velocidad a partir de características biomecánicas como intensidad, periodicidad y postura. Aun con precisión del 96 % y un error RMS de 0.05 m/s al caminar, no consideró velocidades bajas ni terrenos irregulares. Por su parte, Hwang utilizó RF y SVM para clasificar patrones normales y anormales, logrando una precisión de hasta 99 % RF superando a SVM (88%). No obstante, la generalización de sus resultados se ve limitada debido a que la muestra incluyó solo 19 participantes saludables.

## 2. 2. PROBLEMÁTICA

El envejecimiento poblacional es uno de los fenómenos sociales más significativas del siglo XXI, con repercusiones sociales, económicas y sanitarias a nivel global (ONU, 2022). En 2021, las personas mayores de 65 años representaban el 9,54% de la población global, casi duplicando el porcentaje registrado en 1960, lo que refleja un incremento exponencial de 150 millones a 747 millones de personas en ese periodo (Mena Roa, 2022). Este crecimiento continuará acelerándose, para 2050 se proyecta que más del 22% de la población mundial será mayor de 60 años, pasando de 1.000 millones en 2020 a 2.100 millones en 2050, mientras que la población de mayores de 80 años se triplicará hasta llegar a 426 millones. Aunque inicialmente este fenómeno predominaba en países de altos ingresos, actualmente afecta de manera acelerada a países de ingresos bajos y medianos, los cuales albergarán dos tercios de la población mayor para 2050, lo que genera desafíos en infraestructura y políticas de salud en contextos con recursos limitados (OMS, 2024).

En España, el envejecimiento es especialmente crítico, en 2023 el 22% de la población era mayor de 65 años, y para 2050 se proyecta que una de cada tres personas supere esta edad (34%) (INE, 2024). Sin embargo, solo el 50% de esta población vive en condiciones de buena salud, enfrentando una alta prevalencia de enfermedades crónicas y deterioro funcional, incluidas la fragilidad y el riesgo de dependencia (Alonso Bouzón & Rodríguez Mañas, 2021). Dicho deterioro, es uno de los principales desafíos asociados al envejecimiento pues impacta al 18% de las personas mayores de 65 años y hasta al 38% de los mayores de 85 años (Allison et al., 2021; Úrsula Segoviano, 2024).

La fragilidad, definida como un síndrome geriátrico caracterizado por la disminución de la capacidad para enfrentar factores estresantes, incrementa el riesgo de dependencia, hospitalización y mortalidad (Fried et al., 2001). Aunque el envejecimiento es inevitable, la fragilidad puede prevenirse e incluso revertirse mediante intervenciones adecuadas. Este síndrome también tiene un impacto económico considerable: en España, el costo anual por persona frágil asciende a 2.500 euros, el doble que para una persona mayor sin fragilidad (Úrsula Segoviano, 2024). Sin embargo, su detección temprana sigue siendo limitada en países como

Honduras, donde la fragilidad a menudo pasa desapercibida, aumentando la dependencia y discapacidad en la vejez (OMS, 2021).

Aunque herramientas como la escala de FRAIL y el fenotipo de Fried han demostrado ser eficaces en la identificación de personas en riesgo de discapacidad (Bertolazzi et al., 2024), su aplicación está limitada en países como Honduras, donde la detección temprana de la fragilidad es prácticamente inexistente, lo que incrementa los niveles de dependencia y la discapacidad en la vejez (OMS, 2021). La identificación de la fragilidad es crucial para implementar intervenciones adecuadas que mejoren los resultados de salud y la calidad de vida de los adultos mayores (Ghosh et al., 2023).

En América Latina, se prevé que la proporción de personas mayores de 60 años pasará del 8% en 2020 al 14% en 2030, lo que plantea desafíos en términos de infraestructura y políticas de salud (Keating et al., 2021). Honduras, aunque con un envejecimiento menos acelerado que España, también enfrenta un futuro demográfico preocupante. En 2023, solo el 5,3% de la población tenía más de 65 años, pero este grupo está creciendo rápidamente. Además, la esperanza de vida saludable ha disminuido de 61,2 años en 2000 a 60 años en 2021, reflejando las limitaciones del sistema sanitario para satisfacer las necesidades de esta población (Banco Mundial, 2021). Cerca del 40% de los adultos mayores carece de acceso regular a servicios médicos, agravando su vulnerabilidad (Cantú-Martínez, 2022).

En este contexto, las caídas representan un desafío crítico, tanto en España como en Honduras, aunque con particularidades diferentes. En España, las caídas son una de las principales causas de hospitalización y dependencia en personas mayores, con más de 53.200 fracturas anuales (Rodríguez-Moliner et al., 2015). En Honduras, el problema se agrava, el 60% de las caídas no recibe atención médica adecuada debido a la insuficiencia de infraestructura sanitaria, especialmente en áreas rurales (Suarez Alemán et al., 2023). En este contexto, tecnologías avanzadas como sensores inerciales portátiles y algoritmos de aprendizaje automático ofrecen soluciones prometedoras en ambos países, desempeñando un papel clave en la detección temprana del deterioro funcional y otras complicaciones relacionadas con el envejecimiento (Blinka et al., 2021).

Un indicador clave en la detección de la fragilidad es la velocidad de marcha (VM), que refleja el estado funcional y permite predecir eventos adversos. Su monitoreo constituye una herramienta esencial en la prevención de complicaciones asociadas al envejecimiento (Lenardt et al., 2021). Métodos como el Timed Up and Go (TUG), el Test de Velocidad de la Marcha (TVM) y la Short Physical Performance Battery (SPPB), permiten evaluar tanto la velocidad como la capacidad funcional en términos de fragilidad (Bitencourt et al., 2020). Sin embargo, pese a dichos avances, uno de los principales obstáculos sigue siendo el costo y la accesibilidad, especialmente en países como Honduras, donde la infraestructura tecnológica y el acceso a dispositivos médicos avanzados son limitados (Kassem et al., 2020). Aunque en España se desarrollan ensayos con tecnologías portátiles en geriatría, su integración a gran escala en los sistemas de salud pública sigue siendo un reto (Singh & Gupta, 2022).

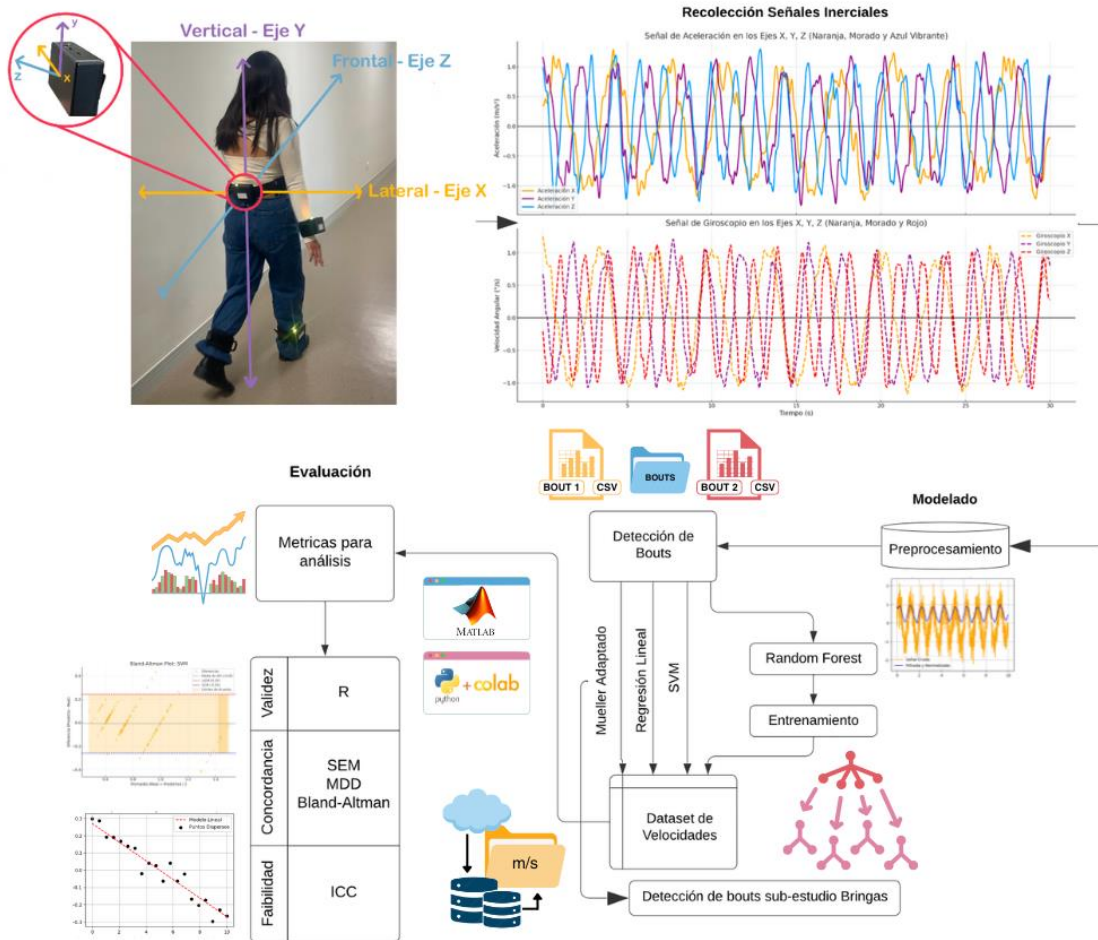
La evolución tecnológica, como los sensores inerciales portátiles han demostrado ser soluciones prometedoras para la evaluación continua de la marcha (Kobsar et al., 2020). En combinación con algoritmos de aprendizaje automático, permiten medir parámetros como la VM y la longitud de los pasos con alta precisión, identificando eventos adversos en la marcha con hasta un 95% de exactitud (Beigh et al., 2023). Sin embargo, en países como Honduras, donde solo el 40% de los adultos mayores tiene acceso regular a servicios médicos, estas tecnologías enfrentan barreras significativas (Suarez Alemán et al., 2023).

A pesar de los avances en e-salud, su impacto en la atención clínica de personas mayores frágiles sigue siendo limitado debido a los altos costos iniciales, el acceso restringido y la falta de capacitación tecnológica (Gwyther et al., 2019). No obstante, proyectos como ActiveUP y MOTIVA, que utilizan sensores vestibles no invasivos, demuestran el potencial de la tecnología para mejorar la calidad de vida de las personas mayores. El incorporar herramientas como señales inerciales y algoritmos avanzados podría transformar la forma de detectar y prevenir el deterioro funcional y la fragilidad, contribuyendo a la sostenibilidad de los sistemas de salud, promoviendo mayor calidad de vida y a enfrentar el envejecimiento poblacional de manera equitativa y eficiente.

### 2. 3. IMAGEN INTEGRADORA

Los métodos tradicionales para evaluar la marcha en adultos mayores, como mediciones manuales y pruebas clínicas estandarizadas, son útiles, pero carecen de precisión y no permiten un monitoreo continuo en entornos reales. Dificultando así la detección temprana de fragilidad y deterioro funcional, afectando la autonomía y calidad de vida de esta población.

Los IMUs miden en tiempo real parámetros clave, como la velocidad de la marcha, un indicador crucial del estado funcional. Sin embargo, para obtener estimaciones precisas, es necesario procesar los datos mediante modelos avanzados como SVM y RF. Este enfoque permite identificar patrones asociados a la fragilidad, realizar monitoreo no intrusivo y diseñar intervenciones personalizadas que contribuyen a mejorar la calidad de vida (Ilustración 12).



**Ilustración 12 Imagen integradora.**

Fuente: Elaboración Propia.

## 2. 4. CUADRO DE LIMITACIONES

Se analizaron estudios sobre la detección de patrones característicos de la marcha mediante IMUs y autoencoders. Las principales limitaciones relacionadas con la población, el entorno experimental y las características metodológicas se resumen en la Tabla 1.

**Tabla 1 Limitaciones Detección de Patrones en Marcha.**

<b>Autores</b>	<b>Año</b>	<b>País</b>	<b>Enfoque</b>	<b>Tipo de Limitación</b>	<b>Detalle de Limitación</b>
<b>Arshad et al.</b>	2023	Países Bajos	Cuantitativo	Falta de diversidad y representatividad en los datos de entrenamiento.	CNN-RNN con un sensor en la cintura, control de variables y muestra limitada de adultos mayores dificultan la generalización a contextos reales.
<b>Hauth et al.</b>	2021	Estados Unidos	Cuantitativo Descriptivo	Muestra limitada y recolección en condiciones controladas.	El tamaño de muestra y el entorno controlado limitan la generalización, y el BiLSTM pierde precisión con cambios en la marcha.
<b>Arom Gómez Arias et al.</b>	2024	Chile	Cuantitativo Descriptivo	Dificultad para generalizar y variabilidad en el uso del sensor.	La precisión de Random Forest y SVM disminuye en entornos no clínicos debido a la variabilidad y diversidad de la población.
<b>Digo et al.</b>	2023	Italia	Experimental	Dificultad para generalizar y variabilidad en el uso del sensor.	Algoritmo IMU limitado para variaciones complejas; entorno controlado y muestra pequeña afectan adaptabilidad.
<b>Mulas et al.</b>	2021	Italia	Transversal Analítico	Limitaciones tecnológicas y dificultad para captar patrones complejos sin aprendizaje profundo.	Algoritmos de extracción de parámetros de marcha sin autoencoders ni aprendizaje profundo limitan la representación de patrones complejos.
<b>Yoon et al.</b>	2024	Corea del Sur	Transversal	Uso de aprendizaje no supervisado.	Autoencoders no supervisados detectan desviaciones en la marcha, pero su eficacia es limitada sin anomalías reales.

<b>Autores</b>	<b>Año</b>	<b>País</b>	<b>Enfoque</b>	<b>Tipo de Limitación</b>	<b>Detalle de Limitación</b>
<b>Ahmed et al.</b>	2023	Pakistán	Experimental Adaptativo	Falta de datos supervisados y de ajuste profundo del modelo.	Sin datos supervisados o ajuste profundo, los autocodificadores no captan variaciones sutiles en la marcha.
<b>Chen et al.</b>	2021	Taiwán	Cuantitativo y Experimental	Metodológica	El modelo depende de datos etiquetados y la variabilidad individual en patrones de marcha puede afectar la generalización de los resultados en diferentes poblaciones
<b>Huertas-Hoyas et al.</b>	2023	España	Observacional Cuantitativo	Metodológica y contextual	Muestra pequeña y desbalanceada, uso de regresión logística que limita relaciones complejas, y evaluación en entornos controlados restringe la generalización.
<b>Arshad et al.</b>	2022	Corea del Sur	Cuantitativo Y Experimental	Falta de diversidad en la población. y aplicabilidad en entornos reales.	Modelo no fue probado en escenarios de larga duración o en condiciones no controladas.
<b>Chen et al.</b>	2023	Taiwán	Cuantitativo Y Transversal	Falta de diversidad en la población.	Autoencoder para detección de caídas, pero la muestra limitada de 44 adultos impide generalizar.
<b>Zheng et al.</b>	2023	Países Bajos	Experimental Adaptativo	Interpretación limitada y aplicabilidad restringida.	Dificultad para interpretar predicciones y falta de estándares en SHAP, limitando la confiabilidad y aplicabilidad clínica.
<b>Malik et al.</b>	2021	Brunei	Experimental Y Cuantitativo	Tamaño de muestra limitado y falta de diversidad en los datos de entrenamiento.	Autoencoder profundo con solo 16 sujetos, limitando la captura de diversidad en patrones de marcha anormales.
<b>Shi et al.</b>	2023	China	Cuantitativo Y Experimental	Confusión en la clasificación debido a datos similares en actividades específicas y dependencia de longitudes fijas en los datos de entrada.	Dificultad para distinguir actividades similares como estar sentado o de pie, y limitaciones para analizar actividades aperiódicas por el uso de ventanas de tiempo fijo.

**TABLA 1 (CONTINUACIÓN)**

<b>Autores</b>	<b>Año</b>	<b>País</b>	<b>Enfoque</b>	<b>Tipo de Limitación</b>	<b>Detalle de Limitación</b>
Zeng et al.	2020	China	Cuantitativo Y Experimental	Falta de diversidad en la población y dificultad para generalizar	Deep learning con datos de adultos jóvenes, limitado para adaptarse a patrones de marcha en personas con movilidad reducida o mayores.

Fuente: Elaboración Propia

Para examinar la bibliografía desde una perspectiva tecnológica, se desarrolló la Tabla 2, que proporciona una descripción detallada del modelado utilizado en cada investigación, las métricas evaluadas, los sensores empleados (cantidad y modelo), así como el número de entradas (inputs) de cada dispositivo.

**Tabla 2 Limitaciones Técnicas Detección de Patrones en Marcha.**

<b>Estudio</b>	<b>Métrica</b>	<b>Modelado</b>	<b>Sensor</b>	<b>Inputs</b>
(Arshad et al., 2023)	Precisión: en seis rangos de tolerancia GRU alcanzó 99.47% con $\pm 6$ ms y 78.98% con $\pm 1$ ms.	Cuatro modelos de aprendizaje profundo: MLP, CNN, LSTM y GRU. El GRU fue el más preciso.	IMU, colocado en la cintura.	6 inputs.
(Hauth et al., 2021)	Precisión, AUROC y AUPR.	Regresión logística regularizada y red neuronal recurrente tipo BiLSTM (Bidirectional Long Short-Term Memory).	IMUs Opal de APDM Inc., miden aceleración y velocidad angular en tres ejes.	32 características cinemáticas x ventana 10s.
(Arom Gómez Arias et al., 2024)	Precisión.	Algoritmos de clasificación: RF, SVM con núcleo RBF y Regresión Logística.	Acelerómetro de tres ejes.	Múltiples parámetros de marcha del acelerómetro de tres ejes se usaron sin especificar número exacto de inputs.
(Digo et al., 2023)	Precisión, Coeficiente de Pearson, RMSE y gráficos Bland-Altman	Algoritmo de detección de picos y patrones.	IMUs MTx de Xsens con sensores triaxiales	45 inputs (5 sensores x 9 ejes)
(Mulas et al., 2021)	Correlación de Spearman y ANOVA para vincular marcha y estado cognitivo.	Software en MATLAB	IMU G-Sensor® de BTS Bioengineering, incluye acelerómetro triaxial	3 inputs; ejes de movimiento (anteroposterior, mediolateral y vertical)

Estudio	Métrica	Modelado	Sensor	Inputs
(Yoon et al., 2024)	Pearson y ANOVA evaluaron edad, marcha y ángulos	Software especializado.	IMU Human Track de R. Biotech Co. Ltd., (X, Y, Z) T	21 inputs (7 sensores × 3 ejes)
(Ahmed et al., 2023)	Precisión, recall y F1-score.	Redes Neuronales Profundas (DNN) y Convolucionales (CNN).	IMU Human Track de R. Biotech (X, Y, Z) T	3 inputs x sensor (no especifica cuantos sensores)
(Chen et al. 2021)	Precisión, sensibilidad y especificidad en los ejes vertical, medio lateral y anteroposterior.	Autoencoder apilado (SAE) con un clasificador softmax.	Acelerómetro triaxial RD3152MMA7260Q, región lumbar	3 inputs/sensor, transformados a tiempo-frecuencia con wavelet de Morlet.
(Huerta-Hoyas, 2023)	Regresión logística y análisis estadísticos como el coeficiente de variabilidad (CV)	Procesamiento estadístico convencional (regresión logística)	IMU - G-STRIDE (X, Y, Z) T	3 inputs x 1 sensor
(Arshad et al., 2022)	Precisión y error absoluto medio (MAE)	Modelo híbrido CNN-BiGRU-Att	IMU - Xsens MVN (Enschede, Países Bajos)	18 inputs (3 sensores x 6 ejes)
(Chen et al., 2023)	Precisión, AUC y F1-score	Autoencoder	Acelerómetros triaxiales	3 inputs por cada sensor (X,Y,Z)
(Zheng et al., 2023)	Exactitud, Sensibilidad, Precisión, F1-score y AUC.	CNN para una zancada y GRU para ocho zancadas consecutivas	Acelerómetro triaxial en dispositivos como iPod, Dynaport o ActiGraph.	3 inputs por cada sensor (X,Y,Z)
(Malik et al., 2021)	Precisión, AUC y F1-score, Sensibilidad	Autoencoder	Sensores MEMS	6 inputs x 1 sensor MEMS
(Shi et al., 2023)	Precisión, curva ROC y área bajo la curva ROC (AUC). y F1-score.	Algoritmo híbrido SConvLSTM que combina 1D-CNN para características locales y Bi-LSTM para secuenciales.	IMU - HuGaDB MPU9250	6 inputs x 1 sensor

Estudio	Métrica	Modelado	Sensor	Inputs
(Zeng et al., 2020)	AUC y EER	FCN para aprendizaje supervisado y autoencoder para no supervisado.	IMU - (X, Y, Z) T	3 inputs x 1 sensor

Fuente: Elaboración Propia

Se seleccionaron estudios que desarrollaron o evaluaron modelos de machine learning, específicamente SVM y RF, para estimar la velocidad de la marcha. Las principales limitaciones se presentan en la Tabla 3.

**Tabla 3 Limitaciones Estimación Velocidad de la Marcha.**

Autores	Año	País	Enfoque	Tipo de Limitación	Detalle de Limitación
(Soltani et al., 2021)	2021	Suiza, Italia y Reino Unido	Cuantitativo, experimental y transversal	Contextual y metodológica.	Entornos controlados con caminatas en línea recta, excluyendo giros. Tamaño de muestra limitado y asunción de altura fija de 170 cm por falta de datos específicos.
(Mueller et al., 2019)	2019	Suiza, participación internacional en sitios clínicos (32 sitios globales).	Cuantitativo, experimental y descriptivo	Contextual y metodológica. Entorno e inconsistencia de uso de dispositivo.	Variabilidad en el cumplimiento del uso de los dispositivos, influencia de factores externos como clima y calzado, y requisitos mínimos de uso definidos (3 días con al menos 3 horas diarias).
(Cobo, Villalba-Mora, et al., 2023)	2023	España	Observacional, Prospectivo y Transversal.	Muestral y contextual.	Muestra pequeña (15 sujetos), generando intervalos de confianza amplios, y las velocidades reales no siempre cumplen umbrales clínicos para decisiones terapéuticas.
(Phan et al., 2020)	2020	Australia	Cuantitativo, experimental, transversal.	Metodológica y tecnológica.	Datos limitados a entornos clínicos y dependencia de sensores específicos, dificultando la generalización a usos cotidianos.
(Kraus et al., 2022)	2022	Alemania	Cuantitativo y transversal	Muestral y metodológica.	Muestra limitada (57 pacientes) y enfoque restringido a SPPB $\leq 8$ , sin incluir otros indicadores clínicos como caídas o discapacidad progresiva.

<b>Autores</b>	<b>Año</b>	<b>País</b>	<b>Enfoque</b>	<b>Tipo de Limitación</b>	<b>Detalle de Limitación</b>
(García-de-Villa et al., 2024)	2024	España	Cuantitativo, experimental, transversal.	Muestral y tecnológica.	Muestra limitada (157 pacientes) y sesgos por usar datos de un solo pie, sin analizar caídas futuras ni entornos cotidianos.
(Soltani, 2020)	2020	Suiza	Cuantitativo, experimental	Metodológica y tecnológica.	Algoritmo probado solo con Physilog 4 en condiciones controladas, lo que limita su generalización y no aborda variaciones de marcha en velocidades bajas o terrenos irregulares.
(Hwang et al., 2024)	2024	Corea del Sur	Cuantitativo, experimental, transversal.	Muestral y contextual.	Muestra pequeña (10 sujetos saludables) y simulaciones controladas, limitando su aplicación a pacientes con impedimentos articulares reales.
(L. L. Y. Chan et al., 2024)	2024	Australia	Cuantitativo, experimental, transversal.	Muestral y contextual.	Muestra dominada por personas saludables, limitada representación de grupos friles y desafíos en el monitoreo continuo durante periodos prolongados.
(Davis et al., 2021)	2021	Irlanda	Cuantitativo, experimental, transversal.	Contextual y metodológica.	Entorno controlado que limita la generalización y menor precisión de la reserva de velocidad (GSR), lo que podría afectar su utilidad en ciertos contextos clínicos.
(Teufl et al., 2021)	2021	Austria y Alemania	metodología cuantitativa experimental con un diseño descriptivo y transversal.	Experimental y muestral.	Variabilidad en los patrones de marcha por fases de aceleración y desaceleración, un grupo normativo sesgado hacia jóvenes activos y un tamaño de muestra reducido.
(Soliman et al., 2022)	2022	Estados Unidos	Cuantitativa experimental con diseño descriptivo.	Experimental y contextual.	Modelo de regresión depende de patrones de laboratorio, limitando su generalización y precisión por la selección de características con PCA.
(Vavasour et al., 2021)	2021	China	Cuantitativo, observacional y experimental.	Metodológica y muestral.	Muestra limitada, se excluyó a personas con capacidad limitada para caminar largas distancias, reduciendo la representatividad de aquellos con mayor fragilidad.

<b>Autores</b>	<b>Año</b>	<b>País</b>	<b>Enfoque</b>	<b>Tipo de Limitación</b>	<b>Detalle de Limitación</b>
(Shah et al., 2020)	2020	Estado Unidos	Cuantitativo y descriptivo, con análisis transversal.	Muestral y modelado.	Modelo limitado a intervalos cortos puede no reflejar patrones en intervalos largos. Tamaño reducido de la muestra (29 con Parkinson y 20 neurotípicos), lo que afecta la generalización.
(Kang et al., 2021)	2021	Corea del sur.	Cuantitativo, observacional y descriptivo.	Generalización y muestral.	Incluyó solo hombres mayores de 50 años sin problemas para caminar y un algoritmo no validado, limitando precisión y generalización en contextos reales y patrones atípicos.

Fuente: Elaboración Propia

Con un enfoque tecnológico, se desarrolló la Tabla 4, especificando los modelos empleados para la estimación de la velocidad de la marcha por los distintos estudios, las métricas evaluadas y el sensor utilizado.

**Tabla 4 Limitaciones Técnicas Estimación Velocidad de la Marcha.**

<b>Estudio</b>	<b>Métrica</b>	<b>Modelado</b>	<b>Sensor</b>
(Soltani et al., 2021)	Error cuadrático medio (RMSE)	Combinación de enfoques biomecánicos, integración directa de aceleración y aprendizaje automático.	IMU Opal™ de APDM en la parte inferior de la espalda
(Mueller et al., 2019)	Error estándar residual (RSE), Coeficiente de correlación (r)	Transformada de Hilbert y filtro Butterworth para detectar pasos y calcular velocidad mediante modelos lineales ajustados.	IMU Actibelt RCT2 (Trium Analysis Online, Alemania), que registra datos a 100 Hz con 12 bits de resolución y un rango de $\pm 6$ g.
(Cobo et al., 2021)	Coeficiente de correlación de Pearson (r), Intraclase (ICC), error estándar de medición (SEM) y diferencias mínimas detectable (MDD)	Algoritmos lineales: Mueller, GaitPy, Urbanek	IMU ActiveUP, seis grados de libertad y un microcontrolador ESP32, que registra datos a 18 Hz.
(Phan et al., 2020)	Correlación con escalas clínicas (ECA y SARA), Error cuadrático medio (RMSE)	Random Forest, Fuzzy Entropy y Transformada Rápida de Fourier (FFT):	BioKin (IMU) con acelerómetros, giroscopios y brújulas triaxiales colocados en el torso y tobillos, muestreados a 50 Hz.

Estudio	Métrica	Modelado	Sensor
(Kraus et al., 2022)	Área bajo la curva ROC y error de clasificación	Random Forest, K-Nearest Neighbor (KNN)	Science3 (Moticon, Alemania), con 19 sensores de presión y un giroscopio 3D integrados
(García-de-Villa et al., 2024)	Precisión, Sensibilidad, F1-Score	SVM-Kernel lineal optimizado con Grid Search, usando 16 parámetros significativos ( $p < 0.05$ ) y validado con K-Fold (10 pliegues),,	Physilog 6S (GaitUp) módulo inercial iNEMO (LSM6DSRX, STMicroelectronics)
(Soltani, 2020)	Precisión, Error RMS	SVM, GNSS de forma ocasional, Comparación con tapetes instrumentados y algoritmos multi-IMU	IMU Physilog 4
(Hwang et al., 2024)	Precisión, F1-score, sensibilidad	SVM (Kernel Lineal), RF (Criterio Gini), XGB (Árboles secuenciales optimizados) y RFECV (Recursive Feature Elimination with Cross-Validation): Selección de características clave como ángulo sagital de la rodilla y TSR (Temporal Symmetry Ratio).	IMU eCEN) con acelerómetros y giroscopios triaxiales, montados en muslos y espinillas, con muestreo a 50 Hz.
(X. Chen et al., 2024)	Error absoluto medio (MAE), Precisión, Sensibilidad	SVM, Validación cruzada de 10 particiones	Axivity AX3, acelerómetros triaxiales
(Davis et al., 2021)	Coefficiente de determinación ajustado (velocidad usual (UGS), máxima (MGS) y reserva de velocidad (GSR))	Histogram Gradient Boosting Regressor (HGBR) (árboles de decisión en un conjunto secuencial)	Sistema GAITRite (pasillo instrumentado con sensores integrados)
(Teufl et al., 2021)	Precisión de clasificación, AUC, ROC	One-Class Support Vector Machine (OCSVM), kernel gaussiano, Escalado de probabilidades	IMUs MTw Awinda, fabricadas por Xsens Technologies BV
(Soliman et al., 2022)	Error promedio de estimación de fase de marcha, promedio general y rango de error.	Análisis de componentes principales (PCA) para reducción de características y modelo de regresión lineal para predicción de fases de marcha.	IMUs (Precision NXP 9-DOF, Adafruit, EE. UU.) colocados en la pierna y el pie.

<b>Estudio</b>	<b>Métrica</b>	<b>Modelado</b>	<b>Sensor</b>
(Vavasour et al., 2021)	Área bajo la curva (AUC), sensibilidad, especificidad y precisión.	RF, Árboles de Decisión, Naïve Bayes, Redes Neuronales y Descenso de Gradiente Estocástico.	Sistema de Sensores Ambuloso, IMU conectado a la aplicación iOS Gait Reminder
(Shah et al., 2020)	Coeficiente de correlación intraclase (ICC) para fiabilidad y área bajo la curva (AUC) para la capacidad discriminativa.	Modelos de análisis de curva de crecimiento para evaluar cómo las métricas de marcha escalan con la longitud de los intervalos.	IMU Opals de APDM (ubicados en los pies y la parte lumbar).
(Kang et al., 2021)	Correlaciones de Pearson, velocidad media de marcha diaria, desviación estándar y coeficiente de variación.	Algoritmo de detección de picos basado en eventos de golpe de talón para analizar la velocidad de marcha.	Cinturón inteligente WELT con acelerómetro triaxial.

Fuente: Elaboración Propia

Entre los estudios destacados se incluyen Cobo et al. (2023), por su validación del algoritmo adaptado de Mueller; Soltani et al. (2021), por su análisis técnico de métricas como el error cuadrático medio; y García-de-Villa et al. (2024), que exploraron técnicas avanzadas de estimación. Además, Hwang et al. (2024) y Arshad et al. (2023) aportaron información sobre limitaciones técnicas y de diversidad en las muestras.

### **III. OBJETIVOS**

En este capítulo, se definen los objetivos del proyecto de investigación, los cuales actuarán cómo modelo de referencia para la metodología que se llevará a cabo durante el desarrollo del presente estudio.

#### **3. 1. OBJETIVO GENERAL**

Desarrollar métodos basados en sensores inerciales vestibles para la estimación de patrones característicos y la velocidad de la marcha en personas mayores empleando análisis de series temporales, técnicas de regresión lineal y aprendizaje automático, con el fin de optimizar la detección de deterioro funcional y elevar la precisión en la evaluación de su estado de salud.

#### **3. 2. OBJETIVOS ESPECÍFICOS**

##### 3.2.1. Detección de Patrones en marcha

Evaluar la viabilidad de las series temporales obtenidas de ActiveUp para la estimación de patrones característicos de la marcha, mediante el desarrollo de un modelo autoencoder.

3.2.1.1. Evaluar la calidad e integridad de los datos de acelerómetros y giroscopios obtenidos de los dispositivos vestibles, asegurando su viabilidad para el análisis de la marcha.

3.2.1.2. Diseñar un modelo basado en autoencoders recurrentes para la obtención de patrones de marcha y su asociación con cambios en el estado de salud.

##### 3.2.2. Estimación Velocidad De La Marcha

Desarrollar modelos para la estimación de la velocidad de la marcha a partir de datos obtenidos de sensores inerciales ubicados en la región lumbar, mediante técnicas de regresión y aprendizaje automático, para optimizar la precisión en la evaluación funcional de la marcha en adultos mayores.

- 3.2.2.1. Evaluar la precisión del algoritmo adaptado de Mueller en la estimación de la velocidad de la marcha utilizando datos inerciales del proyecto MOTIVA mediante métricas de validez y fiabilidad.
- 3.2.2.2. Aplicar el algoritmo adaptado de Mueller para la detección de bouts, utilizando los datos del sub-estudio Bringas del proyecto ActiveUP y analizar su desempeño con métricas de sensibilidad y precisión.
- 3.2.2.3. Desarrollar modelos de estimación mediante técnicas avanzadas de regresión lineal y algoritmos de aprendizaje automático en comparación al modelo adaptado de Mueller.
- 3.2.2.4. Validar los modelos de estimación desarrollados mediante la aplicación de métricas de validez, concordancia y fiabilidad.

## IV. MÉTODOS

En el presente capítulo, se describen los métodos empleados para llevar a cabo la presente investigación, compuesta por la evaluación de dos parámetros. Procurando que los objetivos previamente establecidos se cumplan de forma efectiva a través de su implementación, se presenta un panorama general de la metodología dando inicio con el enfoque de la investigación, la identificación de las variables, las técnicas e instrumentos utilizados. Como parte complementaria, se detalla un cronograma de actividades que proporciona un marco temporal para la realización del proyecto. A su vez se incluye la operacionalización de las variables y una matriz metodológica con el fin de clarificar cada fase del estudio.

### 4.1. ENFOQUE

La metodología empleada en el presente trabajo de investigación se caracteriza por su enfoque cuantitativo, en ambos parámetros se centra en la recopilación y análisis de datos numéricos obtenidos a través de sensores inerciales vestibles (acelerómetros y giroscopios).

#### 4.1.1. Detección de Patrones en marcha

Dado que la investigación se basa en datos obtenidos a lo largo de un periodo de tiempo prolongado y en un entorno natural no controlado, el diseño de la investigación es longitudinal y el enfoque es cuantitativo observacional (Tabla 5). Brindando la posibilidad de reconocer la evolución de las anomalías y, en conjunto con los clústeres obtenidos, relacionarlo con cambios en el estado de salud de los participantes.

**Tabla 5 Detección patrones de la marcha.**

Enfoque	Cuantitativo Observacional
Tipo de diseño	Observacional y Longitudinal
Alcance	Descriptivo
Muestra	No Probabilística por Conveniencia

Fuente: Elaboración Propia

Al no solo buscar documentar, sino también analizar exhaustivamente los patrones de marcha y las anomalías detectadas, el alcance de la investigación es principalmente descriptivo.

Permitiendo que la investigación aporte información sobre la monitorización de la capacidad funcional y la detección temprana de signos de deterioro, destacando la importancia e innovación de realizar un estudio en un entorno real al reforzar la relevancia y aplicabilidad de los resultados.

Cabe destacar que la muestra es no probabilística por conveniencia, compuesta por personas mayores que participaron voluntariamente en el proyecto ActiveUP luego de recibir información verbal y escrita sobre el estudio e incluso firmar el consentimiento informado. Los criterios de inclusión se enlistan en la sección 4.4.1.

#### 4.1.2. Estimación Velocidad De La Marcha

Dado que la investigación se basa en la recopilación de datos durante la ejecución controlada de una prueba específica (SPPB, prueba de marcha de 3 metros), el diseño es observacional y transversal (Tabla 6). El enfoque es cuantitativo observacional, pues se basa en el análisis de datos numéricos obtenidos mediante los sensores inerciales vestibles que registraron los movimientos, en un momento específico mientras un evaluador marcó el inicio y el fin del tramo en un dispositivo. Lo que aseguró un mayor control sobre las condiciones de medición y la calidad de los datos.

El alcance es descriptivo y relacional, al caracterizar variables como la velocidad y explorar relaciones entre estas para desarrollar modelos predictivos útiles en la monitorización funcional de personas mayores. La muestra fue no probabilística por conveniencia, integrada por adultos mayores que participaron voluntariamente en el proyecto Motiva tras firmar el consentimiento informado. Los criterios de inclusión se enlistan en la sección 4.4.2.

**Tabla 6 Enfoque estimación velocidad de la marcha.**

Enfoque	Cuantitativo Observacional
Tipo de diseño	Observacional y Transversal
Alcance	Descriptivo y Relacional
Muestra	No Probabilística por Conveniencia

*Fuente:* Elaboración Propia

## 4. 2. VARIABLES DE INVESTIGACIÓN

### 4.2.1. Variables Dependientes

#### 4.2.1.1. Detección de Patrones en marcha

Se identifican como variables dependientes aquellos rasgos característicos de la marcha obtenidos del procesamiento y análisis de los datos provenientes de los sensores inerciales mediante la implementación de autoencoders y técnicas de clustering. Sin embargo, la variable dependiente como tal, es la clasificación de dichos patrones, diferenciando entre marcha normal y marcha con indicios de deterioro funcional, en otras palabras, marcha normal o anómala.

#### 4.2.1.2. Estimación Velocidad De La Marcha

La variable dependiente en este análisis es la velocidad estimada de la marcha. Adicionalmente, se evalúa la precisión en la detección de los segmentos específicos de la marcha (bouts), representando un paso intermedio clave en el análisis de las señales y el cálculo de las variables de marcha. Se realiza tanto luego del preprocesamiento, como parte de la validez de uno de los algoritmos, Mueller Adaptado, al evaluarlo con datos del sub-estudio bringas del proyecto ActiveUP.

### 4.2.2. Variables Independientes

En ambos parámetros la variable independiente son los datos brutos de IMUs, incluyendo datos de aceleración provenientes de los acelerómetros ( $A_x$ ,  $A_y$ ,  $A_z$ ) y velocidad angular de los giroscopios ( $G_x$ ,  $G_y$ ,  $G_z$ ); que proporcionan datos sobre el movimiento y la orientación del cuerpo (Miranda et al., 2024). Sin embargo, en el análisis de cada parámetro son manejados de forma distinta.

#### 4.2.2.1. Detección de Patrones en marcha

Los datos sensoriales constituyen la entrada inicial al sistema de procesamiento, donde son segmentados en tramos, procesados mediante un autoencoder que genera representaciones latentes, y posteriormente clasificados mediante técnicas de clustering y un clasificador que determina si los patrones de marcha identificados son indicativos de una marcha sana o patológica. Así mismo, la ubicación del sensor (cintura, muslo o pierna) y factores como la duración del estudio (semanas o quincenas de recolección de datos) con relación a la calidad de los datos recolectados, evaluando posibles errores de sincronización o duplicidad de archivos. Además, se consideran el modelo de análisis aplicado, basado en autoencoders recurrentes.

#### 4.2.2.2. Estimación Velocidad De La Marcha

Además de los datos brutos de los IMUs, las variables independientes en este caso incluyen el algoritmo de estimación utilizado (algoritmo de Mueller, adaptación de este, regresión lineal, RF o SVM), y la ubicación del sensor (región lumbar). También se consideran el conjunto de datos empleado (Mueller, MOTIVA, sub-estudio Bringas), la integridad de los registros temporales.

Fuente: Elaboración propia.



**Ilustración 13 Variables de investigación.**

### 4. 3. INSTRUMENTOS Y TÉCNICAS APLICADOS

En esta investigación, se emplearon múltiples instrumentos para recopilar y analizar los datos de la marcha de los pacientes. Entre los principales instrumentos utilizados se incluyen sensores inerciales, el lenguaje de programación Python con sus librerías especializadas, y el entorno de ejecución de Google Colaboratory, todos ellos interconectados para facilitar el análisis y procesamiento de datos mediante técnicas de regresión lineal y aprendizaje automático.

#### 4.3.2.1. Sensores inerciales

En el primer parámetro, orientado a la detección de patrones de marcha asociados al deterioro funcional, los sensores inerciales se utilizaron para registrar datos de aceleración (ejes

Ax, Ay, Az) y velocidad angular (ejes Gx, Gy, Gz). Estas señales capturaron los movimientos tridimensionales del cuerpo durante la marcha, proporcionando información detallada para el procesamiento de estos con el fin de identificar patrones que permitan categorizar el estado de salud en marcha sana o patológica.

En el parámetro enfocado en la estimación de la velocidad de la marcha, los sensores inerciales fueron clave para identificar los "bouts" (segmentos específicos de marcha) y calcular métricas relacionadas con la velocidad. Los datos inerciales se utilizaron como entrada para los modelos de regresión lineal y aprendizaje automático, permitiendo estimar la velocidad de marcha con alta precisión. La combinación de estas señales con algoritmos avanzados y técnicas de extracción de características potenció el análisis, asegurando resultados fiables y relevantes para la evaluación funcional.

#### 4.3.2.2. Google Colab

Google Colab, o Colaboratory, es una plataforma de Google que permite a los usuarios ejecutar código de Python en un entorno basado en la nube. Esta herramienta es especialmente popular entre investigadores, estudiantes y profesionales en el campo del aprendizaje automático y la ciencia de datos, debido a su accesibilidad y la capacidad de colaborar en tiempo real (Bisong, 2019). Se utilizó en ambos parámetros, tanto para la elaboración de códigos para el preprocesamiento de los datos del proyecto ActiveUP, como el desarrollo de los algoritmos para la estimación de la velocidad con los datos del proyecto MOTIVA.

#### 4.3.2.3. Python

Python es un lenguaje de programación de alto nivel que ha aumentado en gran cantidad su popularidad debido a su simplicidad y versatilidad. Su extenso ecosistema de bibliotecas facilita la visualización y el análisis de datos, lo que lo convierte en una herramienta clave en entornos de ciencia de datos, inteligencia artificial y desarrollo web. A diferencia de otros lenguajes, Python permite escribir soluciones con menos líneas de código, optimizando el desarrollo y acercándolo a aplicaciones reales de forma más eficiente.

Entre las bibliotecas utilizadas se encuentran las siguientes:

- *Scikit-Learn*: Ampliamente utilizada para el aprendizaje automático, conocida por su API de fácil uso y su extensa documentación. Su compatibilidad con otras bibliotecas como

NumPy y Pandas, esenciales para la manipulación y el análisis de datos, la convierte en una opción versátil para la construcción y evaluación de modelos de machine learning (Chatelain et al., 2021).

- *Pandas*: Biblioteca de código abierto para la manipulación y análisis de datos estructurados. Su capacidad para manejar grandes volúmenes de datos tabulares de forma eficiente la ha consolidado como una herramienta indispensable para científicos de datos (Chandel et al., 2023).
- *Numpy*: Es la abreviatura de Numerical Python, una biblioteca fundamental para la computación numérica. Ofrece soporte para matrices y arrays multidimensionales de gran tamaño, junto con funciones matemáticas de alto rendimiento para operar con ellos (Harris et al., 2020).
- *Seaborn*: Biblioteca de visualización que se basa en Matplotlib, proporciona una interfaz de alto nivel para crear gráficos estadísticos de calidad. Una herramienta clave en el análisis exploratorio de datos por lo que es una opción preferida para muchos analistas y científicos de datos (Waskom, 2021).
- *Matplotlib*: Fundamental para la visualización de datos. Su flexibilidad permite crear desde gráficos simples como de línea, dispersión, barras, hasta visualizaciones complejas; adaptándose a diversas necesidades de visualización (Pajankar, 2022).

#### 4.3.2.4. Matlab

MATLAB es un entorno de programación y un lenguaje de programación de alto nivel que se utiliza principalmente para el cálculo numérico, la visualización de datos y la programación (Cechinel et al., 2022). Una de sus características más destacadas es su capacidad para manejar grandes conjuntos de datos y realizar análisis estadísticos. Por esa razón se utilizó en el desarrollo del parámetro sobre la estimación de la velocidad de la marcha. El desarrollo del algoritmo de Mueller fue realizado en Matlab, por lo que la regresión lineal con los datos de MOTIVA se realizó en el mismo programa.

#### 4.3.2.5. Canva y Datawrapper

Canva es una plataforma de diseño gráfico en línea que permite a los usuarios crear una amplia variedad de contenido visual, como presentaciones, infografías, carteles, publicaciones

para redes sociales y más, de manera intuitiva y accesible (Ramirez Vilchez et al., 2022). Por lo que se utilizó para la creación de las ilustraciones anexadas en la presente investigación. Así mismo, Datawrapper, una herramienta en línea diseñada para facilitar la visualización de datos estadísticos de manera creativa y concisa.

#### 4.3.2.6. R

R es un lenguaje de programación y un entorno ampliamente utilizado para la computación estadística y la creación de gráficos. Diseñado específicamente para el análisis de datos, R ha experimentado un notable desarrollo y actualización en sus herramientas de visualización durante los últimos años (D. Chan & Galli, 2020). En este contexto, se utilizó R para calcular diversas métricas estadísticas, como la correlación de Pearson, que evalúa la relación lineal entre dos variables; el coeficiente de correlación de concordancia, que mide la precisión y concordancia entre dos conjuntos de mediciones; y el análisis de Bland-Altman, que cuantifica la desviación entre valores predichos y valores de referencia o reales. Además, el cálculo del error estándar de medición (SEM) que permite estimar la magnitud del error asociado a cada valor, facilitando la identificación de discrepancias y la evaluación de predicciones en distintos modelos. Gracias al lenguaje de programación R y a las bibliotecas disponibles, es posible automatizar estos cálculos, optimizando el análisis de datos y mejorando la interpretación de resultados.

#### 4.3.2.7. Pruebas y herramientas complementarias

Para la estimación de la velocidad de la marcha, se incorporaron técnicas de evaluación estandarizada, destacando la prueba SPPB. Esta evaluación consta de tres componentes principales: una prueba de equilibrio, un test de velocidad de marcha de 3 o 4 metros y un test de levantarse de una silla cinco veces (Sáez de Asteasu et al., 2024). La SPPB ha demostrado ser una herramienta fiable para valorar aspectos fundamentales como el equilibrio y la velocidad de la marcha (Souweine et al., 2024).

Dado que empleó específicamente la prueba de marcha de 3 metros, durante su desarrollo, se utilizó un iPad/Tablet con una aplicación diseñada en el marco del proyecto MOTIVA, la cual permitió registrar manualmente los momentos de inicio y fin del recorrido. Estos eventos se sincronizaron con los datos obtenidos de los sensores inerciales, proporcionando una referencia precisa para la identificación de los bouts (segmentos de marcha), desde el inicio hasta la

finalización del trayecto. Esta metodología garantizó una mayor precisión en la evaluación y facilitó el análisis detallado de las variables de marcha.

#### **4. 4. POBLACIÓN**

Ambos análisis reflejan un esfuerzo por desarrollar y validar tecnologías para la evaluación de la marcha y la funcionalidad física en adultos mayores, por lo que esa es su población principal. Sin embargo, cada enfoque establece criterios específicos de inclusión y exclusión.

##### **4.4.1. Detección de Patrones en marcha**

Este se llevó a cabo en el marco del proyecto ActiveUP, cuyo objetivo es validar el uso de sensores vestibles para medir la velocidad de la marcha en adultos mayores durante sus actividades cotidianas. Inicialmente, se planificó trabajar con una muestra de 50 participantes, siguiendo las recomendaciones de la iniciativa COSMIN para estudios de fiabilidad y validez.

La población objetivo incluyó personas de 70 años o más, capaces de deambular con o sin ayuda de instrumentos de movilidad, y que cumplieran al menos un criterio de la escala de fragilidad de Fried. Se excluyeron participantes que no quisieron o no pudieron otorgar su consentimiento informado, quienes no comprendieron las instrucciones (verificado mediante una prueba simple de interacción con el dispositivo), y aquellos considerados clínicamente inestables por el investigador. El reclutamiento se llevó a cabo en el Hospital de Día y en Consulta Externa del Servicio de Geriátrica del Hospital Universitario de Getafe, así como entre familiares y conocidos de los investigadores.

##### **4.4.2. Estimación Velocidad De La Marcha**

Para el estudio se llevó a cabo dentro del proyecto MOTIVA, estudio observacional prospectivo para obtener señales de movimiento y resultados de la prueba SPPB, específicamente la prueba de marcha de 3 metros.

El reclutamiento se realizó en el Hospital de Día y Consulta Externa del Servicio de Geriátrica del Hospital Universitario de Getafe, así como en Centros de Mayores y Centros de Día en municipios de Madrid. Los participantes interesados firmaron un consentimiento informado y fueron evaluados para confirmar su elegibilidad. Durante las sesiones experimentales, los participantes realizaron la prueba SPPB estándar con sensores colocados en la parte baja de la espalda, muñecas y tobillos, tal como se muestra en la Ilustración 13.



**Ilustración 14 SPPB Prueba de velocidad de la marcha en 3 metros.**

Fuente: Elaboración propia.

Las señales de movimiento se registraron en las memorias internas de los dispositivos, mientras que los resultados de las pruebas se registraron en una Tablet. Cabe destacar que el protocolo fue aprobado por el Comité de Ética del Hospital Universitario de Getafe (CEIm24/08). Los criterios de inclusión fueron: tener 70 años o más, una puntuación SPPB  $\geq 4$ , y la capacidad de deambular con o sin ayuda. Se excluyó a quienes no pudieran consentir, entender instrucciones o presentaran contraindicaciones clínicas.

#### 4.4.2.1. Detección de bouts

Se partió del algoritmo adaptado de Mueller, donde se utilizaron los datos obtenidos en el sub-estudio Bringas, parte del proyecto ActiveUP. En el mismo se reclutó a personas mayores y se registraron sus señales de movimiento durante tramos cortos y largos de marcha de 2, 4 y 6 metros.

Se siguieron criterios similares al proyecto MOTIVA, con la excepción de una prueba adicional para verificar la comprensión de instrucciones. Esta consistió en pedir a los participantes que identificaran el botón de encendido/apagado del dispositivo y describieran el significado de la luz que se activaba al presionarlo. El reclutamiento se realizó en las mismas instituciones y

también entre familiares y conocidos del equipo de investigación. Se otorgo a los participantes el tiempo necesario para considerar su participación, con la opción de posponer la decisión, y se les proporcionó un número de contacto para resolver dudas o concertar una cita posterior.

Los participantes elegibles firmaron un consentimiento informado y, en algunos casos, también autorizaron la grabación de las sesiones de recogida de datos. Las grabaciones se limitaron a los momentos en los que el sensor estaba en uso, capturaron únicamente imágenes desde la cintura hacia abajo. Estas medidas garantizaron el respeto por la privacidad y la ética de la investigación. El estudio se realizó de acuerdo con la Declaración de Helsinki y el protocolo fue aprobado por el Comité de Ética del Hospital Universitario de Getafe (CEIm21/41).

#### **4. 5. MÉTODO DE ESTUDIO**

Debido a la estructura dividida de este proyecto en dos parámetros independientes, cada uno con objetivos específicos pero complementados por el objetivo de mejorar la precisión y utilidad de los métodos actuales para evaluar el estado de salud de la población mayor, el método de estudio se encuentra en sus respectivas secciones.

##### **4.5.1. Detección de Patrones en marcha**

Según la planificación inicial, fue diseñado con un enfoque exploratorio y experimental, para detectar patrones de marcha asociados al deterioro funcional en personas mayores utilizando los datos recolectados en el proyecto ActiveUP. Estos sensores registraban información en archivos .CSV delimitados por puntos y comas “;” y organizados en columnas que incluían: fecha, hora, timestamp en milisegundos, aceleración en los ejes X, Y, Z, y datos del giroscopio en los mismos ejes.

La metodología propuesta comprendía diversas etapas, las cuales se muestran en la Ilustración 14. Primero, los datos serían recolectados y posteriormente preprocesados mediante técnicas de eliminación de ruido, normalización de señales y sincronización en series temporales continuas para garantizar su calidad. En la siguiente fase, se emplearían autoencoders recurrentes para identificar patrones a cambios funcionales en la marcha. Los patrones detectados serían agrupados mediante técnicas de clustering no supervisado, como K-means o DBSCAN, para identificar similitudes y diferencias entre las señales recolectadas.

Posteriormente, se planificó el desarrollo de un clasificador supervisado que diferenciara patrones de marcha saludables de aquellos anómalos, evaluando su desempeño mediante métricas como precisión, recall y F1-score. Sin embargo, durante el preprocesamiento de los datos, se identificaron problemas graves en cuanto a su integridad.



**Ilustración 15 Metodología propuesta estudio detección patrones en la marcha.**

Fuente: Elaboración propia.

Durante el preprocesamiento, se realizaron verificaciones para detectar anomalías en los archivos .csv. Se observó que algunos usaban "," o espacios en blanco como delimitadores, por lo que fueron revisados y estandarizados al delimitador (;), identificando como anomalías aquellos con delimitadores inconsistentes. Se encontraron archivos duplicados con sufijos \_rep o .csv1, y se comparó su contenido para determinar si eran idénticos o presentaban variaciones. Además, se detectaron fechas imposibles en ciertas mediciones, aplicando un ciclo que verificaba fila por fila y cotejaba con la columna "Date" para identificar discrepancias cronológicas. En la columna "Time", se calcularon diferencias entre filas consecutivas, marcando como salto significativo cualquier diferencia superior a 60 segundos. Pese a los intentos de corregir las incidencias con distintas alternativas, la inviabilidad de los datos imposibilitó la continuación del análisis y las etapas posteriores de esta metodología.

#### 4.5.2. Estimación Velocidad De La Marcha

El método de estudio empleado en el presente se basa en un enfoque secuencial, conocido como paso a paso.

Este enfoque permite abordar de manera estructurada los objetivos específicos planteados, pues divide el proceso en fases ordenadas que deben completarse de manera sucesiva, procurando que todas las fases del trabajo se desarrollen de forma precisa (Ilustración 15).



**Ilustración 16 Método de estudio estimación de la velocidad de la marcha.**

Fuente: Elaboración propia.

#### 4.5.2.1. Revisión de datos

Se realizó un análisis inicial de los datos inerciales recopilados de 31 pacientes participantes del proyecto MOTIVA. Los datos se clasificaron en dos fuentes principales: registros generados por los sensores inerciales y archivos de la aplicación utilizada en las pruebas. Los sensores inerciales, cinco en total, estaban distribuidos estratégicamente en distintas áreas del cuerpo, incluyendo el antebrazo derecho e izquierdo (ID 4-5), la pantorrilla derecha e izquierda (ID 8-9), y la cintura (ID 1), este último siendo el de mayor interés para este estudio debido a su relevancia en la evaluación de la marcha.

```
{
  "evId": 2, "extraId": null, "phsId": "2", "tm": 10758, "res": 1, "sNum": null, "rNum": null, "ts": 1716886207579, "valido": true}
{"evId": 3, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1716886214948, "valido": true}
{"evId": 3, "extraId": null, "phsId": "2", "tm": 10688, "res": 2, "sNum": null, "rNum": null, "ts": 1716886225675, "valido": true}
{"evId": 4, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1716886243958, "valido": true}
{"evId": 4, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1716886246685, "valido": false}
{"evId": 4, "extraId": null, "phsId": "2", "tm": 3217, "res": 4, "sNum": null, "rNum": null, "ts": 1716886247218, "valido": true}
{"evId": 4, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1716886257915, "valido": false}
{"evId": 4, "extraId": null, "phsId": "3", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1716886259070, "valido": false}
{"evId": 4, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1716886265329, "valido": true}
{"evId": 4, "extraId": null, "phsId": "2", "tm": 2636, "res": 4, "sNum": null, "rNum": null, "ts": 1716886268004, "valido": true}
{"evId": 5, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": 1, "ts": 1716886338292, "valido": true}
{"evId": 5, "extraId": null, "phsId": "2", "tm": null, "res": null, "sNum": 0, "rNum": 1, "ts": 1716886339659, "valido": true}
{"evId": 5, "extraId": null, "phsId": "2", "tm": null, "res": null, "sNum": 0, "rNum": 2, "ts": 1716886341124, "valido": true}
```

**Ilustración 17 Revisión de datos - detección de bouts**


Fuente: Elaboración propia.

Los archivos de la aplicación contenían registros organizados mediante marcas de tiempo y eventos, indicados con la variable evID, que identificaba la naturaleza de cada prueba. Para este parámetro, la prueba de velocidad de marcha en 3 metros, marcada con el evID 4, fue de especial interés. Dentro de esta prueba, se utilizaron marcas de tiempo adicionales registradas por la variable phsID, que indicaban el inicio (phsID 1) y el final (phsID 2) de la marcha. Estas marcas permitieron segmentar cada serie en dos tramos: ida y regreso, asegurando una organización sistemática para los siguientes análisis.

#### 4.5.2.2. Preprocesamiento

Se identificaron los rangos de tiempo correspondientes a las pruebas de caminar 3 metros. A partir de la variable evID 4, asociada a la prueba SPPB\_VM3, y en conjunto con las marcas phsID 1 y phsID 2, se determinaron los intervalos de tiempo exactos para cada serie de marcha. Esto permitió segmentar las señales por intervalos de marcha (bouts), facilitando el análisis posterior.

Con esta información, se diseñó un algoritmo que extrajo automáticamente los rangos de tiempo identificados. Dichos rangos se utilizaron para filtrar las señales registradas por los sensores inerciales, seleccionando únicamente las mediciones relevantes de aceleración (ejes x, y, z) y giroscopio (ejes x, y, z). Los datos filtrados se almacenaron en archivos individuales, organizados por paciente, fecha, identificador de sensor (1 es el sensor de la región lumbar) y el bout; guardados en una carpeta específica denominada "filtrados". Este proceso garantizó una estructura de datos limpia y organizada para las etapas siguientes del estudio.



#### **Ilustración 18 archivos resultantes de preprocesamiento.**

Fuente: Elaboración propia.

#### 4.5.2.3. Desarrollo y entrenamiento de modelos

Se desarrollaron diversos modelos, tanto de regresión lineal como no lineal, utilizando algoritmos de aprendizaje automático (machine learning) para estimar la velocidad de la marcha. Mediante la transformada de Hilbert aplicada a los segmentos (Bouts) de prueba, se

implementaron distintitos enfoques que siguieron procesos similares de preprocesamiento, entrenamiento y evaluación, pero, con variaciones en los algoritmos utilizados.

#### 4.5.2.3.1. Comparativa Mueller y su adaptación

El estudio de Mueller et al. (2019) demostró la capacidad de capturar con precisión la velocidad de marcha en entorno reales en adultos mayores con sarcopenia, validando el monitoreo digital a largo plazo de la movilidad en poblaciones geriátricas. Los resultados evidenciaron que si es posible recopilar datos suficientes para realizar un seguimiento de los patrones de la marcha en contextos no clínicos. Dado que los datos y el código de dicho estudio estaban a disposición de la comunidad, se utilizó su código como base.

Sin embargo, debido a falta de información para su correcta ejecución, fue necesario realizar una adaptación de este. Para validar que la adaptación realizada por Cobo et al. (2023) ofrecía el mismo desempeño y resultados equivalentes a los obtenidos por Mueller, se llevó a cabo una comparativa de ambos algoritmos utilizando los mismos datos y métricas. Buscando confirmar la viabilidad de la adaptación para estimar la velocidad de la marcha en nuevos contextos y con diferentes conjuntos de datos.

##### 4.5.2.3.1.1. Detección de bouts

El mismo algoritmo adaptado de Mueller fue utilizado para la delimitación de segmentos de caminata estable (bouts). Sin embargo, el estudio de Cobo et al. (2023) mostró limitaciones en su implementación, particularmente en relación con la amplitud de los intervalos de confianza y el cumplimiento de criterios clínicos. Con el objetivo de superar dichas limitaciones, el algoritmo fue modificado e implementado nuevamente en Matlab para mejorar su precisión.

##### a Procesamiento

Siguiendo lo establecido en el estudio de Cobo et al. (2023), las señales inerciales evaluadas correspondieron a aquellas obtenidas mediante el sensor ActiveUP, utilizado en el subestudio de Bringas. Estas señales fueron segmentadas en ventanas de 2.5 segundos con un solapamiento del 50%. Adicionalmente, se aplicaron filtros para eliminar el ruido y garantizar que las señales representaran de manera precisa los movimientos reales del usuario. Posteriormente, se calculó la inclinación (pitch) del dispositivo a lo largo del tiempo, lo que permitió evaluar la

postura durante la marcha. Las señales resultantes fueron divididas en ventanas con las mismas características.

#### b Aplicación de criterios

Para identificar correctamente los bouts, se tomaron en consideración diversos criterios. Se estableció que existía una frecuencia dominante cuando las frecuencias principales de los ejes verticales coincidían con las de la dirección del movimiento. Además, se definió un umbral empírico para la potencia de la frecuencia dominante, asegurando que los segmentos seleccionados reflejaran una actividad significativa.

Inicialmente, se contempló un rango de valores promedio de inclinación que fueran compatibles con una postura erguida. No obstante, este criterio fue descartado tras observar inconsistencias entre los valores calculados de inclinación y las grabaciones de video. Dichas discrepancias afectaron la precisión del algoritmo, por lo que se decidió priorizar los criterios de frecuencia dominante y nivel de actividad, lo que permitió mejorar la precisión general del método.

#### c Evaluación

El desempeño del algoritmo fue evaluado mediante métricas como precisión, sensibilidad y especificidad al igual que los algoritmos evaluados, tal como se observa en la Ilustración 18.

#### 4.5.2.3.2. Regresión Lineal con Mueller

Dada su viabilidad, se aplicó la misma adaptación del algoritmo de Mueller desarrollada en Matlab a los datos del proyecto MOTIVA, con el objetivo de evaluar su capacidad de adaptación y generalización. El proceso comenzó con el preprocesamiento de los datos, previamente explicado, que consistió en la obtención de los bouts previamente delimitados, es decir, en los archivos segmentados correspondientes a cada uno de los tramos de 3 metros de la prueba SPPB. A partir de estos segmentos, se calcularon las amplitudes en los planos frontal, lateral y vertical mediante la aplicación de la transformada de Hilbert.

El conjunto de datos resultante, compuesto por las amplitudes, fue introducido en el algoritmo adaptado de Mueller, basado en una regresión lineal previamente entrenada con el conjunto de datos original de Mueller. Durante este proceso, se utilizaron los coeficientes de la regresión lineal, que incluyen:  $b$  (intercepto),  $b_F$  (coeficiente de amplitud frontal),  $b_L$  (coeficiente de amplitud

lateral) y  $bV$  (coeficiente de amplitud vertical), todos obtenidos durante el entrenamiento original de Mueller.

Finalmente, al combinar las amplitudes de MOTIVA con los coeficientes mencionados y ejecutar el código, se obtuvo la estimación de la velocidad de marcha correspondiente a los datos del proyecto MOTIVA.

#### 4.5.2.3.3. Regresión Lineal con MOTIVA

Siguiendo el mismo enfoque que en el caso de lineal con Mueller, tras el preprocesamiento y el cálculo de amplitudes, se cargó el archivo en un modelo de regresión lineal desarrollado en el entorno de Google Colab. A diferencia del anterior, este modelo fue entrenado exclusivamente con datos de MOTIVA. El conjunto se dividió en un 70% para entrenamiento y un 30% para evaluar su funcionamiento. Tras el entrenamiento, se obtuvieron los coeficientes, los cuales se aplicaron en la misma fórmula de linealidad, utilizada en el caso de lineal con Mueller:  $Vel\_res = b + AmpF * bF + AmpL * bL + AmpV * bV$ . Esta fórmula permitió estimar la velocidad de marcha para cada paciente, generando un nuevo conjunto de datos ( $Vel\_res$ ) con las predicciones correspondientes.

#### 4.5.2.3.4. Árboles de Regresión (Random Forest - RF)

El modelo de Random Forest también utilizó los datos de amplitud de MOTIVA, sin embargo, tal como se muestra en la Ilustración 18, su proceso es distinto. Tras la limpieza del archivo para eliminar filas vacías o inconsistentes, se generó un nuevo dataset, al que se añadió una columna;  $predicted\_speed$ , para almacenar las estimaciones de velocidad. El modelo se entrenó con 100 árboles, minimizando el sobreajuste y mejorando la estabilidad. Utilizando la librería `sklearn.ensemble`, se creó una matriz con las amplitudes como variables de entrada ( $X$ ) y las velocidades de referencia como salida ( $y$ ). Las predicciones finales se integraron al conjunto de datos original, que contiene el paciente, el bout, la velocidad de referencia/real y la velocidad predicha.

#### 4.5.2.3.5. Máquina de soporte vectorial (Support Vector Machine SVM)

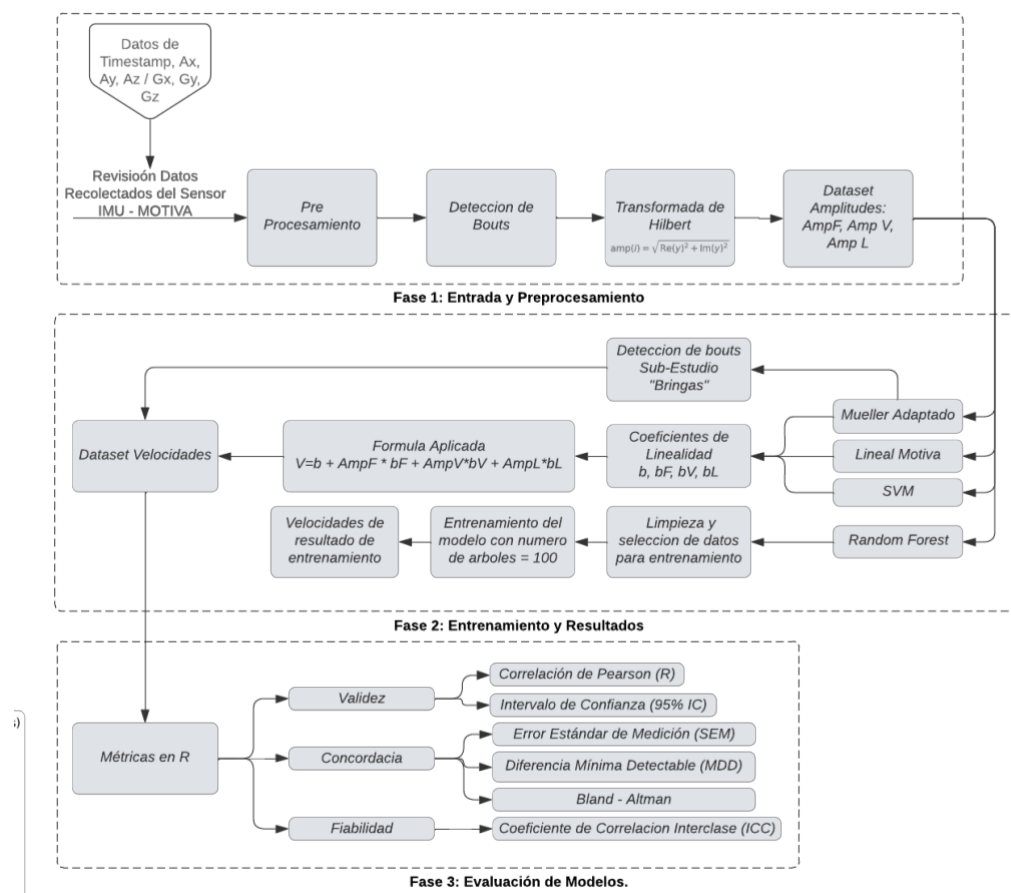
Siguiendo un procedimiento similar a los enfoques anteriores, se utilizó la librería `sklearn.svm` que importa la función `svr` para poder utilizar `svm` de forma lineal. Al entrenar el modelo con los datos de MOTIVA y una vez ajustado, se obtuvieron los coeficientes lineales mencionados en los

modelos anteriores, el intercepto (b) y los coeficientes correspondientes a cada amplitud (bF, bL, bV). Los mismos fueron utilizados para generar predicciones, las cuales se añadieron a los datos originales en una nueva columna denominada svm\_motiva. Al igual que en los modelos precios, se realizó una fusión (merge) de las predicciones con los datos originales, utilizando como claves los identificadores de paciente (SUBJID), la fecha y el número de bout.

Finalmente, todos los resultados fueron guardados en Google Drive, preservando la estructura original del conjunto de datos. Se generaron curvas de aprendizaje que permitieron evaluar el rendimiento del modelo durante las fases de entrenamiento y validación, ofreciendo una visión detallada sobre su estabilidad y capacidad de generalización de cada enfoque

#### 4.5.2.4. Evaluación de los algoritmos

Tras obtener los resultados de los modelos, se generó un dataset consolidado con todas las velocidades predichas, permitiendo así evaluar el desempeño de los algoritmos de estimación utilizados en este estudio.



**Ilustración 19 Resumen método de estudio estimación de la velocidad de la marcha.**  
Fuente: Elaboración propia.

El análisis se llevó a cabo mediante un script en R, diseñado para calcular métricas claves relacionadas con la validez, consistencia y fiabilidad de los modelos. El proceso comenzó con la preparación y limpieza de los datos. Para analizar la validez de las predicciones, se emplearon la correlación de Pearson y el coeficiente de correlación concordante (CCC), proporcionando una cuantificación precisa del grado de relación y concordancia entre las predicciones de los modelos y los valores de referencia. Además, se generaron representaciones gráficas, como diagramas de Bland-Altman y rectas de regresión, que facilitaron la interpretación visual de los niveles de acuerdo entre las mediciones.

La estabilidad de los modelos fue evaluada a través de un análisis prueba-reprueba (test-retest), calculando métricas como (SEM) y los límites de acuerdo (LOA). Se realizaron pruebas estadísticas, incluyendo Shapiro-Wilk y Levene, para verificar las suposiciones de normalidad y homocedasticidad, aspectos esenciales para garantizar la robustez y fiabilidad de los resultados.

Adicionalmente, se calculó el coeficiente de correlación intraclass (ICC) con el fin de medir la fiabilidad de cada modelo, evaluando su capacidad para generar predicciones consistentes bajo diferentes condiciones. Este enfoque integral permitió identificar las fortalezas y limitaciones de cada algoritmo, facilitando la selección del modelo más confiable para la estimación de velocidades de marcha en futuros análisis.

#### **4. 6. METODOLOGÍA DE VALIDACIÓN**

La metodología de validación empleada en esta investigación se fundamenta en la comparación de los resultados obtenidos mediante diferentes métodos y técnicas utilizadas para procesar los datos. Este enfoque busca evaluar la precisión de los algoritmos desarrollados al estimar la velocidad real del paciente, utilizando técnicas estadísticas que permiten determinar la eficiencia y el desempeño de cada modelo analizado.

##### **4.6.1. Estimación Velocidad de la Marcha**

La validez de un instrumento se define como su capacidad para medir con precisión aquello que pretende evaluar; en este caso, la velocidad de la marcha. Para garantizar la validez de los modelos propuestos, se compararon los valores de velocidad estimados por los algoritmos con los obtenidos mediante métodos de referencia, analizando la correlación (R) entre ambos

conjuntos de datos. Cuando fue relevante, se incluyeron intervalos de confianza del 95% (IC 95%) y se utilizó un nivel de significancia estadística fijado en 0.05 para interpretar los resultados.

La concordancia entre las mediciones se evaluó mediante diversas métricas. Se calculó el (SEM), que mide la variabilidad inherente de las mediciones del instrumento. Haciendo uso de las estimaciones de SEM, se calculó la (MDD), la cual indica el cambio más pequeño que puede considerarse real y no debido al error de medición. Ambas métricas permiten cuantificar la precisión del instrumento y determinar el cambio más pequeño que puede detectarse con confianza. Así mismo, la MDD se comparó con la diferencia mínima de relevancia clínica (MCID), lo que permitió determinar si las discrepancias observadas eran significativas desde una perspectiva práctica o terapéutica.

Cabe destacar que el cálculo del SEM y la MDD se realizó mediante un análisis de varianza de medidas repetidas (ANOVA), utilizando la función *aov* en R. También que para utilizar ANOVA fue necesario verificar la normalidad de los datos mediante la prueba de Shapiro-Wilk (*shapiro.test* en R), y la igualdad de varianzas entre grupos con la prueba de Levene (*leveneTest*, paquete *car*).

Los límites de concordancia superior e inferior (uLOA y lLOA) se calcularon realizando un análisis de Bland-Altman con el paquete *blandr* en R. Este análisis permitió evaluar de forma cuantitativa la concordancia entre los métodos, determinando si las diferencias entre mediciones eran aceptables dentro del rango de 95%.

Por último, para evaluar la fiabilidad de las mediciones, es decir, su consistencia, se aplicó el método de fiabilidad test-retest, una técnica ampliamente utilizada en ese tipo de estudios. Dado que la velocidad de la marcha es una variable continua, se calculó el coeficiente de correlación intraclase (ICC) empleando un modelo ICC (A,1) haciendo uso de la función *icc* del paquete *irr* en el software estadístico R, versión 4.2.1. El ICC mide el grado de similitud o concordancia entre valores obtenidos bajo condiciones similares. El modelo (A,1) hace referencia al modelo de efectos aleatorios, ideal si se busca analizar la fiabilidad generalizable. El número 1 indica que el análisis se basa en una medición única por sujeto (no en un promedio de mediciones repetidas). En otras palabras, este coeficiente evalúa la consistencia de las estimaciones de velocidad realizadas por los modelos en comparación con la velocidad real.

Las métricas mencionadas permiten una validación completa de los modelos desarrollados y evaluados, procurando que su diseño sea preciso, eficiente y adecuado para su aplicación práctica y reproducibilidad.

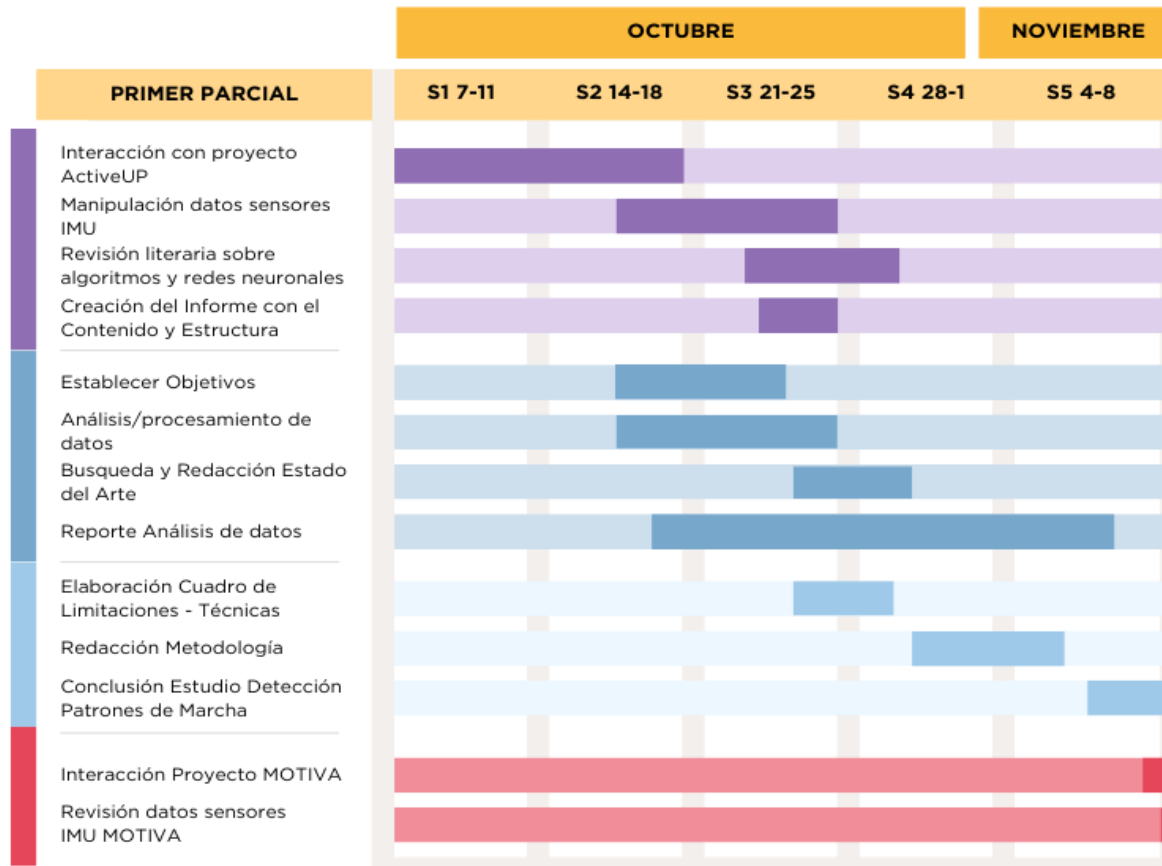
#### 4.6.1.1. Detección de bouts

La detección de bouts se caracterizó como un problema de clasificación y se evaluó calculando la precisión y el alcance (recall) en la detección de bouts reales en el conjunto de datos activeUP de simulaciones de actividades de la vida diaria (ADL). Los verdaderos positivos (TP) se definieron como bouts detectados dentro de los límites de un bout real; los falsos positivos (FP) como bouts detectados fuera de los límites de un bout real; y los falsos negativos (FN) como aquellos bouts reales cuyos límites no contenían ningún bout detectado. Los verdaderos negativos (TN) no se aplican en este caso.

Para evaluar la capacidad del algoritmo para delimitar los bouts, se utilizaron las métricas de precisión y alcance, definidas de la siguiente manera: el recall mide qué proporción de un bout real ha sido detectada y se define como la proporción de la duración de un bout real que se encuentra dentro de los límites de un bout detectado. Por otro lado, la precisión mide qué proporción de un bout detectado coincide con un bout real y se define como la proporción de un bout detectado que se encuentra dentro de los límites de un bout real. Para ambas métricas se reportaron los valores promedio.

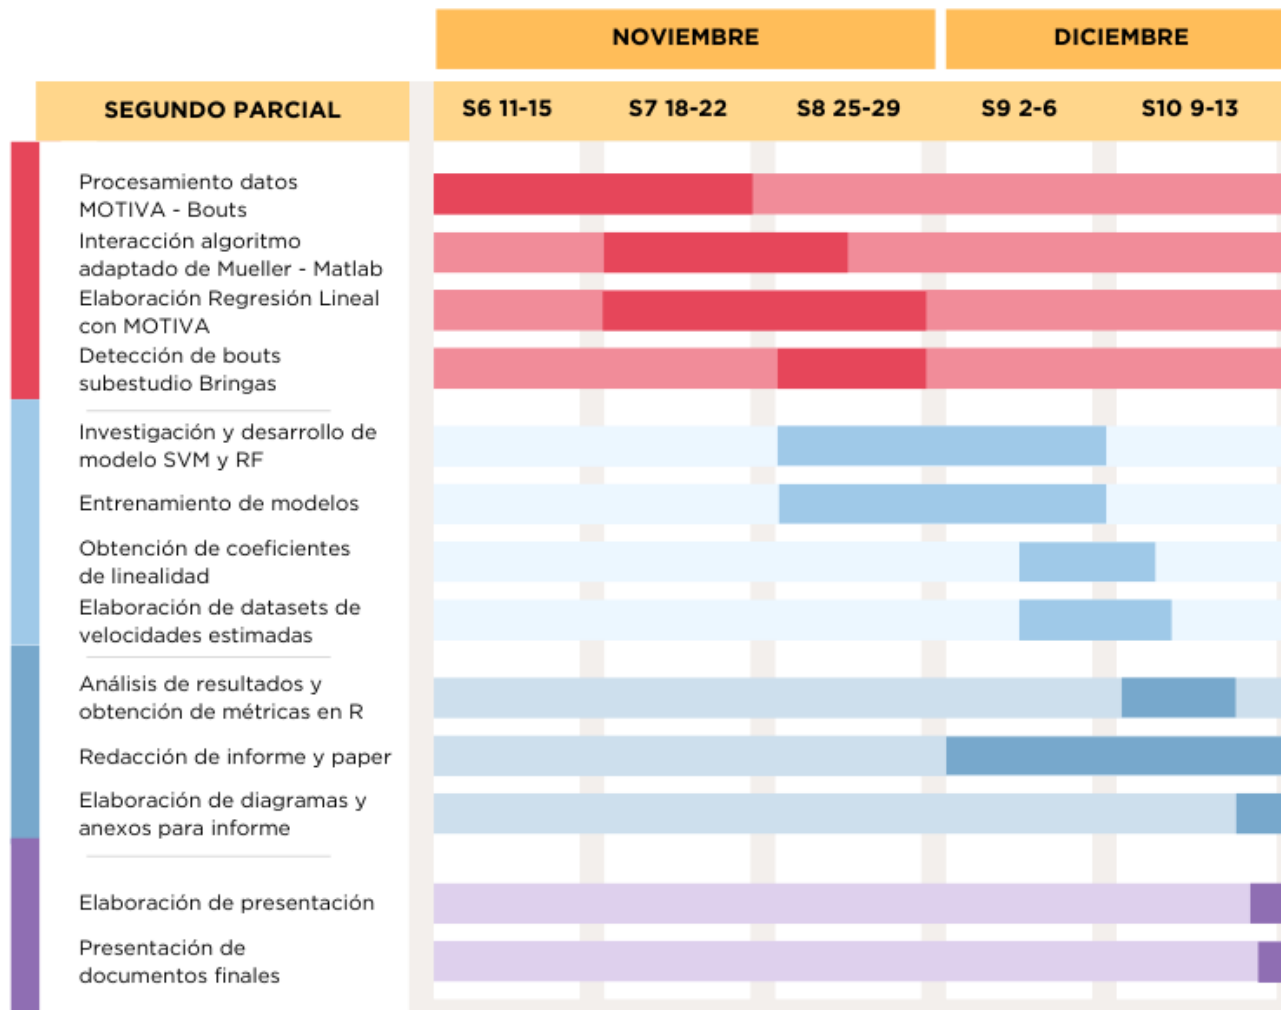
#### 4. 7. CRONOGRAMA DE ACTIVIDADES

El cronograma de actividades muestra de forma visual cada actividad realizada, delimitando el tiempo destinado a cada tarea y señalando el inicio y final de todo el proceso de investigación (Ilustración 19 y 20).



**Ilustración 20 Cronograma de actividades primer parcial.**

Fuente: Elaboración propia.



**Ilustración 21 Cronograma de actividades segundo parcial.**

Fuente: Elaboración propia.

#### 4. 8. OPERACIONES DE LAS VARIABLES

A continuación, se presenta la operacionalización de variables, consiste en establecer de manera metódica las variables que serán analizadas durante el desarrollo de la investigación (Tabla 7).

**Tabla 7 Operacionalización de variables.**

<b>OBJETIVO GENERAL</b>	<b>VARIABLE DEPENDIENTE</b>	<b>DEFINICIÓN CONCEPTUAL</b>	<b>DIMENSIONES</b>	<b>INDICADORES</b>
Desarrollar un modelo de estimación de la velocidad de la marcha utilizando datos de sensores inerciales ubicados en la región lumbar, mediante técnicas de regresión y aprendizaje automático, con el objetivo de optimizar la precisión en la evaluación funcional de la marcha en adultos mayores.	Estimación de la velocidad de la marcha.	Capacidad del modelo para estimar con precisión la velocidad de desplazamiento durante la marcha a partir de datos de sensores inerciales.	Validez, concordancia y fiabilidad.	Velocidad en m/s (estimada), rango de error (%), Diferencia mínima detectable (MDD).
<b>OBJETIVO ESPECIFICO</b>	<b>VARIABLE DEPENDIENTE</b>	<b>DEFINICIÓN CONCEPTUAL</b>	<b>DIMENSIONES</b>	<b>INDICADORES</b>
Evaluar la precisión del algoritmo adaptado de Mueller en la estimación de la velocidad de la marcha utilizando datos inerciales del proyecto MOTIVA mediante métricas de validez y fiabilidad.	Precisión en la estimación de la velocidad de la marcha.	Exactitud del algoritmo de Mueller en la estimación de la velocidad de la marcha utilizando datos inerciales.	Validez y fiabilidad.	Diferencia media entre velocidad estimada y real (m/s), coeficiente de correlación intraclass (ICC).
Desarrollar modelos de estimación mediante técnicas avanzadas de regresión lineal y algoritmos de aprendizaje automático en comparación al modelo adaptado de Mueller.	Desempeño del modelo de estimación.	Eficiencia y precisión de los modelos de regresión y aprendizaje automático en la estimación de la velocidad de la marcha.	Precisión predictiva, comparabilidad y robustez.	Velocidad promedio estimada (m/s), error absoluto medio (MAE), Rango de error en %.

**TABLA 7. (CONTINUACIÓN)**

Validar los modelos de estimación desarrollados mediante la aplicación de métricas de validez, concordancia y fiabilidad.	Validación del modelo de estimación.	Evaluación del rendimiento y estabilidad de los modelos desarrollados para estimar la velocidad de marcha.	Validez, concordancia y fiabilidad.	Velocidad promedio estimada (m/s), error absoluto medio (MAE), rango de error (%), intervalo de confianza (95% CI).
---	--------------------------------------	--	-------------------------------------	---

Fuente: Elaboración propia.

#### 4. 9. MATRIZ METODOLÓGICA

A continuación, se presenta la matriz metodológica, la cual abarca el estudio de investigación y está alineada con las preguntas de investigación, objetivos, variables, métodos y herramientas de análisis (Tabla 8).

**Tabla 8 Matriz metodológica.**

PROBLEMA DE INVESTIGACIÓN	PREGUNTAS DE INVESTIGACIÓN	OBJETIVOS	VARIABLES	METODOLOGÍA Y HERRAMIENTAS
El envejecimiento poblacional y el aumento de la fragilidad en adultos mayores representan un desafío creciente, especialmente en países con sistemas de salud limitados, donde la detección temprana de esta condición es escasa. La fragilidad, caracterizada por una disminución en la capacidad funcional, incrementa el riesgo de caídas, dependencia y hospitalización, afectando hasta al 38% de los mayores de 85 años y duplicando los costos de atención sanitaria. La velocidad de marcha (VM) se ha consolidado como un indicador clave para predecir la fragilidad y evaluar el estado funcional, sin embargo, en países como Honduras, donde el 60% de las caídas no recibe atención adecuada, la falta de herramientas accesibles y precisas dificulta su monitoreo.		<b>GENERAL</b>	<b>DEPENDIENTES</b>	
	¿Cómo se puede optimizar la detección de fragilidad mediante la estimación de la velocidad de marcha en adultos mayores?	Desarrollar un modelo de estimación de la velocidad de la marcha utilizando datos de sensores inerciales ubicados en la región lumbar, mediante técnicas de regresión y aprendizaje automático, con el objetivo de optimizar la precisión en la evaluación funcional de la marcha en adultos mayores.	Velocidad estimada de la marcha y la precisión de detección de fragilidad.	Procesamiento y análisis de datos de sensores inerciales, Algoritmos de regresión y aprendizaje automático, Pruebas físicas (SPPB), Software: Python, MATLAB, R
		<b>ESPECÍFICOS</b>	<b>INDEPENDIENTE</b>	
	¿Qué precisión tiene el algoritmo adaptado de Mueller en la estimación de la velocidad de marcha en adultos mayores?	Evaluar la precisión del algoritmo adaptado de Mueller en la estimación de la velocidad de la marcha utilizando datos inerciales del proyecto MOTIVA mediante métricas de validez y fiabilidad.	Algoritmo Adaptado de Mueller, datos IMUs ubicación del sensor.	Análisis de precisión con métricas de validez y fiabilidad en R.
		<b>ESPECÍFICOS</b>	<b>INDEPENDIENTES</b>	
	¿Qué técnicas de regresión lineal y algoritmos de aprendizaje	Desarrollar modelos de estimación mediante técnicas avanzadas de regresión lineal y algoritmos de aprendizaje automático en	Conjunto de datos ( MOTIA, Bringas, ActiveUP),	MATLAB, Colab – Python

**Tabla 8. (Continuación)**

<b>PROBLEMA DE INVESTIGACIÓN</b>	<b>PREGUNTAS DE INVESTIGACIÓN</b>	<b>OBJETIVOS</b>	<b>VARIABLES</b>	<b>METODOLOGÍA Y HERRAMIENTAS</b>
<b>Tecnologías emergentes como sensores inerciales y algoritmos de aprendizaje automático ofrecen una oportunidad para mejorar la detección temprana de fragilidad y prevenir el deterioro funcional.</b>	automático presentan mayor precisión en la estimación de la velocidad de marcha?	comparación al modelo adaptado de Mueller.	Algoritmos de aprendizaje automático, Técnicas de regresión lineal	
		<b>ESPECÍFICOS</b>	<b>INDEPENDIENTES</b>	
	¿Cuál es la validez y fiabilidad de los modelos desarrollados para estimar la velocidad de marcha?	Validar los modelos de estimación desarrollados mediante la aplicación de métricas de validez, concordancia y fiabilidad.	Métricas de validez por modelo estimación.	Obtenciones de métricas de validez (R, 95% IC, SEM, MDD, ICC, Bland-Altman) mediante el lenguaje de programación R.

Fuente: Elaboración propia.

## V. RESULTADOS Y ANÁLISIS

En este capítulo, se analizarán y contextualizarán de manera detallada los resultados obtenidos a partir del desarrollo del proyecto, el cual se estructura en torno al estudio de dos parámetros de la marcha: la detección de patrones característicos y la estimación de la velocidad de la marcha, ambos asociados al deterioro funcional y el envejecimiento saludable. Los resultados se expondrán de manera clara y concisa, utilizando tablas y gráficos. Se explorarán las implicaciones e interpretaciones, además de comparar los hallazgos con investigaciones previas. También se abordarán posibles limitaciones del estudio.


### 5.1. Detección de patrones característicos en la marcha

En esta sección, se presentan los resultados obtenidos durante la evaluación de los datos recolectados por IMUs, como parte del estudio ActiveUP. Esta colección de datos, fue diseñado inicialmente con un enfoque exploratorio y experimental debido a la naturaleza innovadora del objetivo y la incertidumbre respecto a los datos recolectados. Este enfoque permitía explorar posibles patrones ocultos en las series temporales de sensores inerciales utilizando autoencoders recurrentes, agrupamientos por similitud y clasificadores para diferenciar patrones saludables de aquellos que indicaran deterioro funcional.

Sin embargo, durante el preprocesamiento, se detectó que los datos presentaban problemas de integridad y calidad, lo que imposibilitó su uso para los análisis previstos. Pese a ello, el diseño exploratorio inicial permitió evaluar la viabilidad del proyecto y establecer que el dataset no cumplía con los requisitos necesarios para continuar. Cabe destacar que el mismo se llevó a cabo en el marco del proyecto ActiveUP.

El análisis inicial, correspondiente al primer objetivo específico, se centró en evaluar la calidad e integridad de los datos recolectados para garantizar su viabilidad en el análisis de patrones de marcha. Incluyó la revisión de los archivos generados por los sensores y la detección de posibles inconsistencias. Sin embargo, durante esta etapa se identificaron problemas técnicos significativos en los datos, asociados principalmente al funcionamiento del RTC (Real-Time Clock) de los sensores, lo que imposibilitó la continuación del análisis y el desarrollo de los métodos planificados. A continuación, se presentan los hallazgos más relevantes relacionados con la evaluación de los datos y las conclusiones derivadas de este análisis.

Siguiendo la iniciativa COSMIN para estudios de fiabilidad y validez, inicialmente, se planifico trabajar con una muestra de 50 participantes. Como resultado del reclutamiento en el Hospital de Día y en las consultas externas del Servicio de Geriátria del Hospital Universitario de Getafe, familiares y conocidos de los investigadores; se reclutó a 25 pacientes. De los cuales a 10, pese a ser reclutados, no se les llegó a instalar la arquitectura de computación necesaria para la recopilación de datos en la vivienda.



**Ilustración 22 Población ActiveUP.**


Fuente: Elaboración propia.

De los 15 pacientes a los que se instaló el sistema, 12 concluyeron el estudio en las doce quincenas estimadas como tiempo de evaluación, mientras 3 se retiraron entre la tercera y sexta quincena por fallecimiento, enfermedad o incomodidad del sensor. Cabe destacar que, durante el estudio, los participantes realizaron intermitencias por razones de viaje, afecciones médicas y en ocasiones, porque olvidaban utilizar el dispositivo.

Así mismo, los participantes compartieron inconformidades como ser, dificultades para usar el sensor, dolores en la zona de uso, fallos en la aplicación, uso incorrecto del sensor por

desconocimiento y en general, incomodidad del dispositivo. La idea principal fue detectar anomalías o patrones de marcha utilizando los datos de los 15 pacientes del proyecto. Sin embargo, debido a una incidencia en el RTC (Real-Time Clock) del dispositivo, la precisión y la sincronización de los registros de tiempo se vio afectado. Tras identificar el error, se evaluó que datos podrían ser viables, concluyendo así con 9 pacientes cuyos datos permitieron realizar el análisis.

La gráfica en la Ilustración 22 resume las principales anomalías detectadas durante el preprocesamiento. Se observaron cinco tipos de anomalías: problemas de delimitador, archivos duplicados, fechas inconsistentes, saltos de tiempo y reinicios de timestamp. Cada una de ellas se presenta con un porcentaje del total de archivos procesados de 9 pacientes, lo que en conjunto formó un total de 204 ficheros y cada uno de ellos contenía aproximadamente 6000 muestras recolectadas diariamente.



**Ilustración 23 Incidencia anomalías datos ActiveUP.**

Fuente: Elaboración propia.

El análisis mostró que las anomalías más comunes fueron aquellas relacionadas al timestamp, los saltos de tiempo, afectando en el 32.8% y los reinicios de timestamp con la mayoría de 48.5%. Estas anomalías solían incluir reinicios de valores en timestamp como 0, 3, 4 y 7 a lo largo de todo el fichero, representando una posibilidad de error de ejecución. Bajo el mismo criterio, también sucedió que el tiempo no cambio de ninguna forma, pero el timestamp presentó un valor menor al anterior y en una sola fila de forma aleatoria. Así mismo con respecto al tiempo, se detectaron

saltos mayores a 10 minutos lo que es excesivo e incluso, aunque no se generó ningún reinicio, representó una pérdida de continuidad temporal.

Aunque las fechas inconsistentes representaron solo el 4.9%, fueron una de las incidencias más complejas debido a casos de fechas imposibles y también formato variable (año-mes-día o día-mes-año) e incluso en cuanto a dígitos del año ya sea 4 dígitos (2024) o de 2 (24). El caso de los archivos duplicados es curioso pues había ficheros con nombres repetidos, sin embargo, no contenían los mismos datos. Finalmente, los problemas de delimitador, aunque representando la minoría, se resolvieron reemplazando los delimitadores erróneos por comas “,”. Es importante destacar que 111 de los 204 archivos procesados presentaron más de una anomalía, lo que complicó el análisis inicial y subrayó la necesidad de un preprocesamiento riguroso.

Según la literatura expuesta anteriormente, numerosos estudios destacan que una muestra limitada representa una restricción común en el desarrollo de proyectos con autoencoders. Esta limitación suele deberse a poblaciones específicas que dificultan la generalización en el ámbito geriátrico, así como a la cantidad o integridad de los datos, lo que puede afectar el desempeño de la tecnología desarrollada. Los estudios de Arshad et al. (2023), Digo et al. (2023), Hauth et al. (2021), Huertas-Hoyas et al. (2023), y Malik (2021) coinciden en señalar que la muestra y la población constituyen factores limitantes.

## 5.2. Estimación de la velocidad de la marcha

En esta sección se presentan los resultados del análisis comparativo entre el algoritmo original de Mueller et al. (2019) y su versión adaptada por Cobo et al. (2023). Se evalúa el desempeño del algoritmo adaptado al aplicarlo a datos nuevos, como el conjunto de datos MOTIVA. Por último, se comparan dichos resultados con los obtenidos mediante modelos alternativos, como regresiones no lineales, para identificar variaciones en la estimación de la velocidad.

### 5.2.1 Adaptación Mueller

Para verificar la aplicabilidad del algoritmo adaptado, se realizó una comparación entre los resultados del algoritmo original de Mueller y los de la versión adaptada.

Los resultados obtenidos por el algoritmo de Mueller se derivan de su aplicación sobre la totalidad de los datos disponibles en el conjunto de datos de este, es decir, 983 intervalos de 129 pacientes distintos.

En la columna correspondiente a la Adaptación Mueller, se encuentran los resultados de la versión adaptada del algoritmo. Dado que parte de los datos originales se utilizaron para entrenar el modelo de regresión lineal, los resultados reflejan su desempeño exclusivamente en 212 intervalos de 33 participantes diferentes. Pese a ello, es notable que ambos algoritmos presentan una validez sólida, aunque la adaptación muestra una disminución en la correlación (R) entre las estimaciones y las mediciones de referencia, el resultado sigue manteniéndose dentro de un rango aceptable.

**Tabla 9 Métricas Mueller y su adaptación.**

	Mueller et al. (2019)	Adaptación Mueller Cobo et al. (2023)
Validez	R = 0.85 (0.831, 0.868)	R = 0.84 (0.800, 0.878)
Concordancia	SEM = 0.04	SEM = 0.04
	MDD=0.12	MDD=0.11
	Bland-Altman	Bland-Altman
	Bias = -0.01 (-0.017, -0.0060)	Bias = -0.01 (-0.024, 0.003)
	uLOA = 0.11 (0.099, 0.119)	uLOA = 0.09 (0.076, 0.112)
	lLOA = -0.13 (-0.142, -0.122)	lLOA = -0.12 (-0.140, -0.103)
Fiabilidad	ICC = 0.93 (0.908, 0.938)	ICC = 0.91 (0.862, 0.937)

Fuente: Elaboración propia.

Así mismo en términos de concordancia, el (SEM) es idéntico en ambos algoritmos, lo que demuestra que la precisión en términos de variabilidad es comparable. No obstante, el modelo adaptado muestra una menor (MDD), lo que indica una capacidad superior para identificar cambios pequeños de manera más fiable. Del mismo modo, los límites de concordancia (uLOA y lLOA) demuestran una ligera mejora en la adaptación, con una menor dispersión en las diferencias entre los métodos. A diferencia de los valores del coeficiente de correlación intraclass (ICC) pues, aunque es ligeramente menor en la versión adaptada, los valores altos evidencian una consistencia sólida entre las mediciones (test-retest) lo que indica una fiabilidad muy alta.

La versión adaptada ofrece ventajas específicas, como una mayor sensibilidad para detectar cambios pequeños (menor MDD) y una concordancia mejorada, aun con una ligera reducción en los valores de R e ICC. Lo que sugiere que las modificaciones realizadas optimizan aspectos clave del algoritmo sin comprometer su precisión o consistencia general para estimar la velocidad de la marcha.

#### 5.2.1.1. Detección de bouts

El algoritmo adaptado de Mueller fue ejecutado en 15 señales de 15 participantes distintos. Cada señal contenía 3 bouts (uno largo de 10 pasos, uno mediano de 6 pasos y uno corto de 3 pasos), sumando un total de 45 bouts. El algoritmo detectó 48 bouts en total, como se resume a continuación en la Tabla 10.

**Tabla 10 Bouts detectados.**

	TP	FP	TN	FN	Precisión	Sensibilidad
Todos los bouts	32	2	N/A	14	0.94	0.70

Fuente: Elaboración propia.

Lo que demuestra que el 94% de los bouts detectados ocurrieron mientras los participantes realmente estaban caminando y el 70% de los bouts reales fueron correctamente identificados por el algoritmo. La Tabla 11 muestra un desglose de la sensibilidad del algoritmo según la longitud de los bouts reales. Los datos evidencian que el algoritmo tiene dificultades para detectar la mayoría de los bouts cortos (3 pasos), pero identifica la gran mayoría de los bouts medianos y largos.

**Tabla 11 Sensibilidad por longitud de bout.**

	TP	FN	Sensibilidad
Bouts largos	12	3	0.80
Bouts medianos	13	2	0.87
Bouts cortos	6	9	0.40

Fuente: Elaboración propia.

El promedio de sensibilidad y precisión del algoritmo se resumen en la Tabla 12, incluyendo un desglose según la longitud de los bouts. Los valores de sensibilidad muestran que el algoritmo no detecta el 100% de la duración de los bouts reales, principalmente debido a que

las primeras ventanas dentro de un bout real no presentan características claras de caminata. Esto provoca un retraso en la detección hasta que el movimiento se vuelve más evidente.

**Tabla 12 Promedio de sensibilidad y precisión según la longitud de bout.**

	Todos los bouts	Bouts largos	Bouts medios	Bouts cortos
Sensibilidad	0.77	0.75	0.73	0.89
Precisión	0.91	0.94	0.91	0.86

Fuente: Elaboración propia.

Por su parte, los valores de precisión indican que casi el 100% de los bouts detectados corresponden con los bouts reales, aunque algunas porciones de bouts detectados exceden ligeramente los límites temporales de los bouts reales. Lo que ocurre porque las ventanas de análisis tienen una longitud fija y, en ocasiones, algunas ventanas que presentan características de caminata al final del bout real se extienden más allá después de que estos han concluido.

Sin embargo, cabe destacar que los bouts cortos (3 pasos) muestran un comportamiento ligeramente diferente. La longitud de las ventanas de análisis es comparable a la duración de los bouts, lo que afecta negativamente su detección y contribuye a una menor sensibilidad en este caso.

### 5.2.2 Comparación Modelos

Se desarrollaron y evaluaron modelos alternativos basados en regresión lineal,(RF) y (SVM), con el objetivo de comparar su desempeño frente al algoritmo adaptado de Mueller. Los resultados se presentan en las Tablas 13, 14 y 15, destacando las métricas de validez, concordancia y fiabilidad.

#### 5.2.2.1 Validez

El análisis comparativo entre los modelos desarrollados muestra diferencias significativas en su desempeño, evaluadas mediante el coeficiente de correlación (R) y sus respectivos intervalos de confianza al 95% (95% CI), como se observa en la Tabla 13.

El modelo lineal con Mueller, basado en coeficientes derivados de un entrenamiento previo utilizando el conjunto de datos originales de Mueller, alcanzó un valor de  $R = 0.85$  (95% CI: 0.80-0.89), mostrando un rendimiento aceptable pese a no estar ajustado al conjunto MOTIVA.

Por otro lado, el modelo lineal con MOTIVA, entrenado directamente con este conjunto de datos, evidenció una ligera mejora con  $R = 0.86$  (95% CI: 0.81-0.89), lo que sugiere que las

características del nuevo conjunto de datos contribuyen a una calibración más precisa del modelo, optimizando su capacidad predictiva en este contexto.

**Tabla 13 Validez de Modelos**

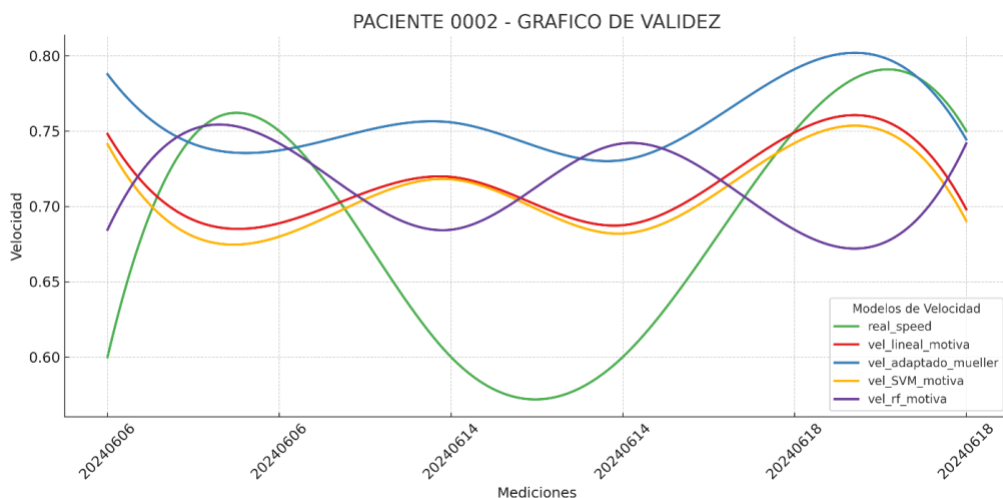
	Lineal con Mueller	Lineal con MOTIVA	Bosques Aleatorios (RF)	Máquina de Soporte Vectorial (SVM)
Validez	R= 0.85 95%CI= (0.80, 0.89)	R=0.86 95%CI=(0.81, 0.89)	R=0.98 95%CI=(0.98, 0.99)	R=0.86 95%CI=(0.81, 0.89)

Fuente: Elaboración propia.

En contraste, el modelo de (RF) mostró el mejor desempeño, con R = 0.98 (95% CI: 0.98-0.99), enfatizando su capacidad para manejar la complejidad de los datos no lineales y capturar variaciones sutiles en las señales inerciales.

Por su parte, el modelo deSVM, con un valor de R = 0.86 (95% CI: 0.81-0.89), ofreció un equilibrio entre simplicidad y precisión, pero con limitaciones para igualar la robustez del RF.

Para complementar este análisis cuantitativo, se realizó una evaluación específica utilizando los datos del Paciente 0002, registrados entre el 6 y el 18 de junio de 2024. Las mediciones se realizaron en dos tramos consecutivos, correspondientes al recorrido de 3 metros de ida y 3 metros de regreso dentro de las mismas fechas, lo que permite analizar la consistencia de los modelos en ambas situaciones.



**Ilustración 24 Comparación velocidades.**

Fuente: Elaboración propia.

Del Anexo 3 Comparación Velocidades por Bouts - Paciente 0001.- Anexo 34 Comparación Velocidades por Bouts - Paciente 5025. se encuentra la misma comparación de velocidades por cada paciente.

La Ilustración 23 permite una comparación visual entre la velocidad real y las estimaciones de los modelos, proporcionando evidencia adicional que respalda las métricas obtenidas previamente.

El modelo de (RF) logró un ajuste más preciso en ambos tramos, capturando las oscilaciones de la velocidad real con mayor fidelidad, lo que refuerza sus resultados cuantitativos. En cambio, el modelo lineal con MOTIVA y el SVM lograron seguir la tendencia general de la velocidad, pero suavizaron las variaciones, especialmente en fechas con fluctuaciones más marcadas, como el 14 y el 18 de junio. El algoritmo adaptado de Mueller, aunque mostró un desempeño estable ( $R = 0.84$ ), presentó desviaciones puntuales que limitan su precisión frente a cambios dinámicos.

Este análisis intraindividual evidencia la importancia de evaluar mediciones en ambos tramos dentro de las mismas fechas, ya que revela la capacidad de los modelos para adaptarse a variaciones naturales en la marcha, frecuentes en adultos mayores. Los resultados posicionan al modelo de RF como la opción más precisa y robusta, destacando su utilidad en aplicaciones clínicas donde la detección de cambios funcionales sutiles es crítica.

#### 5.2.2.2 Concordancia

La evaluación de la concordancia entre los modelos desarrollados se realizó utilizando métricas como el (SEM), (MDD) y los límites de concordancia (uLOA y lLOA).

**Tabla 14 Concordancia entre modelos**

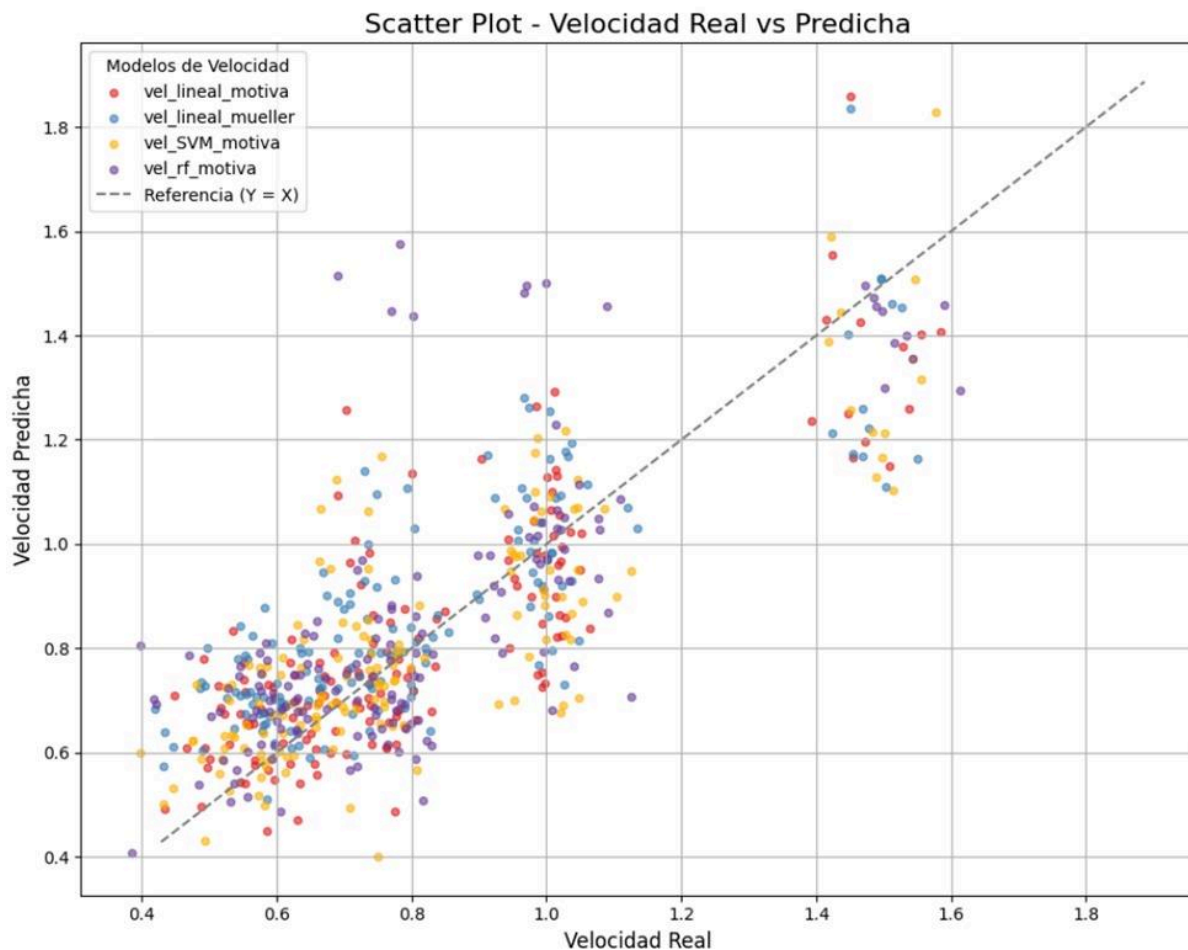
	Lineal con Mueller	Lineal con MOTIVA	Bosques Aleatorios (RF)	Máquina de Soporte Vectorial (SVM)
Concordancia	SEM= 0.08	SEM=0.07	SEM=0.09	SEM=0.07
	MDD= 0.21	MDD=0.18	MDD=0.26	MDD=0.18
	95%CI(uLOA) = (0.15, 0.23)	95%CI(uLOA) =(0.13, 0.20)	95%CI(uLOA) =(0.17, 0.27)	95%CI(uLOA) =(0.13, 0.21)
	95%CI(lLOA) = (-0.28, -0.19)	95%CI(lLOA) =(-0.23, -0.16)	95%CI(lLOA) = (-0.34, -0.24)	95%CI(lLOA) =(-0.23, -0.16)

Fuente: Elaboración propia.

Los modelos Lineal con MOTIVA y SVM tienen los menores valores de error ( $SEM = 0.07$ ) y una menor MDD (0.18), lo que indica una mayor precisión en la estimación de la velocidad. En contraste, el modelo Lineal con Mueller presenta un error ligeramente mayor ( $SEM = 0.08$ ,  $MDD = 0.21$ ), pero mantiene límites de concordancia más amplios en comparación con MOTIVA y SVM. Lo que sugiere que, aunque funcional, presenta mayor dispersión en sus predicciones.

Por otro lado, el modelo de (RF), aunque obtuvo la mayor MDD (0.26) y un  $SEM = 0.09$ , presenta límites de concordancia más amplios ( $uLOA = 0.27$ ,  $lLOA = -0.34$ ), lo que indica una mayor variabilidad en las predicciones pese a su alta validez global.

En la Ilustración 24, se comparan las velocidades reales (eje X) con las velocidades predichas (eje Y) para los cuatro modelos de estimación. Se observa que, si bien existe una buena correlación entre las velocidades, hay mayor dispersión en valores extremos. La línea punteada negra ( $Y = X$ ) representa el ajuste ideal, donde las predicciones coinciden exactamente con los valores reales.



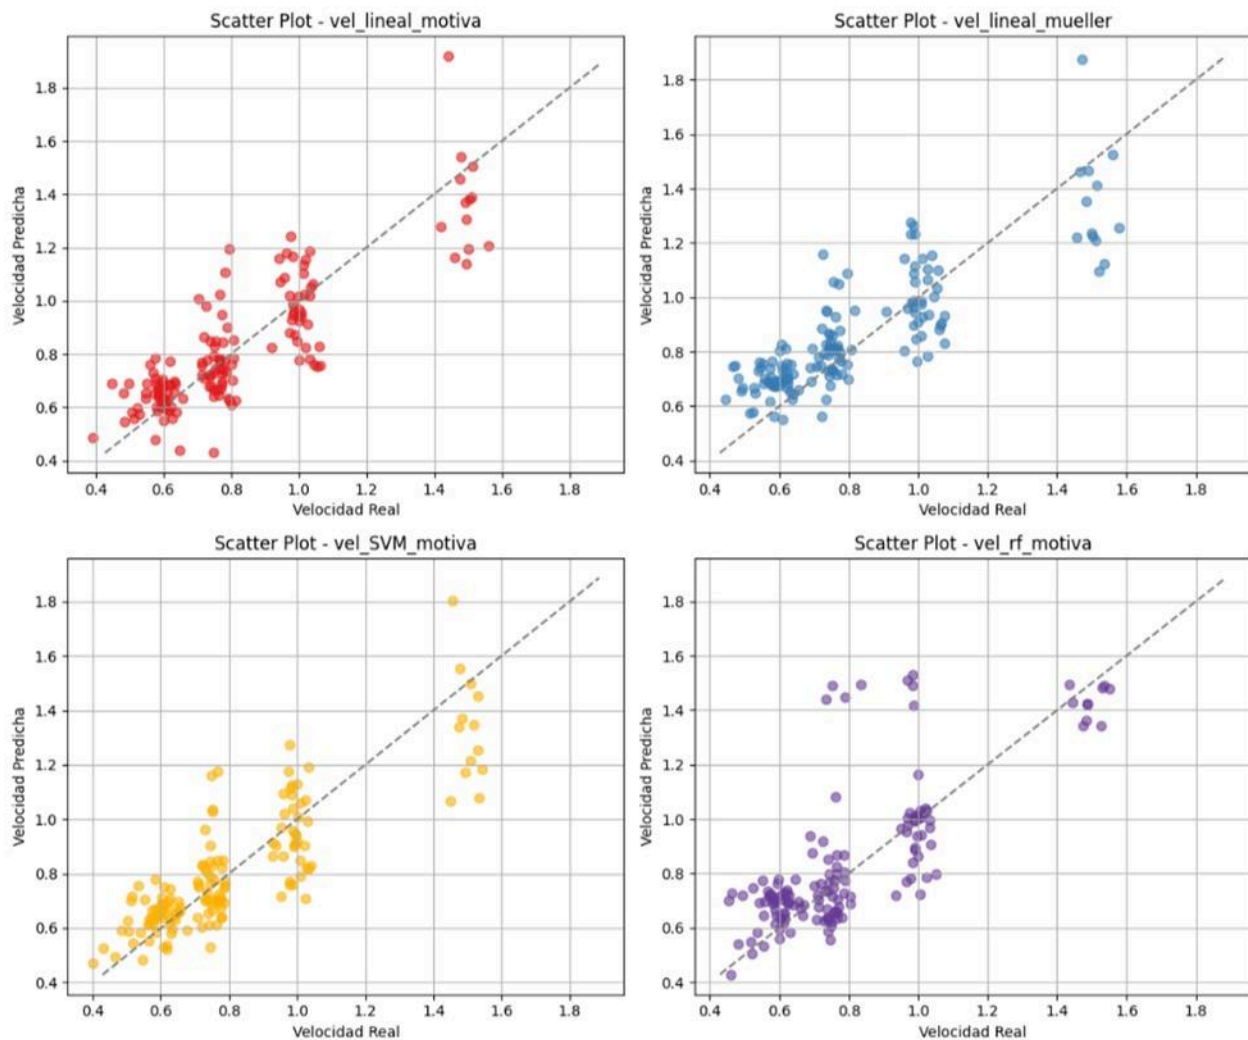
**Ilustración 25 Velocidades por modelo.**

Fuente: Elaboración propia.

La mayoría de los puntos se concentran en torno a esta línea, lo que confirma un desempeño general adecuado de los modelos.

Sin embargo, al observar la dispersión, se aprecia que el modelo (RF) presenta puntos más alejados de la línea ideal, especialmente en valores extremos, lo que coincide con los valores mayores de SEM y MDD en la tabla.

Los gráficos individuales en la Ilustración 25, permiten identificar diferencias específicas de cada modelo. El modelo lineal con MOTIVA y el SVM muestran una alta concentración de puntos cercanos a la línea de referencia ( $Y = X$ ), lo que confirma su precisión en el rango medio de velocidades.



**Ilustración 26 Comportamiento de cada modelo.**

Fuente: Elaboración propia.

En contraste, el modelo lineal con Mueller, aunque funcional, muestra mayor dispersión en las velocidades más altas, evidenciando limitaciones en su capacidad de generalización. Por el contrario, aunque el modelo RF es altamente válido, su mayor variabilidad lo posiciona como menos robusto en términos de concordancia.

La combinación de estos análisis visuales y métricos permite identificar las fortalezas y limitaciones de cada modelo. Los modelos lineales con MOTIVA y SVM destacan por su precisión y estabilidad, con límites de concordancia más estrechos y menor error estándar de medición. Por el contrario, el modelo de RF, aunque altamente válido, presenta mayor variabilidad en sus estimaciones. Estos hallazgos son relevantes pues la elección del modelo dependerá del contexto: mientras que RF es ideal para situaciones que priorizan la validez global, los modelos lineales y SVM son más adecuados en escenarios donde se requiere alta consistencia y sensibilidad para detectar cambios sutiles en la velocidad de la marcha.

### 5.2.2.3 Fiabilidad

Se evaluó la fiabilidad mediante el coeficiente de correlación intraclass (ICC(A,1)) y sus respectivos intervalos de confianza al 95% (95% CI), como se detalla en la Tabla 15. Los resultados permiten analizar la consistencia de las estimaciones en relación con las velocidades reales, mientras que la Ilustración 26 presenta la distribución de las predicciones para cada modelo mediante diagramas de caja (boxplots) que complementan el análisis numérico.

**Tabla 15 Fiabilidad de modelos**

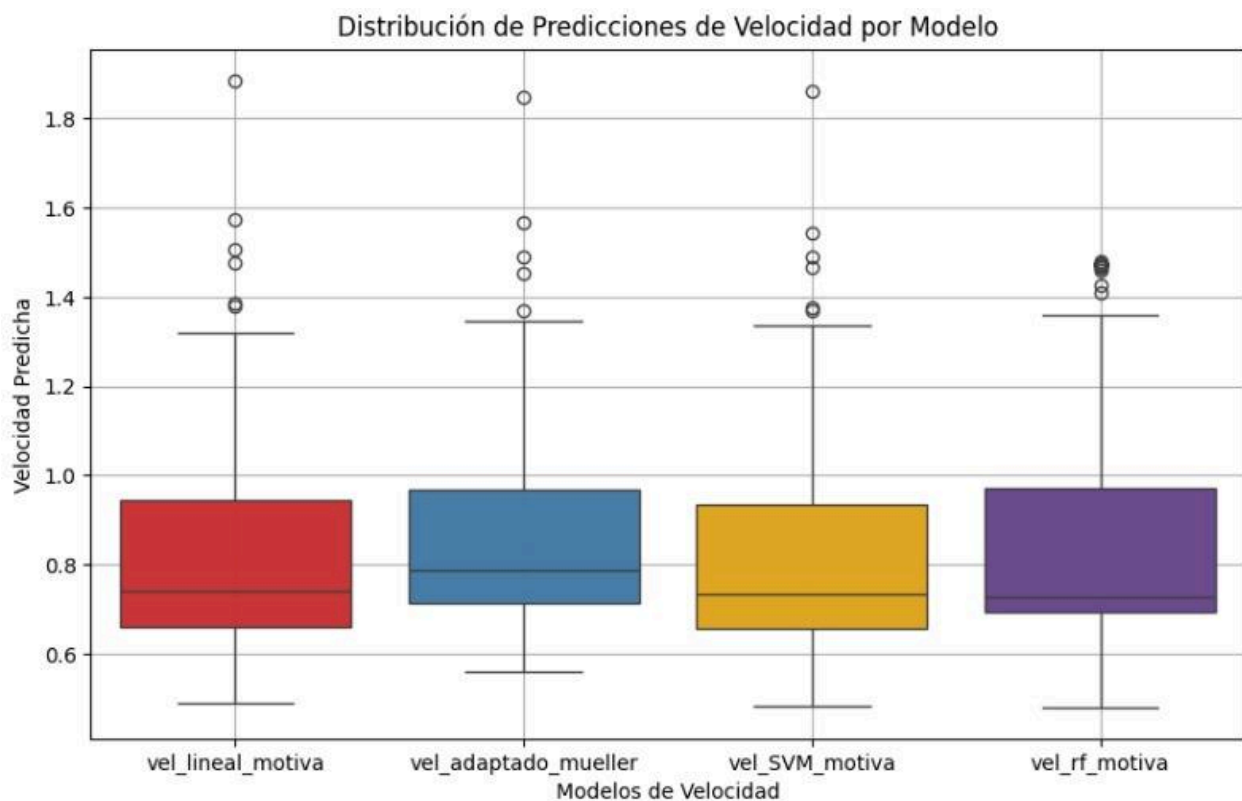
	Lineal con Mueller	Lineal con MOTIVA	Bosques Aleatorios (RF)	Máquina de Soporte Vectorial (SVM)
Fiabilidad	ICC(A,1)= 0.88 95%CI= (0.81, 0.92)	ICC(A,1)=0.90 95%CI=(0.84, 0.93)	ICC(A,1)=0.82 95%CI=(0.73, 0.89)	ICC(A,1)=0.90 95%CI=(0.84, 0.94)

Fuente: Elaboración propia.

Los modelos Lineal con MOTIVA y SVM obtuvieron los valores más altos de fiabilidad con un ICC = 0.90, y límites de confianza de 0.84 a 0.93 y 0.84 a 0.94, respectivamente. Estos valores evidencian una alta consistencia en las mediciones, lo que se traduce en predicciones más precisas y confiables. Al observar los boxplots, se confirma que ambos modelos presentan distribuciones más compactas, con menor variabilidad y un número reducido de valores atípicos. Este

comportamiento refuerza la estabilidad de las predicciones, validando su capacidad para estimar de manera robusta la velocidad de marcha.

Por otro lado, el modelo Lineal con Mueller mostró una fiabilidad ligeramente inferior, con un ICC = 0.88 (95% CI: 0.81 - 0.92). Aunque su desempeño es aceptable y se encuentra cercano al de los modelos anteriores, el diagrama de caja revela una ligera dispersión en las predicciones, particularmente en los extremos de la distribución. Si bien este modelo mantiene un comportamiento adecuado, presenta mayor sensibilidad a la variabilidad en ciertos intervalos de la marcha.



**Ilustración 27 Distribución de predicciones.**

Fuente: Elaboración propia.

En contraste, el modelo de (RF) obtuvo el valor más bajo de fiabilidad, con un ICC = 0.82 (95% CI: 0.73 - 0.89). Este resultado refleja una menor consistencia en sus estimaciones, lo cual es corroborado visualmente en el boxplot, donde se observa una mayor dispersión y la presencia de valores atípicos por encima y por debajo de los "bigotes" de la caja. La amplitud de la distribución indica que el modelo RF, aunque válido, presenta limitaciones para generar

predicciones estables, especialmente en escenarios donde las velocidades de marcha muestran mayor variabilidad.

Por lo que es posible concluir que los modelos Lineal con MOTIVA y SVM son los más confiables, al combinar altos valores de fiabilidad ( $ICC = 0.90$ ) con distribuciones compactas y reducida variabilidad en sus predicciones. El modelo Lineal con Mueller, aunque intermedio, presenta un desempeño aceptable con una ligera dispersión en valores extremos. Por el contrario, el modelo de (RF) muestra una fiabilidad inferior, caracterizada por una mayor dispersión y presencia de valores atípicos, lo que limita su aplicabilidad en contextos donde la estabilidad en las mediciones es crítica.

Con el objetivo de garantizar la reproducibilidad del estudio, los códigos utilizados durante el desarrollo del análisis se encuentran disponibles en los anexos de este documento.

En el proceso de identificación de tramos (bouts), el Anexo 35 Código de preprocesamiento de datos MOTIVA. describe la selección de archivos provenientes de los sensores de cintura, estableciendo los rangos de tiempo correspondientes a recorridos de 3 metros y su regreso. Posteriormente, el anexo 36 detalla el cálculo de amplitudes de aceleración mediante la función Get Hilbert Amplitudes, generando un conjunto de datos a partir de los ejes establecidos según la posición del sensor. La función específica utilizada para este cálculo se encuentra en el Anexo 37 Función Matlab - Transformada de Hilbert. El Anexo 38 Código para calcular coeficientes de regresión lineal. describe el entrenamiento de un modelo de regresión lineal utilizando las amplitudes calculadas, validando los datos y generando coeficientes que permiten realizar predicciones de velocidad.

El Anexo 39 Código Cálculo SVM Lineal. aborda el entrenamiento de un modelo SVM sobre el mismo conjunto de amplitudes, mientras que el Anexo 40 Código Cálculo Random Forest (RF). detalla la implementación de un modelo Random Forest Regressor, que elimina datos faltantes y realiza predicciones directas de velocidad real (real\_speed). Los cálculos de velocidad estimada a partir de las amplitudes se describen en el Anexo 41 Código Adaptado de Mueller - MATLAB, utilizando transformadas de Hilbert para eliminar ruido y obtener amplitudes medias de señales (Anexo 42 Función Matlab – Transformada de Hilbert Amplitudes).

La aplicación de estos modelos a señales reales y su comparación con velocidades predichas se explica en el *Anexo 43 Código Matlab – Obtención de velocidades por modelo y creación de dataset*. donde se documenta la función que automatiza la identificación de bouts, facilitando el procesamiento de grandes volúmenes de datos y el cálculo preciso de velocidades para el modelo Mueller.

## VI. DISCUSIÓN

Los resultados obtenidos en este estudio destacan tanto el potencial como las limitaciones de los métodos basados en IMUs para la estimación de patrones característicos y la velocidad de la marcha en personas mayores. En relación con la evaluación de las series temporales de ActiveUp mediante un modelo autoencoder, se evidenciaron problemas en la calidad de los datos, como reinicios en el timestamp y saltos de tiempo, que complicaron la sincronización y afectaron la identificación de patrones. Además, la limitada muestra restringe la generalización de los resultados, alineándose con observaciones similares realizadas en la literatura como Chen et al. (2023) y Huertas Hoyas et al. (2023).

En cuanto a la estimación de la velocidad de la marcha, los modelos desarrollados mostraron alta validez y fiabilidad, respaldando su utilidad en el análisis de parámetros funcionales. La comparación del algoritmo adaptado de Mueller et al. (2019) ajustado por Cobo et al. (2023), con modelos como SVM, regresión lineal y RF, refuerza la solidez de los métodos implementados y su aplicabilidad en el análisis de la marcha.

El SEM (0.04-0.09) y el MDD (0.11-0.21) obtenidos son comparables a los valores de RMSE (0.10-0.18 m/s) reportados por Soltani et al. (2021), quienes utilizaron RF para estimar la velocidad y longitud de paso. Aunque las métricas difieren, la similitud en los márgenes de error sugiere que ambos modelos poseen una capacidad precisa y fiable para la estimación de parámetros de marcha.

Las limitaciones del tamaño muestral, señaladas como un desafío en este trabajo ( $n = 31$  participantes, 151 bouts), también han sido documentadas en la literatura. Estudios como los de Kraus et al. (2022) y García-de-Villa et al. (2024) con muestras de 57 y 157 pacientes, respectivamente, destacan que incluso tamaños moderados pueden no ser suficientes para entrenar modelos complejos como SVM o RF. Esta problemática se intensifica en trabajos como el de Hwang et al. (2024), donde solo 10 sujetos saludables fueron evaluados, limitando la representatividad. Pese a ello, los valores obtenidos de ICC (0.91) en este proyecto indican una fiabilidad aceptable sugiriendo que, aunque el tamaño muestral afecta la generalización, el rendimiento del modelo sigue siendo sólido. Sin embargo, ampliar la muestra permitiría optimizar el entrenamiento y mejorar la robustez de los resultados.

Estudios como los de Teufl et al. (2021) y Chan et al. (2024) subrayan la necesidad de incorporar muestras heterogéneas que reflejen distintos niveles de movilidad y fragilidad. En este estudio, aunque los valores de ICC (0.91) reflejan una alta fiabilidad test-retest, la muestra estuvo compuesta mayoritariamente por adultos funcionales, lo que podría haber generado un sesgo similar al observado en trabajos como el de Vavasour et al. (2021), donde se excluyó a individuos con dificultades para caminar largas distancias.

Un reto identificado fue la baja sensibilidad en la detección de bouts cortos (3 pasos, sensibilidad = 0.40), mientras que la detección de bouts medianos y largos fue más precisa (0.75-0.87). Kang et al. (2021) reportaron resultados similares, señalando que los algoritmos tienden a ser más eficaces con movimientos prolongados, pero presentan limitaciones en la identificación de patrones breves, atribuibles a la longitud fija de las ventanas de análisis. Además, destacan la importancia de utilizar métricas como la correlación de Pearson, la velocidad media y el coeficiente de variación para analizar patrones de marcha y su relación con la sarcopenia y el envejecimiento.

El desempeño del modelo SVM ( $R = 0.86$ ,  $ICC = 0.90$ ) se alinea con los resultados de Shah et al. (2020), donde valores de  $ICC \geq 0.88$  fueron indicadores de alta fiabilidad en evaluaciones repetidas de marcha en pacientes con Parkinson. En contraste, el modelo de RF aunque altamente válido ( $R = 0.98$ ), mostró una fiabilidad menor ( $ICC = 0.82$ ), reflejando una mayor variabilidad en las predicciones, como también lo reportó Vavasour et al. (2021). Esta mayor dispersión, observada en los límites de concordancia (uLOA y lLOA), resalta la necesidad de considerar modelos que prioricen la consistencia, especialmente en entornos clínicos.

Los resultados de este trabajo coinciden con la literatura tanto en precisión como en fiabilidad, reflejando limitaciones compartidas como el tamaño muestral reducido y la menor sensibilidad en la detección de movimientos breves. A pesar de ello, las métricas obtenidas indican que los algoritmos implementados ofrecen un desempeño robusto y confiable en la estimación de parámetros de marcha. Estos hallazgos subrayan la importancia de continuar optimizando los modelos, integrando muestras más amplias y diversas que permitan mejorar la generalización y aplicabilidad de los resultados en contextos clínicos reales.

## **VII. CONCLUSIONES**

En este capítulo, se presentan las conclusiones obtenidas del proyecto de investigación, las cuales están estrechamente alineadas con los objetivos establecidos inicialmente, tanto el general como los específicos.

### **7. 1. CONCLUSIÓN GENERAL**

El desarrollo de métodos basados en sensores inerciales vestibles permitió progresar en la estimación de patrones característicos y la velocidad de la marcha en personas mayores, integrando técnicas de análisis de series temporales, regresión lineal y aprendizaje automático. En el análisis de patrones de marcha asociados al deterioro funcional, las limitaciones en la calidad e integridad de los datos recolectados restringieron la implementación de los modelos planificados. No obstante, este proceso permitió establecer bases metodológicas robustas para el manejo y preprocesamiento de datos, identificando desafíos clave para futuras investigaciones en esta área.

Por otro lado, en la estimación de la velocidad de la marcha, los modelos desarrollados demostraron alta precisión y fiabilidad, cumpliendo con los estándares establecidos en las métricas de validez y concordancia. Los modelos basados en SVM y RF destacaron por su capacidad para capturar la complejidad de los datos, ofreciendo herramientas precisas para la evaluación funcional en adultos mayores. Estos resultados reflejan el potencial de las tecnologías vestibles combinadas con técnicas analíticas avanzadas para optimizar el monitoreo y la evaluación funcional en esta población.

### **7. 2. CONCLUSIONES PARCIALES**

#### **7.2.1. Detección de Patrones en marcha**

- La evaluación de la calidad e integridad de los datos recolectados por los sensores inerciales vestibles evidenció múltiples limitaciones técnicas que afectaron la viabilidad del análisis planificado. Se identificaron anomalías recurrentes, como reinicios de temporización, inconsistencias en los timestamps y formatos de fechas variables, además de archivos duplicados con contenidos discrepantes. Estos problemas, atribuidos a fallos

en el RTC de los dispositivos y al uso inconsistente de los sensores por parte de los participantes, provocaron que más del 50% de los 204 archivos procesados no cumplieran con los requisitos de calidad necesarios para el análisis de series temporales. A pesar de estos desafíos, fue posible identificar un subconjunto de datos (9 participantes) que permitió realizar análisis exploratorios, estableciendo las bases metodológicas para garantizar la viabilidad de los datos en futuros estudios. Estos hallazgos resaltan la importancia de implementar estrategias de preprocesamiento rigurosas y de optimizar tanto la configuración de los sensores como las condiciones de uso por parte de los usuarios.

- El diseño de un modelo basado en autoencoders recurrentes, concebido para la identificación de patrones de marcha asociados al deterioro funcional, no pudo ser implementado completamente debido a las limitaciones impuestas por la calidad de los datos disponibles. Sin embargo, fue posible identificar los retos técnicos y conceptuales más relevantes para futuros desarrollos. Entre ellos, destacan la necesidad de datos con sincronización precisa y continuidad temporal, además de un volumen de datos representativo que permita la implementación robusta de modelos de aprendizaje automático.

#### 7.2.2. Estimación velocidad de la marcha

- El algoritmo adaptado de Mueller demostró un desempeño adecuado en la estimación de la velocidad de la marcha, manteniendo una validez ( $R = 0.84$ ) y fiabilidad ( $ICC = 0.91$ ) sólidas. Si bien presentó ligeras reducciones respecto al modelo original, estos valores permanecieron dentro de rangos aceptables para su uso en la evaluación funcional. Además, el modelo adaptado mostró mejoras específicas, como una menor ( $MDD = 0.11$ ) y límites de concordancia más estrechos, lo que aumenta su capacidad para detectar cambios pequeños en la velocidad. Estas características confirman su utilidad en escenarios clínicos donde se requiere precisión en el análisis de la marcha.
- Mediante la implementación del algoritmo, se obtuvo una alta precisión en la detección de episodios de marcha (*bouts*) en personas mayores, con una incidencia mínima de falsos positivos. El algoritmo ha demostrado ser efectivo en la identificación de *bouts* de 6 y 10

pasos (*bouts* medianos (87%) y largos (80%)), los cuales representan duraciones comunes en entornos domésticos. No obstante, se ha observado una limitación en la detección de *bouts* muy cortos, de aproximadamente 3 pasos. Sin embargo, esta restricción no compromete de manera significativa la utilidad del algoritmo, ya que los *bouts* más largos reflejan con mayor fidelidad la velocidad de marcha, proporcionando una métrica más representativa para el análisis del patrón de locomoción. Pese a los resultados obtenidos, se reconoce la necesidad de evaluar la capacidad de generalización del algoritmo en otros conjuntos de datos y con diferentes modelos de sensores, con el fin de asegurar su robustez y aplicabilidad en diversos escenarios y poblaciones.

- Los modelos alternativos, desarrollados con técnicas avanzadas como (RF), (SVM) y regresión lineal ajustada, mostraron variaciones en su desempeño. El modelo RF destacó por su alta validez ( $R = 0.98$ ), lo que refleja una excelente capacidad para capturar variaciones complejas. Sin embargo, su fiabilidad más baja ( $ICC = 0.82$ ) y una mayor dispersión en los límites de concordancia limitaron su aplicabilidad en entornos que requieren alta estabilidad. En contraste, los modelos de SVM y regresión ajustados al conjunto de datos MOTIVA ofrecieron un desempeño más equilibrado, combinando alta validez ( $R = 0.86$ ), fiabilidad ( $ICC = 0.90$ ) y errores estándar de medición más bajos, posicionándose como las opciones más robustas para aplicaciones prácticas.
- La validación de los modelos confirmó la superioridad de las técnicas avanzadas de aprendizaje automático y regresión lineal ajustada en relación con el algoritmo adaptado de Mueller. Los modelos SVM y lineal ajustado al conjunto MOTIVA destacaron por su fiabilidad, precisión y menor error estándar de medición, lo que los hace más adecuados para aplicaciones clínicas. Aunque el modelo RF mostró una validez excepcional, su mayor variabilidad en las predicciones lo hace menos adecuado para escenarios que demandan consistencia. Estas validaciones destacan la importancia de seleccionar el modelo más adecuado según las necesidades específicas del contexto de aplicación.

## VIII. LIMITACIONES Y RECOMENDACIONES

Estas propuestas están orientadas a mejorar los aspectos técnicos, metodológicos y operativos de futuros trabajos relacionados con el análisis de la marcha en personas mayores mediante sensores inerciales vestibles.

- Dado los problemas técnicos identificados, como fallos en el RTC, anomalías en timestamps y formatos inconsistentes, se recomienda optimizar la calibración de los dispositivos inerciales para garantizar datos de mayor calidad. Establecer protocolos automatizados de preprocesamiento que detecten y corrijan errores en tiempo real minimizarían inconsistencias en los datos y reducirían la dependencia de procesos posteriores de corrección. Aumentando así la viabilidad y confiabilidad de los datos para análisis avanzados.
- Es recomendable garantizar desde el inicio datasets robustos y de alta calidad, es decir, con un volumen amplio de datos para mejorar la generalización de los resultados. Así mismo es crucial para aplicar técnicas avanzadas como autoencoders recurrentes, maximizando su capacidad de detectar patrones complejos y signos de deterioro funcional en esta población. Sin embargo, para lograrlo, es necesario implementar estrategias que fomenten la retención de participantes, como el diseño de dispositivos más cómodos y un sistema de comunicación eficiente, ya sea mediante aplicaciones móviles o contacto directo, que motive a los pacientes a continuar en el estudio.
- Aunque para la estimación de la velocidad de la marcha se utilizó exclusivamente el sensor ubicado en la región lumbar, integrar datos de sensores adicionales podría proporcionar un análisis más integral de la dinámica de la marcha. Esto permitiría complementar la información obtenida del sensor lumbar y reducir las limitaciones inherentes a depender de un solo dispositivo.
- Las incomodidades reportadas por los participantes y los errores en el uso de los sensores impactaron la continuidad de los datos. Por ello, se recomienda diseñar dispositivos más ergonómicos y livianos, así como interfaces de usuario más intuitivas. Además, brindar una

capacitación adecuada sobre el uso de los dispositivos podría reducir errores y garantizar datos de mayor calidad.

Cada recomendación busca no solo mitigar los desafíos encontrados, sino también potenciar el impacto de las tecnologías vestibles y los modelos analíticos en el monitoreo funcional y la investigación sobre el envejecimiento saludable. Con estos lineamientos, se espera contribuir al diseño de estudios más robustos y efectivos en el ámbito de la evaluación funcional.

## IX. REFERENCIAS BIBLIOGRÁFICAS

1. Abramov, S., Abramova, V., Abramov, K., & Lukin, V. (2022). Aplicación de filtrado DSP para el procesamiento de señales del módulo de medición inercial. *Aerospace Technic and Technology*, 6, 50-56. <https://doi.org/10.32620/akt.2022.6.06>
2. Acosta-Benito, M. Á., & Martín-Lesende, I. (2022). [Frailty in primary care: Diagnosis and multidisciplinary management]. *Atencion Primaria*, 54(9), 102395. <https://doi.org/10.1016/j.aprim.2022.102395>
3. Adhikari, R. D. (2020). Ageing Persons and Rising Responsibilities of Family Caregivers: Minireview. *Global Journal of Aging & Geriatric Research*, 1(1). <https://doi.org/10.33552/GJAGR.2020.01.000503>
4. Ahmed, S., Irfan, S., Kiran, N., Masood, N., Anjum, N., & Ramzan, N. (2023). Remote Health Monitoring Systems for Elderly People: A Survey. *Sensors*, 23(16), 7095. <https://doi.org/10.3390/s23167095>
5. Allison, R., Assadzandi, S., & Adelman, M. (2021). Frailty: Evaluation and Management. *American Family Physician*, 103(4), 219-226.
6. Almansoori, M., & Telek, M. (2023). Anomaly Detection using combination of Autoencoder and Isolation Forest. *1st Workshop on Intelligent Infocommunication Networks, Systems and Services*, 25-30. <https://doi.org/10.3311/WINS2023-005>
7. Alonso Bouzón, C., & Rodríguez Mañas, L. (2021). La experiencia europea ADVANTAGE para el manejo de la fragilidad: Claves sobre su aplicabilidad en América Latina. *Revista Panamericana de Salud Pública*, 45, 1. <https://doi.org/10.26633/RPSP.2021.107>
8. Álvaro Elices Acero. (2023). Trabajo Social y Atención Centrada en la Persona: Funciones y claves profesionales en los cuidados de larga duración dirigidos a personas mayores. *RIAGE - Revista Ibero-Americana de Gerontología*, 4. <https://doi.org/10.61415/riage.120>
9. Amrani, H., Micucci, D., & Napoletano, P. (2022a). Unsupervised Deep Learning-based clustering for Human Activity Recognition. *2022 IEEE 12th International Conference on Consumer Electronics (ICCE-Berlin)*, 1-6. <https://doi.org/10.1109/ICCE-Berlin56473.2022.9937141>

10. Amrani, H., Micucci, D., & Napoletano, P. (2022b). Unsupervised Deep Learning-based clustering for Human Activity Recognition. *2022 IEEE 12th International Conference on Consumer Electronics (ICCE-Berlin)*, 1-6. <https://doi.org/10.1109/ICCE-Berlin56473.2022.9937141>
11. Andrade Vera, S. A., Zambrano Segovia, M. M., Zambrano Cevillano, A. N., & Morales Ponce, V. L. (2024). TÉCNICAS DE MACHINE LEARNING APLICADAS A LA INTERPRETACIÓN DE DATOS DE MERCADO. *Ciencia y Desarrollo*, 27(2), 217. <https://doi.org/10.21503/cyd.v27i2.2615>
12. Antofie, B.-G., Larco, M.-C., & Lucian Grigorie, T. (2023). Improvement of the global positioning accuracy with miniaturized strap-down INS systems through wavelet filtering of data from MEMS inertial sensors. En S. Ramakrishnan (Ed.), *Modern Applications of Wavelet Transform*. IntechOpen. <https://doi.org/10.5772/intechopen.1003199>
13. Arom Gómez Arias, B., Gonzalo Chávez Orellana, S., Cecilia Ortega-Bastidas, P., & Esteban Aqueveque Navarro, P. (2024). Community-Based and Everyday Life Gait Analysis: Approach to an Automatic Balance Assessment and Fall Risk Prediction in the Elderly. En M. Domínguez-Morales & F. Luna-Perejón (Eds.), *Biomedical Engineering* (Vol. 24). IntechOpen. <https://doi.org/10.5772/intechopen.112873>
14. Arshad, M. Z., Jamsrandorj, A., Kim, J., & Mun, K.-R. (2022). Gait Events Prediction Using Hybrid CNN-RNN-Based Deep Learning Models through a Single Waist-Worn Wearable Sensor. *Sensors*, 22(21), 8226. <https://doi.org/10.3390/s22218226>
15. Arshad, M. Z., Lee, D., Jung, D., Jamsrandorj, A., Kim, J., & Mun, K.-R. (2023). Deep Learning-Based Gait Event Prediction through a Single Waist-worn Wearable Sensor. *2023 IEEE International Conference on Consumer Electronics (ICCE)*, 1-6. <https://doi.org/10.1109/ICCE56470.2023.10043541>
16. Aznielle Rodríguez, Tania, Machado Morciego, Beatriz, Serrano Blanco, & Leisy, Menéndez Álvarez. (2023). Unidades de Medición Inercial: Una alternativa promisoría en la evaluación de la marcha. *EAC [online]*, vol.44(3).
17. Baba, T., Watanabe, M., Ogihara, H., Handa, S., Sasamoto, K., Okada, S., Okuizumi, H., & Kimura, T. (2023). Validity of temporo-spatial characteristics of gait as an index for fall risk

- screening in community-dwelling older people. *Journal of Physical Therapy Science*, 35(3), 265-269. <https://doi.org/10.1589/jpts.35.265>
18. Bank, D., Koenigstein, N., & Giryas, R. (2020). *Autoencoders* (Versión 2). arXiv. <https://doi.org/10.48550/ARXIV.2003.05991>
19. Barahona, A., Espín, C. M., Velásquez, C., & Pozo, J. (2021). Estado Nutricional y factores de riesgo para enfermedad crónica no transmisible en ancianos de la población El Juncal, Ecuador. *La U Investiga*, 8(1), 9-21. <https://doi.org/10.53358/lauinvestiga.v8i1.358>
20. Battikh, M. S., & Lenskiy, A. A. (2021). Latent-Insensitive Autoencoders for Anomaly Detection. *Mathematics*, 10(1), 112. <https://doi.org/10.3390/math10010112>
21. Bazrafkan, L., Mohseni, R., Hamidi, F., & Mohseni, Z. (2022). *Evaluation of health services to The residents of UNHR in Sarvestan refugee camp based on the responsive evaluation model in the Covid epidemic 19*. <https://doi.org/10.21203/rs.3.rs-2040335/v1>
22. Beard, J. R., Si, Y., Liu, Z., Chenoweth, L., & Hanewald, K. (2022). Intrinsic Capacity: Validation of a New WHO Concept for Healthy Aging in a Longitudinal Chinese Study. *The Journals of Gerontology. Series A, Biological Sciences and Medical Sciences*, 77(1), 94-100. <https://doi.org/10.1093/gerona/glab226>
23. Beigh, N. T., Beigh, F. T., & Mallick, D. (2023). Machine learning assisted hybrid transduction nanocomposite based flexible pressure sensor matrix for human gait analysis. *Nano Energy*, 116, 108824. <https://doi.org/10.1016/j.nanoen.2023.108824>
24. Benesha, J., Lee, J., James, D. A., & White, B. (2020). Are You for Real? Engineering a Virtual Lab for the Sports Sciences Using Wearables and IoT. *The 13th Conference of the International Sports Engineering Association*, 110. <https://doi.org/10.3390/proceedings2020049110>
25. Bertolazzi, A., Quaglia, V., & Bongelli, R. (2024). Barriers and facilitators to health technology adoption by older adults with chronic diseases: An integrative systematic review. *BMC Public Health*, 24(1), 506. <https://doi.org/10.1186/s12889-024-18036-5>
26. Betances Reinoso, F. A., Lopez Montes, T., Rodríguez Ontiveros, V. M., & Chiesa Estomba, C. (2020). Análisis de la marcha y el equilibrio mediante el uso de sensores inerciales: Estudio prospectivo, longitudinal, no aleatorio. *Ciencia y Salud*, 4(1), 11-16.

<https://doi.org/10.22206/cysa.2020.v4i1.pp11-16>

27. Bisong, E. (2019). *Building Machine Learning and Deep Learning Models on Google Cloud Platform: A Comprehensive Guide for Beginners*. Apress. <https://doi.org/10.1007/978-1-4842-4470-8>
28. Bitencourt, T., Klitzke Dos Santos, F. M., & Soares, A. V. (2020). Relação entre a Funcionalidade e a Capacidade Motora de Pacientes Pós-AVC na Fase Aguda. *Revista Neurociências*, 28, 1-18. <https://doi.org/10.34024/rnc.2020.v28.10241>
29. Blinka, M. D., Buta, B., Bader, K. D., Hanley, C., Schoenborn, N. L., McNabney, M., & Xue, Q.-L. (2021). Developing a sensor-based mobile application for in-home frailty assessment: A qualitative study. *BMC Geriatrics*, 21(1), 101. <https://doi.org/10.1186/s12877-021-02041-z>
30. Bosnes, I., Nordahl, H. M., Stordal, E., Bosnes, O., Myklebust, T. Å., & Almkvist, O. (2019). Lifestyle predictors of successful aging: A 20-year prospective HUNT study. *PloS One*, 14(7), e0219200. <https://doi.org/10.1371/journal.pone.0219200>
31. Bousquet, J., Kuh, D., Bewick, M., Standberg, T., Farrell, J., Pengelly, R., Joel, M. E., Rodriguez Mañas, L., Mercier, J., Bringer, J., Camuzat, T., Bourret, R., Bedbrook, A., Kowalski, M. L., Samolinski, B., Bonini, S., Brayne, C., Michel, J. P., Venne, J., ... Zins, M. (2015). Operational definition of Active and Healthy Ageing (AHA): A conceptual framework. *The Journal of Nutrition, Health and Aging*, 19(9), 955-960. <https://doi.org/10.1007/s12603-015-0589-6>
32. Buran Sevik, O., González Alted, C., Casado Romo, M. P., & Martínez Herraiz, A. (2024). Evaluación de la marcha mediante dispositivos portátiles en un paciente con daño cerebral adquirido. *Revista Colombiana de Medicina Física y Rehabilitación*, 34(1). <https://doi.org/10.28957/rcmfr.421>
33. Calderón-Campos, K. M., Parodi, J. F., & Runzer-Colmenares, F. M. (2019). Comorbilidades neurológicas y su relación con la velocidad de la marcha en adultos mayores del Centro Médico Naval "Cirujano Mayor Santiago Távara" 2010-2015. *Revista de Neuro-Psiquiatria*, 82(2), 110-116. <https://doi.org/10.20453/rnp.v82i2.3537>
34. Calvo Higuera, I., & Gomez Carrillo, A. (2023). Sarcopenia y envejecimiento saludable: Reporte de caso. *Revista de Nutrición Clínica y Metabolismo*, 6(1). <https://doi.org/10.35454/rncm.v6n1.499>

35. Cantú-Martínez, P. C. (2022). Envejecimiento saludable y condiciones sociales de los adultos mayores en México. *Revista Iberoamericana de Bioética*, 19, 1-12. <https://doi.org/10.14422/rib.i19.y2022.005>
36. Cao, Y., Bai, H., Jin, K., & Zou, G. (2023). An GNSS/INS Integrated Navigation Algorithm Based on PSO-LSTM in Satellite Rejection. *Electronics*, 12(13), 2905. <https://doi.org/10.3390/electronics12132905>
37. Carrasco Diaz, B., & Araya, A.-X. (2023). SOLEDAD Y FRAGILIDAD EN PERSONAS MAYORES QUE VIVEN EN COMUNIDAD: UNA REVISIÓN INTEGRATIVA. *Horizonte de enfermería, NE*. [https://doi.org/10.7764/Horiz\\_Enferm.Num.esp.332-348](https://doi.org/10.7764/Horiz_Enferm.Num.esp.332-348)
38. Castellanos-Ruíz, J., Montealegre-Mesa, L. M., Martínez-Toro, B. D., Gallo-Serna, J. J., & Almanza-Fuentes, O. (2020). Uso de sensores inerciales en fisioterapia: Una aproximación a procesos de evaluación del movimiento humano. *Universidad y Salud*, 23(1), 55-63. <https://doi.org/10.22267/rus.212301.214>
39. Cechinel, C., Lenardt, M. H., Rodrigues, J. A. M., Binotto, M. A., Aristides, M. M., & Kraus, R. (2022). Fragilidad y delirium en adultos mayores hospitalizados: Revisión sistemática con metanálisis. *Revista Latino-Americana de Enfermagem*, 30, e3687. <https://doi.org/10.1590/1518-8345.6120.3686>
40. Cesari, M., Vellas, B., Hsu, F.-C., Newman, A. B., Doss, H., King, A. C., Manini, T. M., Church, T., Gill, T. M., Miller, M. E., Pahor, M., & for the LIFE Study Group. (2015). A Physical Activity Intervention to Treat the Frailty Syndrome in Older Persons—Results From the LIFE-P Study. *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, 70(2), 216-222. <https://doi.org/10.1093/gerona/glu099>
41. Chan, D., & Galli, M. G. (2020). Aplicación de técnicas estadísticas multivariadas con el lenguaje de programación R en investigaciones educativas del nivel superior. *Revista Argentina de Educación Superior: RAES*, 20, 123-136.
42. Chan, L. L. Y., Lord, S. R., & Brodie, M. A. (2024). Daily-Life Walking Speed, Quality and Quantity Derived from a Wrist Motion Sensor: Large-Scale Normative Data for Middle-Aged and Older Adults. *Sensors*, 24(16), 5159. <https://doi.org/10.3390/s24165159>
43. Chandel, G., Sahimkhan, P., Verma, S., & Sharm, A. (2023). Machine Learning Based Remote

- Sensing Technique for Analysis of The Glaciated Regions. *E3S Web of Conferences*, 405, 02019. <https://doi.org/10.1051/e3sconf/202340502019>
44. Chatelain, Y., Yong, N., Kiar, G., & Glatard, T. (2021). *PyTracer: Automatically profiling numerical instabilities in Python* (Versión 2). arXiv. <https://doi.org/10.48550/ARXIV.2112.11508>
45. Chen, H., Taha, T. M., & Chodavarapu, V. P. (2022). Towards Improved Inertial Navigation by Reducing Errors Using Deep Learning Methodology. *Applied Sciences*, 12(7), 3645. <https://doi.org/10.3390/app12073645>
46. Chen, S.-H., Lee, C.-H., Jiang, B. C., & Sun, T.-L. (2021). Using a Stacked Autoencoder for Mobility and Fall Risk Assessment via Time–Frequency Representations of the Timed Up and Go Test. *Frontiers in Physiology*, 12, 668350. <https://doi.org/10.3389/fphys.2021.668350>
47. Chen, X., Liu, W., Bao, Q., Liu, X., Yang, Q., Dai, R., & Mei, T. (2024). *Motion Capture from Inertial and Vision Sensors* (Versión 1). arXiv. <https://doi.org/10.48550/ARXIV.2407.16341>
48. Chia, F., Huang, W.-Y., Huang, H., & Wu, C.-E. (2023). Promoting Healthy Behaviors in Older Adults to Optimize Health-Promoting Lifestyle: An Intervention Study. *International Journal of Environmental Research and Public Health*, 20(2), 1628. <https://doi.org/10.3390/ijerph20021628>
49. Chowdhury, D., Stolee, P., Sims-Gould, J., & Tong, C. (2023). “Think positive and don’t die alone”—Foreign-born, South Asian older adults’ perceptions on healthy aging. *International Journal of Qualitative Studies on Health and Well-Being*, 18(1), 2253576. <https://doi.org/10.1080/17482631.2023.2253576>
50. Cigarroa, I., Lasserre-Laso, N., Zapata-Lamana, R., Leiva-Ordóñez, A. M., Troncoso-Pantoja, C., Martínez-Sanguinetti, M. A., Villagrán, M., Nazar, G., Díaz, X., Petermann-Rocha, F., & Celis-Morales, C. (2020). Asociación entre la velocidad de marcha y el riesgo de deterioro cognitivo en personas mayores que viven en la comunidad. *Gerokomos*, 31(4), 204-210. <https://doi.org/10.4321/S1134-928X2020000500002>
51. Clegg, A., Young, J., Iliffe, S., Rikkert, M. O., & Rockwood, K. (2013). Frailty in elderly people. *The Lancet*, 381(9868), 752-762. [https://doi.org/10.1016/S0140-6736\(12\)62167-9](https://doi.org/10.1016/S0140-6736(12)62167-9)

52. Cobo, A., Rodríguez-Laso, Á., Villalba-Mora, E., Pérez-Rodríguez, R., & Rodríguez-Mañas, L. (2023). Frailty detection in older adults via fractal analysis of acceleration signals from wrist-worn sensors. *Health Information Science and Systems*, 11(1), 29. <https://doi.org/10.1007/s13755-023-00229-8>
53. Cobo, A., Villalba-Mora, E., Pérez-Rodríguez, R., Ferre, X., & Rodríguez-Mañas, L. (2021). Unobtrusive Sensors for the Assessment of Older Adult's Frailty: A Scoping Review. *Sensors (Basel, Switzerland)*, 21(9), 2983. <https://doi.org/10.3390/s21092983>
54. Cobo, A., Villalba-Mora, E., Pérez-Rodríguez, R., Medina, J. E., Robles-Mateos, P., Rodríguez-Laso, Á., & Rodríguez-Mañas, L. (2023). Assessing Older Adult's Gait Speed with Wearable Accelerometers in Community Settings: Validity and Reliability Study. En A. Tsanas & A. Triantafyllidis (Eds.), *Pervasive Computing Technologies for Healthcare* (Vol. 488, pp. 127-137). Springer Nature Switzerland. [https://doi.org/10.1007/978-3-031-34586-9\\_10](https://doi.org/10.1007/978-3-031-34586-9_10)
55. Contreras Carrasco, O. (2021). Modelos Generativos en el Aprendizaje Automático y su aplicación a la generación de Imágenes Digitales. *Journal Boliviano de Ciencias*, 17(51), 79-109. <https://doi.org/10.52428/20758944.v17i51.110>
56. Cristofori, G., Aguado Ortego, R., & Gómez Pavón, J. (2023). Concepto y manejo práctico de la fragilidad en neurología. *Revista de Neurología*, 76(10), 327. <https://doi.org/10.33588/rn.7610.2023124>
57. Cunha, A. N. D., Zanetti, M. L., Santos, J. L. F., & Rodrigues, R. A. P. (2023). Síndrome de la Fragilidad y sarcopenia en ancianos con y sin diabetes mellitus tipo 2 del municipio de Sinop, Mato Grosso: Un estudio epidemiológico. *Revista Latino-Americana de Enfermagem*, 31, e4076. <https://doi.org/10.1590/1518-8345.6677.4076>
58. Czech, M. D., Psaltos, D., Zhang, H., Adamusiak, T., Calicchio, M., Kelekar, A., Messere, A., Van Dijk, K. R. A., Ramos, V., Demanuele, C., Cai, X., Santamaria, M., Patel, S., & Karahanoglu, F. I. (2020). Age and environment-related differences in gait in healthy adults using wearables. *Npj Digital Medicine*, 3(1), 127. <https://doi.org/10.1038/s41746-020-00334-y>
59. Dabove, M. I. (2023). Cuidados gerontológicos de largo plazo. Los derechos de las personas mayores como meta política. *Política y Sociedad*, 60(2), e88577.

<https://doi.org/10.5209/poso.88577>

60. Davis, J. R. C., Knight, S. P., Donoghue, O. A., Hernández, B., Kenny, R. A., & Romero-Ortuno, R. (2021). *Comparison of gait speed reserve, usual gait speed, and maximum gait speed of adults aged 50+ in Ireland using explainable machine learning*. <https://doi.org/10.1101/2021.07.23.21260911>
61. De Araújo, F. R., S. De Araújo, D., Lobo De Aguiar Gomes, C., De Souza Medeiros, A. L., Medeiros Gondim, A. L., Oliveira Cacho, R., & Azevedo Cacho, E. W. (2020). Interferência da dupla tarefa no desempenho da marcha em indivíduos com doença de Parkinson. *Revista Pesquisa em Fisioterapia*, 10(2), 248-257. <https://doi.org/10.17267/2238-2704rpf.v10i2.2887>
62. Dent, E., Daly, R. M., Hoogendijk, E. O., & Scott, D. (2023). Exercise to Prevent and Manage Frailty and Fragility Fractures. *Current Osteoporosis Reports*, 21(2), 205-215. <https://doi.org/10.1007/s11914-023-00777-8>
63. Dent, E., Morley, J. E., Cruz-Jentoft, A. J., Woodhouse, L., Rodríguez-Mañas, L., Fried, L. P., Woo, J., Aprahamian, I., Sanford, A., Lundy, J., Landi, F., Beilby, J., Martin, F. C., Bauer, J. M., Ferrucci, L., Merchant, R. A., Dong, B., Arai, H., Hoogendijk, E. O., ... Vellas, B. (2019). Physical Frailty: ICFSR International Clinical Practice Guidelines for Identification and Management. *The Journal of Nutrition, Health and Aging*, 23(9), 771-787. <https://doi.org/10.1007/s12603-019-1273-z>
64. Department of Community Health Nursing, and Geriatric Nursing, School of Nursing & Midwifery, Iran University of Medical Sciences, Tehran, Iran., Bastani, F., Haghani, H., & Department of Statistics, Faculty of Health, Iran University of Medical Sciences, Tehran, Iran. (2022). Perceived Stress and Fear of COVID-19 Among the Elderly Referred to Comprehensive Health Centers in Tehran, Iran. *The Iran Journal of Nursing*, 35(136), 134-149. <https://doi.org/10.32598/ijn.35.2.256.16>
65. Dev, R., Zaslavsky, O., Cochrane, B., Eagen, T., & Woods, N. F. (2020). Healthy aging through the lens of community-based practitioners: A focus group study. *BMC Geriatrics*, 20(1), 211. <https://doi.org/10.1186/s12877-020-01611-x>
66. Dias, S. F., Graf, C., Jehli, E., Oertel, M. F., Mahler, J., Schmid Daners, M., & Stieglitz, L. H.

- (2023). Gait pattern analysis in the home environment as a key factor for the reliable assessment of shunt responsiveness in patients with idiopathic normal pressure hydrocephalus. *Frontiers in Neurology*, *14*, 1126298. <https://doi.org/10.3389/fneur.2023.1126298>
67. Digo, E., Panero, E., Agostini, V., & Gastaldi, L. (2023). Comparison of IMU set-ups for the estimation of gait spatio-temporal parameters in an elderly population. *Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine*, *237*(1), 61-73. <https://doi.org/10.1177/09544119221135051>
68. Dugarte Jerez, N., Alvarez Abril, A., Alvarado Riviera, N. W., Gómez, C. M., Lattuca, A., Sosa Barraco, G. M., Dugarte Dugarte, E. D. C., & Lombardo, G. (2024a). Sistema biométrico para el análisis de la marcha utilizando unidades de medida inerciales (IMU). *Revista Tecnología y Ciencia*, *49*, 47-67. <https://doi.org/10.33414/rtyc.49.47-67.2024>
69. Dugarte Jerez, N., Alvarez Abril, A., Alvarado Riviera, N. W., Gómez, C. M., Lattuca, A., Sosa Barraco, G. M., Dugarte Dugarte, E. D. C., & Lombardo, G. (2024b). Sistema biométrico para el análisis de la marcha utilizando unidades de medida inerciales (IMU). *Revista Tecnología y Ciencia*, *49*, 47-67. <https://doi.org/10.33414/rtyc.49.47-67.2024>
70. Eidam, A., Durga, J., Bauer, J. M., Zimmermann, S., Vey, J. A., Rapp, K., Schwenk, M., Cesari, M., & Benzinger, P. (2024). Interventions to prevent the onset of frailty in adults aged 60 and older (PRAE-Frail): A systematic review and network meta-analysis. *European Geriatric Medicine*. <https://doi.org/10.1007/s41999-024-01013-x>
71. Elsayed, E., Radwan, E., & Fadila, D. (2024). The Effects of Health Promotion Program on Healthy Aging, Wellbeing and Health Promoting Behaviour among Community Dwelling Older Adults. *NILES Journal for Geriatric and Gerontology*, *7*(2), 417-442. <https://doi.org/10.21608/niles.2024.353844>
72. Ertem, U. (2021). EVALUATION OF HEALTH LITERACY LEVEL AND RELATED FACTORS IN OLDER ADULT PATIENTS. *The Turkish Journal of Geriatrics*, *24*(4), 490-498. <https://doi.org/10.31086/tjgeri.2021.246>
73. Esmaeili, F., Cassie, E., Nguyen, H. P. T., Plank, N. O. V., Unsworth, C. P., & Wang, A. (2023). Anomaly Detection for Sensor Signals Utilizing Deep Learning Autoencoder-Based Neural

- Networks. *Bioengineering*, 10(4), 405. <https://doi.org/10.3390/bioengineering10040405>
74. Fernández-Revelles, A. B., Rangel García, J. A., & Loza Herbella, J. (2023). EFFECT OF 36 WEEKS OF MULTICOMPONENT PHYSICAL EXERCISE FOR THE PREVENTION OF FRAGILITY IN PEOPLE OVER 65. *Journal of Sport and Health Research*, 15(Supl. 1). <https://doi.org/10.58727/jshr.102762>
75. Fried, L. P., Tangen, C. M., Walston, J., Newman, A. B., Hirsch, C., Gottdiener, J., Seeman, T., Tracy, R., Kop, W. J., Burke, G., McBurnie, M. A., & Cardiovascular Health Study Collaborative Research Group. (2001). Frailty in older adults: Evidence for a phenotype. *The Journals of Gerontology. Series A, Biological Sciences and Medical Sciences*, 56(3), M146-156. <https://doi.org/10.1093/gerona/56.3.m146>
76. Gálvez, E., Cruz, P. y Cruz, G. (2022). La política pública en México en materia de la tercera edad. En P. C. CantúMartínez (ed.), *Adulto Mayor y Envejecimiento (pp. 47-58)*. Universidad Autónoma de Nuevo León.
77. Gamonales Puerto, J. M., Durán-Vaca, M., Gámez-Calvo, L., Hernández-Beltrán, V., Muñoz-Jiménez, J., & León, K. (2021). Fútbol para personas con amputaciones: Revisión sistemática exploratoria (Football for people with amputations: Exploratory systematic review). *Retos*, 42, 145-153. <https://doi.org/10.47197/retos.v42i0.86380>
78. Garcia, R. F. (2020) *Estudio de viabilidad de sensores inerciales (IMUs) para el análisis de Timed Up & Go test*. (s. f.).
79. García-de-Villa, S., Ruiz, L. R., Neira, G. G.-V., Álvarez, M. N., Huertas-Hoyas, E., del-Ama, A. J., Rodríguez-Sánchez, M. C., Seco, F., & Jiménez, A. R. (2024). Validation of an IMU-based Gait Analysis Method for Assessment of Fall Risk Against Traditional Methods. *IEEE Journal of Biomedical and Health Informatics*, 1-11. <https://doi.org/10.1109/JBHI.2024.3434973>
80. Gaska, I., Sygit, K., Cipora, E., Sygit, M., & Krakowiak, J. (2020). Factors determining health behaviours of the 50+ population with cardiovascular diseases. *Annals of Agricultural and Environmental Medicine*, 27(1), 99-105. <https://doi.org/10.26444/aaem/118194>
81. Ghazali, S., Aziz, A. A., & Amin, R. M. (2023). Healthy Aging and its Determinants Among Community-dwelling Older Persons in East Coast, Malaysia: A Multidimensional Assessment. *Oman Medical Journal*, 38(6), e573. <https://doi.org/10.5001/omj.2023.124>

82. Ghosh, A., Kundu, M., Devasenapathy, N., Woodward, M., & Jha, V. (2023). Frailty among middle-aged and older women and men in India: Findings from wave 1 of the longitudinal Ageing study in India. *BMJ Open*, *13*(7), e071842. <https://doi.org/10.1136/bmjopen-2023-071842>
83. González-García, A., Mota-Hernández, E., Olguín-Estrada, C., Maya-Sánchez, A., López-Nolasco, B., & Cano-Estrada, E. A. (2023). Nivel de dependencia funcional de los adultos mayores de la comunidad de Tula de Allende. *Revista de Enfermería Neurológica*, *21*(3). <https://doi.org/10.51422/ren.v21i3.396>
84. Guralnik, J. M., Simonsick, E. M., Ferrucci, L., Glynn, R. J., Berkman, L. F., Blazer, D. G., Scherr, P. A., & Wallace, R. B. (1994). A Short Physical Performance Battery Assessing Lower Extremity Function: Association with Self-Reported Disability and Prediction of Mortality and Nursing Home Admission. *Journal of Gerontology*, *49*(2), M85-M94. <https://doi.org/10.1093/geronj/49.2.M85>
85. Gustavson, A. M., LeDoux, C. V., Himawan, M., Stevens-Lapsley, J. E., & Nearing, K. A. (2022). Implementation of a rehabilitation model in a Program of All-Inclusive Care for the Elderly (PACE ): Preliminary data. *Journal of the American Geriatrics Society*, *70*(3), 880-890. <https://doi.org/10.1111/jgs.17674>
86. Gwyther, H., van Velsen, L., Shaw, R. L., D'Avanzo, B., Bujnowska-Fedak, M., Kurpas, D., Szwamel, K., Van't Klooster, J.-W., & Holland, C. (2019). The use of technology in the context of frailty screening and management interventions: A study of stakeholders' perspectives. *BMC Medical Informatics and Decision Making*, *19*(1), 110. <https://doi.org/10.1186/s12911-019-0828-6>
87. Hanada, M., Yamauchi, K., Miyazaki, S., Oyama, Y., Yanagita, Y., Sato, S., Miyazaki, T., Nagayasu, T., & Kozu, R. (2020). Short-Physical Performance Battery (SPPB) score is associated with postoperative pulmonary complications in elderly patients undergoing lung resection surgery: A prospective multicenter cohort study. *Chronic Respiratory Disease*, *17*, 1479973120961846. <https://doi.org/10.1177/1479973120961846>
88. Harris, C. R., Millman, K. J., Van Der Walt, S. J., Gommers, R., Virtanen, P., Courneau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., Van Kerkwijk, M. H.,

- Brett, M., Haldane, A., Del Río, J. F., Wiebe, M., Peterson, P., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, *585*(7825), 357-362. <https://doi.org/10.1038/s41586-020-2649-2>
89. Hauth, J., Jabri, S., Kamran, F., Feleke, E. W., Nigusie, K., Ojeda, L. V., Handelzalts, S., Nyquist, L., Alexander, N. B., Huan, X., Wiens, J., & Sienko, K. H. (2021). Automated Loss-of-Balance Event Identification in Older Adults at Risk of Falls during Real-World Walking Using Wearable Inertial Measurement Units. *Sensors*, *21*(14), 4661. <https://doi.org/10.3390/s21144661>
90. Heydarian, H., Rouast, P. V., Adam, M. T. P., Burrows, T., Collins, C. E., & Rollo, M. E. (2020). Deep Learning for Intake Gesture Detection from Wrist-Worn Inertial Sensors: The Effects of Data Preprocessing, Sensor Modalities, and Sensor Positions. *IEEE Access*, *8*, 164936-164949. <https://doi.org/10.1109/ACCESS.2020.3022042>
91. Horch, K. (2021). *Searching for health information on the Internet – Results from the KomPaS study*. Robert Koch-Institut. <https://doi.org/10.25646/7147>
92. Hore, S., Nguyen, Q. H., Xu, Y., Shah, A., Bastian, N. D., & Le, T. (2023). Empirical Evaluation of Autoencoder Models for Anomaly Detection in Packet-based NIDS. *2023 IEEE Conference on Dependable and Secure Computing (DSC)*, 1-8. <https://doi.org/10.1109/DSC61021.2023.10354098>
93. Huang, Haohua. (2021). *Inertial sensor-based gait feature extraction and gait recognition method*. <https://patentscope.wipo.int/search/en/detail.jsf?docId=WO2021115066>
94. Huertas-Hoyas, E., Alvarez, M. N., Neira, G. G.-V., Rodriguez-Sanchez, M. C. C., Espinoza-Cerda, M. T. T., Perez-Delgado, L. T., Reina-Robles, E. T., Martin, I. B., Ama, A. J. J. D., Ruiz-Ruiz, L., De Villa, S. G., & Jimenez-Ruiz, A. R. R. (2023). *G-STRIDE inertial system to explore gait factors that are associated with frailty in older adults with falls*. <https://doi.org/10.21203/rs.3.rs-3563181/v1>
95. Hwang, S., Kim, J., Yang, S., Moon, H.-J., Cho, K.-H., Youn, I., Sung, J.-K., & Han, S. (2024). Machine Learning Based Abnormal Gait Classification with IMU Considering Joint Impairment. *Sensors*, *24*(17), 5571. <https://doi.org/10.3390/s24175571>
96. Instituto Nacional de Estadística INE. (2024). *Proyecciones de Población Años 2024—2074*.

<https://www.ine.es/dyngs/Prensa/es/PROP20242074.htm>

97. Jain, R., Semwal, V. B., & Kaushik, P. (2022). Stride segmentation of inertial sensor data using statistical methods for different walking activities. *Robotica*, *40*(8), 2567-2580. <https://doi.org/10.1017/S026357472100179X>
98. Jang, H.-Y. (2020). Factors Associated with Successful Aging among Community-Dwelling Older Adults Based on Ecological System Model. *International Journal of Environmental Research and Public Health*, *17*(9), 3220. <https://doi.org/10.3390/ijerph17093220>
99. Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, *31*(3), 685-695. <https://doi.org/10.1007/s12525-021-00475-2>
100. Jaramillo, C., & Montealegre Mesa, L. M. (2023). Efectos de un programa de entrenamiento de fuerza en máquinas inerciales sobre Squat Jump, Countermovement Jump y Abalakov en jugadoras juveniles de voleibol. *Revista Iberoamericana de Ciencias de la Actividad Física y el Deporte*, *12*(3), 1-14. <https://doi.org/10.24310/riccafd.12.3.2023.17429>
101. Jiao, D., Li, X., Zhu, Z., Zhang, J., Liu, Y., Cui, M., Matsumoto, M., Banu, A. A., Sawada, Y., Watanabe, T., Tanaka, E., & Anme, T. (2023). Latent Subtype of Cognitive Frailty among Multimorbidity Older Adults and Their Association with Social Relationships. *Healthcare*, *11*(13), 1933. <https://doi.org/10.3390/healthcare11131933>
102. Jones- Ortiz, C. V., & Guzmán – Seraquive, J. E. (2022). Análisis de las técnicas de machine learning aplicadas en la detección de fraudes bancarios. *Revista Científica Ciencia y Tecnología*, *22*(33). <https://doi.org/10.47189/rcct.v22i33.516>
103. Joseph, A., & Jayaraman, C. (2024). Preprocessing Techniques for Neuroimaging Modalities: An In-Depth Analysis. En X. Lv (Ed.), *Frontiers in Neuroimaging*. IntechOpen. <https://doi.org/10.5772/intechopen.109803>
104. Jung, S., Michaud, M., Oudre, L., Dorveaux, E., Gorintin, L., Vayatis, N., & Ricard, D. (2020). The Use of Inertial Measurement Units for the Study of Free-Living Environment Activity Assessment: A Literature Review. *Sensors (Basel, Switzerland)*, *20*(19), 5625. <https://doi.org/10.3390/s20195625>
105. Kaewsuphan, W., Popa, A., Maneesakprasert, S., Meeton, A., & Pimboon, B. (2023).

- Health Behavior and Recreational Activity of Elderly People in Elderly Schools of Thailand. *Universal Journal of Public Health*, 11(1), 27-33. <https://doi.org/10.13189/ujph.2023.110104>
106. Kang, M., Kang, S.-J., Roh, H.-K., Jung, H.-Y., Kim, S., Choi, J.-Y., & Kim, K. (2021). Accuracy and Diversity of Wearable Device–Based Gait Speed Measurement Among Older Men: Observational Study. *Journal of Medical Internet Research*, 23(10), e29884. <https://doi.org/10.2196/29884>
107. Keating, N. C., Rodríguez Mañas, L., & De Francisco, A. (2021). Hacia el envejecimiento saludable en América Latina y el Caribe: ¿no dejar a nadie atrás? *Revista Panamericana de Salud Pública*, 45, 1. <https://doi.org/10.26633/RPSP.2021.120>
108. Kim, J., & Choi, S. (2024). *Timed Up and Go Test and Prediction of Injurious Falls among Older Adults by Sex: A Population-based Cohort Study*. <https://doi.org/10.21203/rs.3.rs-4521597/v1>
109. Kirk, C., Küderle, A., Micó-Amigo, M. E., Bonci, T., Paraschiv-Ionescu, A., Ullrich, M., Soltani, A., Gazit, E., Salis, F., Alcock, L., Aminian, K., Becker, C., Bertuletti, S., Brown, P., Buckley, E., Cantu, A., Carsin, A.-E., Caruso, M., Caulfield, B., ... Van Gelder, L. (2024). Mobilise-D insights to estimate real-world walking speed in multiple conditions with a wearable device. *Scientific Reports*, 14(1), 1754. <https://doi.org/10.1038/s41598-024-51766-5>
110. Kirk, C., Kuederle, A., Mico-Amigo, M. E., Bonci, T., Paraschiv-Ionescu, A., Ullrich, M., Soltani, A., Gazit, E., Salis, F., Alcock, L., Aminian, K., Becker, C., Bertuletti, S., Brown, P., Buckley, E., Cantu, A., Carsin, A.-E., Caruso, M., Caulfield, B., ... Din, S. D. (2023). *Estimating real-world walking speed from a single wearable device: Analytical pipeline, results and lessons learnt from the Mobilise-D technical validation study*. <https://doi.org/10.21203/rs.3.rs-2965670/v1>
111. Kobsar, D., Masood, Z., Khan, H., Khalil, N., Kiwan, M. Y., Ridd, S., & Tobis, M. (2020). Wearable Inertial Sensors for Gait Analysis in Adults with Osteoarthritis-A Scoping Review. *Sensors (Basel, Switzerland)*, 20(24), 7143. <https://doi.org/10.3390/s20247143>
112. Kraus, M., Saller, M. M., Baumbach, S. F., Neuerburg, C., Stumpf, U. C., Böcker, W., &

- Kepler, A. M. (2022). Prediction of Physical Frailty in Orthogeriatric Patients Using Sensor Insole-Based Gait Analysis and Machine Learning Algorithms: Cross-sectional Study. *JMIR Medical Informatics*, *10*(1), e32724. <https://doi.org/10.2196/32724>
113. Latta Sánchez, M. A., Proaño Poveda, M. J., Moscoso Córdova, G. V., & Ortiz Villalba, P. G. (2022). La marcha del adulto mayor, un factor de alerta ante la fragilidad. *Medicinas UTA*, *6*(4), 103-107. <https://doi.org/10.31243/mdc.uta.v6i4.1824.2022>
114. Lee, P.-A., Yu, W., Zhou, J., Tsai, T., Manor, B., & Lo, O.-Y. (2023). *A novel approach for improving the estimation of gait speed using a single inertial measurement unit embedded in a smartphone (Preprint)*. <https://doi.org/10.2196/preprints.52166>
115. Lee, S. Y., Choo, P. L., Pang, B. W. J., Lau, L. K., Jabbar, K. A., Seah, W. T., Chen, K. K., Ng, T. P., & Wee, S.-L. (2021). SPPB reference values and performance in assessing sarcopenia in community-dwelling Singaporeans – Yishun study. *BMC Geriatrics*, *21*(1), 213. <https://doi.org/10.1186/s12877-021-02147-4>
116. Lenardt, M. H., Setlik, C. M., Pereira, A. P., Lourenço, T. M., Marrocos Aristides Barbiero, M., Elero Betioli, S., & Rodríguez-Martínez, M. D. C. (2021). Velocidad de la marcha y cognición en adultos mayores en atención secundaria de salud. *Avances en Enfermería*, *39*(1), 84-92. <https://doi.org/10.15446/avenferm.v39n1.88364>
117. Li, M., Huang, Y., Liu, Z., Shen, R., Chen, H., Ma, C., Zhang, T., Li, S., & Prince, M. (2020). The association between frailty and incidence of dementia in Beijing: Findings from 10/66 dementia research group population-based cohort study. *BMC Geriatrics*, *20*(1), 138. <https://doi.org/10.1186/s12877-020-01539-2>
118. Li, Y., Feng, Q., Ji, C., Sun, J., & Sun, Y. (2024). GNSS and LiDAR Integrated Navigation Method in Orchards with Intermittent GNSS Dropout. *Applied Sciences*, *14*(8), 3231. <https://doi.org/10.3390/app14083231>
119. Liu, K., Kotani, T., Nakamura, K., Chihiro, T., Morita, Y., Ishii, K., Fujizuka, K., Yasumura, D., Taniguchi, D., Hamagami, T., Shimojo, N., Nitta, M., Hongo, T., Akieda, K., Atsuo, M., Kaneko, T., Sakuda, Y., Andoh, K., Nagatomi, A., ... Ogura, T. (2022). Effects of evidence-based ICU care on long-term outcomes of patients with sepsis or septic shock (ILOSS): Protocol for a multicentre prospective observational cohort study in Japan. *BMJ Open*,

12(3), e054478. <https://doi.org/10.1136/bmjopen-2021-054478>

120. Ma, J. (2022). *Comparison on gait characteristics between controlled and free-living conditions in old adults* (Versión 1). arXiv. <https://doi.org/10.48550/ARXIV.2202.07921>
121. Maas, S. A., Göcking, T., Stojan, R., Voelcker-Rehage, C., & Kutz, D. F. (2024). Synchronization of Neurophysiological and Biomechanical Data in a Real-Time Virtual Gait Analysis System (GRAIL): A Proof-of-Principle Study. *Sensors*, 24(12), 3779. <https://doi.org/10.3390/s24123779>
122. Maia, L. C., Colares, T. D. F. B., Morais, E. N. D., Costa, S. D. M., & Caldeira, A. P. (2021). Impacto do apoio matricial a idosos na atenção primária: Ensaio comunitário randomizado. *Revista de Saúde Pública*, 55, 10. <https://doi.org/10.11606/s1518-8787.2021055002685>
123. Maity, S., Das, H., Chakrawarty, A., & Devanbu, V. G. C. (2024). Gait analysis and geriatric syndromes: An association among elderly patients attending a teaching hospital of Delhi. *Journal of Family Medicine and Primary Care*, 13(6), 2329-2335. [https://doi.org/10.4103/jfmpc.jfmpc\\_1728\\_23](https://doi.org/10.4103/jfmpc.jfmpc_1728_23)
124. Malik, O. A. (2021). Deep Autoencoder for Identification of Abnormal Gait Patterns Based on Multimodal Biosignals. *International Journal of Computing and Digital Systems*, 10(1), 1-8. <https://doi.org/10.12785/ijcnds/100101>
125. Mena Roa, M. (2022, septiembre 29). *Infografía: Cerca del 10% de la población mundial tiene más de 65 años*. Statista Daily Data. <https://es.statista.com/grafico/23071/poblacion-mayor-de-65-anos-como-porcentaje-de-la-poblacion-mundial-total>
126. Menassa, M., Stronks, K., Khatmi, F., Roa Díaz, Z. M., Espinola, O. P., Gamba, M., Itodo, O. A., Buttia, C., Wehrli, F., Minder, B., Velarde, M. R., & Franco, O. H. (2023). Concepts and definitions of healthy ageing: A systematic review and synthesis of theoretical models. *EClinicalMedicine*, 56, 101821. <https://doi.org/10.1016/j.eclinm.2022.101821>
127. Metanmo, S., Simo-Tabue, N., Kuate-Tegoue, C., Bonnet, M., Gbessemehlan, A., Metanmo, F., Dramé, M., & Tabue-Teguo, M. (2023). Short Physical Performance Battery and Study of Osteoporotic Fractures Index in the Exploration of Frailty Among Older

- People in Cameroon. *International Journal of Public Health*, 68, 1605900. <https://doi.org/10.3389/ijph.2023.1605900>
128. Mila Maldonado, F. L., Yánez Yánez, K. A., & Mantilla Salgado, J. D. (2021). Una aproximación a la metodología de la investigación jurídica. *Revista Pedagogía Universitaria y Didáctica del Derecho*, 8(2), 81. <https://doi.org/10.5354/0719-5885.2021.60341>
129. Miranda, A., Oña, P., Mendoza, K., & Chango, W. (2024). NoSQL Database Benchmarking: Key/value in an application-building Environment. *ESPOCH Congresses: The Ecuadorian Journal of S.T.E.A.M.* <https://doi.org/10.18502/epoch.v4i1.15813>
130. Mueller, A., Hoefling, H. A., Muaremi, A., Praestgaard, J., Walsh, L. C., Bunte, O., Huber, R. M., Fürmetz, J., Keppler, A. M., Schieker, M., Böcker, W., Roubenoff, R., Brachat, S., Rooks, D. S., & Clay, I. (2019). Continuous Digital Monitoring of Walking Speed in Frail Elderly Patients: Noninterventional Validation Study and Longitudinal Clinical Trial. *JMIR mHealth and uHealth*, 7(11), e15191. <https://doi.org/10.2196/15191>
131. Muneera, K., Muhammad, T., Pai, M., Ahmed, W., & Althaf, S. (2023). Associations between intrinsic capacity, functional difficulty, and fall outcomes among older adults in India. *Scientific Reports*, 13(1), 9829. <https://doi.org/10.1038/s41598-023-37097-x>
132. Nakano, N., Sakura, T., Ueda, K., Omura, L., Kimura, A., Iino, Y., Fukushima, S., & Yoshioka, S. (2020). Evaluation of 3D Markerless Motion Capture Accuracy Using OpenPose with Multiple Video Cameras. *Frontiers in Sports and Active Living*, 2, 50. <https://doi.org/10.3389/fspor.2020.00050>
133. Namazi, A. (2020). Health Literacy and Its Related Factors in Non-Medical College Students. *Journal of Holistic Nursing and Midwifery*, 30(4), 233-239. <https://doi.org/10.32598/jhnm.30.4.2023>
134. Narváez, M., & Aranda, J. (2021). Instrumentación de muletas de antebrazo para uso en la monitorización de marcha y movimiento. En *XLII JORNADAS DE AUTOMÁTICA: LIBRO DE ACTAS* (pp. 168-174). Servizo de Publicacións da UDC. <https://doi.org/10.17979/spudc.9788497498043.168>
135. Nicholaus, I. T., Park, J. R., Jung, K., Lee, J. S., & Kang, D.-K. (2021). Anomaly Detection of Water Level Using Deep Autoencoder. *Sensors*, 21(19), 6679.

<https://doi.org/10.3390/s21196679>

136. O'Brien, M. K., Shin, S. Y., Khazanchi, R., Fanton, M., Lieber, R. L., Ghaffari, R., Rogers, J. A., & Jayaraman, A. (2022). Wearable Sensors Improve Prediction of Post-Stroke Walking Function Following Inpatient Rehabilitation. *IEEE Journal of Translational Engineering in Health and Medicine*, 10, 1-11. <https://doi.org/10.1109/JTEHM.2022.3208585>
137. Obuchi, S. P., Tsuchiya, S., & Kawai, H. (2018). Test-retest reliability of daily life gait speed as measured by smartphone global positioning system. *Gait & Posture*, 61, 282-286. <https://doi.org/10.1016/j.gaitpost.2018.01.029>
138. Ocampo-Chaparro, J. M., Departamento de Medicina Interna, Facultad de Ciencias de la Salud, Universidad Libre, Cali, Colombia, Reyes-Ortiz, C. A., & Institute of Public Health, College of Pharmacy and Pharmaceutical Sciences, Florida A & M University, USA. (2021). Efecto conjunto de deterioro cognitivo y condición sociofamiliar sobre el estado funcional en adultos mayores hospitalizados. *Revista Latinoamericana de Psicología*, 53. <https://doi.org/10.14349/rlp.2021.v53.3>
139. Organización de Naciones Unidas (ONU). (2022). *World Population Prospects 2022*. Department of economic and social affairs.
140. Organización Mundial de la Salud. (2024, octubre 1). *Envejecimiento y salud*. Organización Mundial de la Salud. <https://www.who.int/es/news-room/fact-sheets/detail/ageing-and-health>
141. Otamendi, J., Lucas, S., Zubizarreta, A., & Brull-Mesanza, A. (2022). Evaluación de la capacidad de una contera sensorizada para detectar cambios en el patrón de la marcha. En *XLIII Jornadas de Automática: Libro de actas: 7, 8 y 9 de septiembre de 2022, Logroño (La Rioja)* (2022.<sup>a</sup> ed., pp. 108-115). Servicio de Publicaciones da UDC. <https://doi.org/10.17979/spudc.9788497498418.0108>
142. Pajankar, A. (2022). Introduction to Data Visualization with Seaborn. En A. Pajankar, *Hands-on Matplotlib* (pp. 243-267). Apress. [https://doi.org/10.1007/978-1-4842-7410-1\\_17](https://doi.org/10.1007/978-1-4842-7410-1_17)
143. Palacios Freire, M. A., Ortega Chancay, M. C., Sierra Nieto, V. H., & Sánchez Astudillo, R. E. (2024). Entrenamiento de la marcha con la cinta rodante antigravitatoria en pacientes

- con Parkinson. *Revista Vive*, 7(19). <https://doi.org/10.33996/revistavive.v7i19.286>
144. Pavlin, L., Rodriguez, A., Ohresser, I., Larivière, M., Portal, C., Cristol, J., Bernardi, H., Turc-Baron, C., & Candau, R. (2022). Does the interference phenomenon affect strength development during same session combined rehabilitation program in hemodialysis patients? *Seminars in Dialysis*, 35(2), 154-164. <https://doi.org/10.1111/sdi.13033>
145. Peñaloza-Mendoza, G. R., Pérez-Silva, R. B., Campos-Hernández, A., & Flores-Medina, P. J. (2024). Diseño y Construcción de un Dispositivo Trazador Controlado Mediante Movimientos de la Cabeza. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 12(Especial2), 52-58. <https://doi.org/10.29057/icbi.v12iEspecial2.12265>
146. Pérez Molinet, A., Hernández Montero, F. E., Arencibia Castellanos, G., & Rodriguez, J. R. (2021). Estimación de la posición a través de IMU basada en la detección de periodos de estabilidad durante la marcha. *Orange Journal*, 3(5), 16-29. <https://doi.org/10.46502/issn.2710-995X/2021.5.03>
147. *Perspectivas demográficas del envejecimiento poblacional en la Región de las Américas*. (2023). OPS y CEPAL. <https://doi.org/10.37774/9789275326794>
148. Phan, D., Nguyen, N., Pathirana, P. N., Horne, M., Power, L., & Szmulewicz, D. (2020). A Random Forest Approach for Quantifying Gait Ataxia with Truncal and Peripheral Measurements Using Multiple Wearable Sensors. *IEEE Sensors Journal*, 20(2), 723-734. <https://doi.org/10.1109/JSEN.2019.2943879>
149. Pilotto, A., Custodero, C., Maggi, S., Polidori, M. C., Veronese, N., & Ferrucci, L. (2020). A multidimensional approach to frailty in older people. *Ageing Research Reviews*, 60, 101047. <https://doi.org/10.1016/j.arr.2020.101047>
150. Prasanth, H., Caban, M., Keller, U., Courtine, G., Ijspeert, A., Vallery, H., & Von Zitzewitz, J. (2021). Wearable Sensor-Based Real-Time Gait Detection: A Systematic Review. *Sensors*, 21(8), 2727. <https://doi.org/10.3390/s21082727>
151. Qin, N., Li, Z., Song, N., Wilson, C. L., Easton, J., Mulder, H., Plyler, E., Neale, G., Walker, E., Zhou, X., Pan, H., Hudson, M. M., Yasui, Y., Robison, L. L., Zhang, J., Ness, K. K., & Wang, Z. (2021). Epigenetic Age Acceleration and Chronic Health Conditions Among

- Adult Survivors of Childhood Cancer. *JNCI: Journal of the National Cancer Institute*, 113(5), 597-605. <https://doi.org/10.1093/jnci/djaa147>
152. Quiroz, N. H., Posadas Martínez, M. L., Rossi, E., Giunta, D., & Risk, M. (2022). Aprendizaje automático aplicado en área de la salud. Parte 2. *Revista del Hospital Italiano de Buenos Aires*, 42(1), 56-58. <https://doi.org/10.51987/revhospitalbaires.v42i1.152>
153. Quispe Montalvo, I. M., Córdor Gómez, C. A., & Hinostraza Robles, N. M. (2024). Efectividad del programa de musicoterapia, en el envejecimiento activo y saludable en la tercera edad—Anexo de Cochayoc, Tarma – 2022. *Revista Enfermería la Vanguardia*, 12(1), 21-32. <https://doi.org/10.35563/revan.v12i1.584>
154. Ramírez Arellano, O. A., & Mendoza-Núñez, V. M. (2022). Generatividad relativa a la salud. Una estrategia para el envejecimiento saludable desarrollada en México. *Revista Pensamiento y Acción Interdisciplinaria*, 8(2), 56-72. <https://doi.org/10.29035/pai.8.2.56>
155. Ramirez Vilchez, E. A., Salazar Zavaleta, J. R., Gomez Palomino, S. M., Martínez Díaz, N. E., & Chiri Saravia, P. C. (2022). Plataforma Canvas y el aprendizaje de matemáticas en estudiantes. *Ciencia Latina Revista Científica Multidisciplinar*, 6(4), 5428-5441. [https://doi.org/10.37811/cl\\_rcm.v6i4.3024](https://doi.org/10.37811/cl_rcm.v6i4.3024)
156. Ramos-Galarza, C. (2021). Editorial: Diseños de investigación experimental. *CienciaAmérica*, 10(1), 1-7. <https://doi.org/10.33210/ca.v10i1.356>
157. Ranji, A. R., Damodaran, V., Li, K., Chen, Z., Alirezaee, S., & Ahamed, M. J. (2022). Recent Advances in MEMS-Based 3D Hemispherical Resonator Gyroscope (HRG)—A Sensor of Choice. *Micromachines*, 13(10), 1676. <https://doi.org/10.3390/mi13101676>
158. Rast, F. M., Aschwanden, S., Werner, C., Demkó, L., & Labruyère, R. (2022). Accuracy and comparison of sensor-based gait speed estimations under standardized and daily life conditions in children undergoing rehabilitation. *Journal of NeuroEngineering and Rehabilitation*, 19(1), 105. <https://doi.org/10.1186/s12984-022-01079-3>
159. Realpe Muñoz, P. C., Erazo Aux, J., Cortés Carvajal, J. H., Erazo Aux, J., & Vargas Occa, J. (2023). Implementación en hardware para la medición de la aceleración usando FPGA. *Revista Sapientía*, 15(29). <https://doi.org/10.54278/sapientia.v15i29.126>
160. Reina, M., Mancha-Triguero, D., & Ibáñez, S. J. (2022). MONITORIZACIÓN DE UN

MICROCICLO COMPETITIVO EN BALONCESTO FEMENINO PROFESIONAL MEDIANTE DISPOSITIVOS INERCIALES. *Revista Internacional de Medicina y Ciencias de la Actividad Física y del Deporte*, 22(87), 663-685. <https://doi.org/10.15366/rimcafd2022.87.015>

161. Reyes Leiva, K. M., Jaén-Vargas, M., Cuba, M. Á., Lara, S. S., & Olmedo, J. J. S. (2021). A Proposal of a Motion Measurement System to Support Visually Impaired People in Rehabilitation Using Low-Cost Inertial Sensors. *Entropy*, 23(7), 848. <https://doi.org/10.3390/e23070848>
162. Ribera Casado, J. M. (2021). A decade for healthy ageing. 2020-2030. *ANALES RANM*, 138(138(03)), 214-220. <https://doi.org/10.32440/ar.2021.138.03.rev02>
163. Rodríguez Mañas, L., García-Sánchez, I., Hendry, A., Bernabei, R., Roller-Wirnsberger, R., Gabrovec, B., Liew, A., Carriazo, A. M., Redon, J., Galluzzo, L., Viña, J., Antoniadou, E., Targowski, T., Di Furia, L., Lattanzio, F., Bozdog, E., & Telo, M. (2018). Key Messages for a Frailty Prevention and Management Policy in Europe from the ADVANTAGE JOINT ACTION Consortium. *The Journal of Nutrition, Health & Aging*, 22(8), 892-897. <https://doi.org/10.1007/s12603-018-1064-y>
164. Rodríguez-Molinero, A., Narvaiza, L., Gálvez-Barrón, C., de la Cruz, J. J., Ruíz, J., Gonzalo, N., Valldosera, E., & Yuste, A. (2015). Caídas en la población anciana española: Incidencia, consecuencias y factores de riesgo. *Revista Española de Geriátría y Gerontología*, 50(6), 274-280. <https://doi.org/10.1016/j.regg.2015.05.005>
165. Roustaei, N. (2024). Application and interpretation of linear-regression analysis. *Medical hypothesis discovery and innovation in ophthalmology*, 13(3), 151-159. <https://doi.org/10.51329/mehdiophthal1506>
166. Rudnicka, E., Napierała, P., Podfigurna, A., Męczekalski, B., Smolarczyk, R., & Grymowicz, M. (2020). The World Health Organization (WHO) approach to healthy ageing. *Maturitas*, 139, 6-11. <https://doi.org/10.1016/j.maturitas.2020.05.018>
167. Ruiz-Ruiz, L., Jimenez, A. R., Garcia-Villamil, G., & Seco, F. (2021). Detecting Fall Risk and Frailty in Elders with Inertial Motion Sensors: A Survey of Significant Gait Parameters. *Sensors*, 21(20), 6918. <https://doi.org/10.3390/s21206918>
168. Sáez de Asteasu, M. L., Martínez-Velilla, N., Zambom-Ferraresi, F., Galbete, A.,

- Ramírez-Vélez, R., Cadore, E. L., Abizanda, P., Gómez-Pavón, J., & Izquierdo, M. (2024). Dose-Response Relationship Between Exercise Duration and Enhanced Function and Cognition in Acutely Hospitalized Older Adults: A Secondary Analysis of a Randomized Clinical Trial. *Innovation in Aging*, 8(6), igae053. <https://doi.org/10.1093/geroni/igae053>
169. Sanchez-Cárdenas, M. A., Correa Morales, J. E., Guerrero Benítez, A. C., Suarez Prieto, V. K., Moreno García, J. R., & León Delgado, M. X. (2021). Estrategias de evaluación del desarrollo de los Cuidados Paliativos: Una revisión sistemática. *Gerencia y Políticas de Salud*, 20. <https://doi.org/10.11144/Javeriana.rgps20-40.eedc>
170. Santafé Caiza, A. N., & Latta Sanchez, M. A. (2024). Análisis de la velocidad de la marcha en pacientes con EPOC. *Revista Científica de Salud BIOSANA*, 4(2), 96-105. <https://doi.org/10.62305/biosana.v4i2.138>
171. Santamaría Peláez, M., González Bernal, J., González Santos, J., & Soto Cámara, R. (2021). La calidad de vida de las personas mayores frágiles institucionalizadas. *Revista INFAD de Psicología. International Journal of Developmental and Educational Psychology*, 1(2), 89-100. <https://doi.org/10.17060/ijodaep.2020.n2.v1.1958>
172. Sethi, D., Prakash, C., & Bharti, S. (2024). MULTI-FEATURE gait analysis approach using deep learning in constraint-free environment. *Expert Systems*, 41(7), e13274. <https://doi.org/10.1111/exsy.13274>
173. Shah, V. V., McNames, J., Harker, G., Mancini, M., Carlson-Kuhta, P., Nutt, J. G., El-Gohary, M., Curtze, C., & Horak, F. B. (2020). Effect of Bout Length on Gait Measures in People with and without Parkinson's Disease during Daily Life. *Sensors*, 20(20), 5769. <https://doi.org/10.3390/s20205769>
174. Shi, L.-F., Liu, Z.-Y., Zhou, K.-J., Shi, Y., & Jing, X. (2023). Novel Deep Learning Network for Gait Recognition Using Multimodal Inertial Sensors. *Sensors*, 23(2), 849. <https://doi.org/10.3390/s23020849>
175. Silva, N., Rajado, A. T., Esteves, F., Brito, D., Apolónio, J., Roberto, V. P., Binnie, A., Araújo, I., Nóbrega, C., Bragança, J., Castelo-Branco, P., ALFAScore Consortium, Andrade, R. P., Calado, S., Faleiro, M. L., Matos, C., Marques, N., Marreiros, A., Nzwalo, H., ... Sardo, A. (2023). Measuring healthy ageing: Current and future tools. *Biogerontology*, 24(6), 845-

866. <https://doi.org/10.1007/s10522-023-10041-2>
176. Sirgo Álvarez, M. O. (2022). Envejecimiento activo desde una perspectiva de género. *Revista Iberoamericana de Bioética*, 19, 1-13. <https://doi.org/10.14422/rib.i19.y2022.003>
177. Soliman, A., Ribeiro, G. A., Torres, A., Wu, L.-F., & Rastgaar, M. (2022). Gait Phase Estimation of Unsupervised Outdoors Walking Using IMUs and a Linear Regression Model. *IEEE Access*, 10, 128090-128100. <https://doi.org/10.1109/ACCESS.2022.3227344>
178. Soltani, A. (2020). *Gait in real world: Validated algorithms for gait periods and speed estimation using a single wearable sensor* [Lausanne, EPFL]. <https://doi.org/10.5075/EPFL-THESIS-8099>
179. Soltani, A., Aminian, K., Mazza, C., Cereatti, A., Palmerini, L., Bonci, T., & Paraschiv-Ionescu, A. (2021). Algorithms for Walking Speed Estimation Using a Lower-Back-Worn Inertial Sensor: A Cross-Validation on Speed Ranges. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29, 1955-1964. <https://doi.org/10.1109/TNSRE.2021.3111681>
180. Song, N., Li, Z., Qin, N., Howell, C. R., Wilson, C. L., Easton, J., Mulder, H. L., Edmonson, M. N., Rusch, M. C., Zhang, J., Hudson, M. M., Yasui, Y., Robison, L. L., Ness, K. K., & Wang, Z. (2020). Shortened Leukocyte Telomere Length Associates with an Increased Prevalence of Chronic Health Conditions among Survivors of Childhood Cancer: A Report from the St. Jude Lifetime Cohort. *Clinical Cancer Research*, 26(10), 2362-2371. <https://doi.org/10.1158/1078-0432.CCR-19-2503>
181. Souweine, J.-S., Pasquier, G., Morena, M., Patrier, L., Rodriguez, A., Raynal, N., Ohresser, I., Benomar, R., Hayot, M., Mercier, J., Gouzi, F., & Cristol, J.-P. (2024). Beyond sarcopenia: Frailty in chronic haemodialysis patients. *Clinical Kidney Journal*, 17(7), sfae069. <https://doi.org/10.1093/ckj/sfae069>
182. Suarez Alemán, G. G., Velasco Rodríguez, V. M., Limones Aguilar, M. D. L., & Pereyra Navarro, Z. (2023). Caídas en el adulto mayor, en relación a su salud y capacidad funcional: Falls in the elderly, in relation to their health and functional capacity. *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, 4(3). <https://doi.org/10.56712/latam.v4i3.1130>

183. Takayanagi, N., Sudo, M., Yamashiro, Y., Lee, S., Kobayashi, Y., Niki, Y., & Shimada, H. (2019). Relationship between Daily and In-laboratory Gait Speed among Healthy Community-dwelling Older Adults. *Scientific Reports*, 9(1), 3496. <https://doi.org/10.1038/s41598-019-39695-0>
184. Tan, F., & Xie, X. (2021). Recognition Technology of Athlete's Limb Movement Combined Based on the Integrated Learning Algorithm. *Journal of Sensors*, 2021(1), 3057557. <https://doi.org/10.1155/2021/3057557>
185. Tarbert, R. J., & Singhatat, W. (2023). Real World Evidence of Wearable Smartbelt for Mitigation of Fall Impact in Older Adult Care. *IEEE Journal of Translational Engineering in Health and Medicine*, 11, 247-251. <https://doi.org/10.1109/JTEHM.2023.3256893>
186. Tasca, P., Salis, F., Rosati, S., Balestra, G., & Cereatti, A. (2024). *Estimating Gait Events and Speed in the Real World with a Head-Worn IMU*. <https://doi.org/10.36227/techrxiv.170654480.02767120/v1>
187. Tedesco, S., Crowe, C., Sica, M., Kenny, L., O'Flynn, B., Mueller, D. S., Timmons, S., & Barton, J. (2023). Gait speed estimation via inertial sensors and machine learning. *Gait & Posture*, 106, S201-S203. <https://doi.org/10.1016/j.gaitpost.2023.07.243>
188. Teufl, W., Taetz, B., Miezal, M., Dindorf, C., Fröhlich, M., Trinler, U., Hogan, A., & Bleser, G. (2021). Automated detection and explainability of pathological gait patterns using a one-class support vector machine trained on inertial measurement unit-based gait data. *Clinical Biomechanics*, 89, 105452. <https://doi.org/10.1016/j.clinbiomech.2021.105452>
189. Tipán Espinoza, J. M. (2022). Implementación de un algoritmo para detección del movimiento en una aplicación de realidad virtual. *REVISTA ODIGOS*, 3(3), 57-73. <https://doi.org/10.35290/ro.v3n3.2022.673>
190. Tziolas, T., Papageorgiou, K., Theodosiou, T., Papageorgiou, E., Mastos, T., & Papadopoulos, A. (2022). Autoencoders for Anomaly Detection in an Industrial Multivariate Time Series Dataset. *The 8th International Conference on Time Series and Forecasting*, 23. <https://doi.org/10.3390/engproc2022018023>
191. Ullrich, M., Kuderle, A., Hannink, J., Del Din, S., Gassner, H., Marxreiter, F., Klucken,


- J., Eskofier, B. M., & Kluge, F. (2020). Detection of Gait from Continuous Inertial Sensor Data Using Harmonic Frequencies. *IEEE Journal of Biomedical and Health Informatics*, 1-1. <https://doi.org/10.1109/JBHI.2020.2975361>
192. Urbanek, J. K., Zipunnikov, V., Harris, T., Crainiceanu, C., Harezlak, J., & Glynn, N. W. (2018). Validation of Gait Characteristics Extracted from Raw Accelerometry During Walking Against Measures of Physical Function, Mobility, Fatigability, and Fitness. *The Journals of Gerontology: Series A*, 73(5), 676-681. <https://doi.org/10.1093/gerona/glx174>
193. ÚRSULA SEGOVIANO. (2024, octubre 2). *Cambios en el protocolo de prevención de fragilidad en mayores: Sanidad trabaja en su actualización*. 65 y más - El diario de las personas mayores. [https://www.65ymas.com/salud/cambios-en-protocolo-prevencion-fragilidad-en-mayores-sanidad\\_63677\\_102.html](https://www.65ymas.com/salud/cambios-en-protocolo-prevencion-fragilidad-en-mayores-sanidad_63677_102.html)
194. Usami, T., Nishida, K., Iguchi, H., Okumura, T., Sakai, H., Ida, R., Horiba, M., Kashima, S., Sahashi, K., Asai, H., Nagaya, Y., Murakami, H., Ueki, Y., & Kuroyanagi, G. (2022). Evaluation of lower extremity gait analysis using Kinect V2<sup>®</sup> tracking system. *SICOT-J*, 8, 27. <https://doi.org/10.1051/sicotj/2022027>
195. Vargas-Del-Valle, M. C., Sánchez-Brenes, O., Sánchez-Brenes, M., Huete-Calderón, A., & Arias-Mora, R. A. (2021). Identificación de factores que afectan la aplicación de la prueba Short Physical Performance Battery en centros de atención para el adulto mayor. *Revista Tecnología en Marcha*. <https://doi.org/10.18845/tm.v34i4.5204>
196. Vavasour, G., Giggins, O. M., Doyle, J., & Kelly, D. (2021). How wearable sensors have been utilised to evaluate frailty in older adults: A systematic review. *Journal of NeuroEngineering and Rehabilitation*, 18(1), 112. <https://doi.org/10.1186/s12984-021-00909-0>
197. Villalba Mora, E., Petidier-Torregrossa, R., Alonso-Bouzon, C., Carnicero-Carreño, J. A., & Rodríguez-Mañas, L. (2015). Early detection of Heart Failure exacerbation by telemonitoring in old people. *International Journal of Integrated Care*, 15(5). <https://doi.org/10.5334/ijic.2173>
198. Villegas, D. A., Arana, M. V., Villar, P. S., Vizarrata, L. M. F., Chaparro, N. E. B., Soriano, A. O., Fajardo, M. R. V., Ancco, V. N. V., Orihuela, M. P., & Faneite, S. F. A. (2023). Calidad

- de la educación superior: Gestión estratégica, formación integral y soporte institucional. En *IDICAP PACÍFICO*. IDICAP PACÍFICO. <https://doi.org/10.53595/eip.007.2023>
199. Vivas Albán, O. A., Valencia Chacón, D. C., Quijano Guzmán, K. J., & 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), 252-266. <https://doi.org/10.17981/ingecuc.16.1.2020.19>
200. Wahl, H.-W. (2020). Aging Successfully: Possible in Principle? Possible for all? Desirable for all? *Integrative Psychological and Behavioral Science*, 54(2), 251-268. <https://doi.org/10.1007/s12124-020-09513-8>
201. Wang, H., Chen, X., Zheng, M., Wu, Y., & Liu, L. (2024). Research status and hotspots of social frailty in older adults: A bibliometric analysis from 2003 to 2022. *Frontiers in Aging Neuroscience*, 16, 1409155. <https://doi.org/10.3389/fnagi.2024.1409155>
202. Waskom, M. (2021). seaborn: Statistical data visualization. *Journal of Open-Source Software*, 6(60), 3021. <https://doi.org/10.21105/joss.03021>
203. Werner, C., Awai Easthope, C., Curt, A., & Demkó, L. (2021). Towards a Mobile Gait Analysis for Patients with a Spinal Cord Injury: A Robust Algorithm Validated for Slow Walking Speeds. *Sensors*, 21(21), 7381. <https://doi.org/10.3390/s21217381>
204. Wu, G., & Cavanagh, P. R. (1995). ISB recommendations for standardization in the reporting of kinematic data. *Journal of Biomechanics*, 28(10), 1257-1261. [https://doi.org/10.1016/0021-9290\(95\)00017-C](https://doi.org/10.1016/0021-9290(95)00017-C)
205. Xuan, C., Zhang, B., & Jia, X. (2023). The Effect of Human Settlement Pedestrian Environment on Gait of Older People: An Umbrella Review. *International Journal of Environmental Research and Public Health*, 20(2), 1567. <https://doi.org/10.3390/ijerph20021567>
206. Yan, F. (2023). Study on the Status Quo, Trend, Causes and Countermeasures of Population Aging in China. *Communications in Humanities Research*, 18(1), 151-157. <https://doi.org/10.54254/2753-7064/18/20231146>
207. Yang, S., Li, X., Qin, W., Yang, L., & Hu, W. (2022). Association Between Large Numbers of Enlarged Perivascular Spaces in Basal Ganglia and Motor Performance in

- Elderly Individuals: A Cross-Sectional Study. *Clinical Interventions in Aging, Volume 17*, 903-913. <https://doi.org/10.2147/CIA.S364794>
208. Zahn, A., Koch, V., Schreff, L., Oschmann, P., Winkler, J., Gaßner, H., & Müller, R. (2023). Validity of an inertial sensor-based system for the assessment of spatio-temporal parameters in people with multiple sclerosis. *Frontiers in Neurology, 14*, 1164001. <https://doi.org/10.3389/fneur.2023.1164001>
209. Zasukhin, I. V., Pushkov, V. Y., Shalymov, R. V., Tkachenko, A. N., & Larionov, D. Yu. (2022). The Concept of Speeding up Calibration Data Processing of Inertial Sensors. *2022 Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*, 1443-1446. <https://doi.org/10.1109/ElConRus54750.2022.9755453>
210. Zhang, K., Liu, W., Zhang, J., Li, Z., & Liu, J. (2023). A Fall Risk Assessment Model for Community-Dwelling Elderly Individuals Based on Gait Parameters. *IEEE Access, 11*, 120857-120867. <https://doi.org/10.1109/ACCESS.2023.3327091>
211. Zhang, P., Abudukelimu, N., Sali, A., Chen, J.-X., Li, M., Mao, Y.-Y., Zhu, Y., & Zhu, Q.-X. (2023). Sociodemographic features associated with the MoCA, SPPB, and GDS scores in a community-dwelling elderly population. *BMC Geriatrics, 23*(1), 557. <https://doi.org/10.1186/s12877-023-04162-z>
212. Zhou, Z., Huang, Y., Wang, J., Su, H., Tang, H., & Wang, Y. (2023). A novel digital biomarker of sarcopenia in frail elderly: New combination of gait parameters under dual-task walking. *Frontiers in Aging Neuroscience, 15*, 1087318. <https://doi.org/10.3389/fnagi.2023.1087318>

## X. ANEXOS

### Anexo 1 Sensor Vestible ActiveUP



Fuente: Memoria científica proyecto ActiveUP.


### Anexo 2. Dispositivo Final ActiveUP y MOTIVA.



Fuente: Elaboración Propia

### Anexo 3 Comparación Velocidades por Bouts - Paciente 0001.


Velocidad (Paciente 1)



Fuente: Elaboración Propia

Velocidad (Paciente 2)


### Anexo 4 Comparación Velocidades por Bouts - Paciente 0002



Fuente: Elaboración Propia

### Anexo 5 Comparación Velocidades por Bouts - Paciente 0003


Velocidad (Paciente 3)



Fuente: Elaboración Propia

### Anexo 6 Comparación Velocidades por Bouts - Paciente 0004


Velocidad (Paciente 4)



Fuente: Elaboración Propia

### Anexo 7 Comparación Velocidades por Bouts - Paciente 0005


Velocidad (Paciente 5)



Fuente: Elaboración Propia

### Anexo 8 Comparación Velocidades por Bouts - Paciente 0007


Velocidad (Paciente 7)



Fuente: Elaboración Propia

### Anexo 9 Comparación Velocidades por Bouts - Paciente 0009


Velocidad (Paciente 9)



Fuente: Elaboración Propia

### Anexo 10 Comparación Velocidades por Bouts - Paciente 5001


Velocidad (Paciente 5001)



Fuente: Elaboración Propia

### Anexo 11 Comparación Velocidades por Bouts - Paciente 5002.


Velocidad (Paciente 5002)



Fuente: Elaboración Propia


### Anexo 12 Comparación Velocidades por Bouts - Paciente 5003.

Velocidad (Paciente 5003)



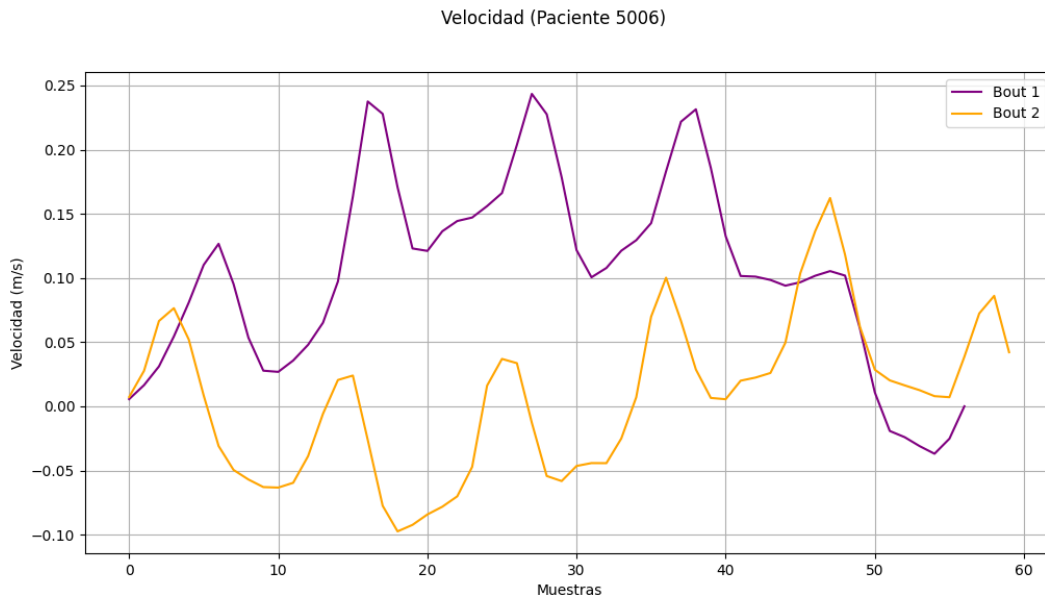
Fuente: Elaboración Propia

### Anexo 13 Comparación Velocidades por Bouts - Paciente 5004.




Fuente: Elaboración Propia

### Anexo 14 Comparación Velocidades por Bouts - Paciente 5006.




Fuente: Elaboración Propia

### Anexo 15 Comparación Velocidades por Bouts - Paciente 5007.



Fuente: Elaboración Propia


### Anexo 16 Comparación Velocidades por Bouts - Paciente 5008.



Fuente: Elaboración Propia

## Anexo 18 Comparación Velocidades por Bouts - Paciente 5009.

Velocidad (Paciente 5009)



Fuente: Elaboración Propia


## Anexo 17 Registro de 1 Bout Paciente 5009.

```
{ "evId": 2, "extraId": null, "phsId": "2", "tm": 10314, "res": 1, "sNum": null, "rNum": null, "ts": 1727777762411, "valido": true}
{ "evId": 3, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1727777774666, "valido": true}
{ "evId": 3, "extraId": null, "phsId": "2", "tm": 10243, "res": 2, "sNum": null, "rNum": null, "ts": 1727777784940, "valido": true}
{ "evId": 4, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": null, "ts": 1727777799838, "valido": true}
{ "evId": 4, "extraId": null, "phsId": "2", "tm": 2716, "res": 4, "sNum": null, "rNum": null, "ts": 1727777802591, "valido": true}
{ "evId": 5, "extraId": null, "phsId": "1", "tm": null, "res": null, "sNum": null, "rNum": 1, "ts": 1727777831175, "valido": true}
{ "evId": 5, "extraId": null, "phsId": "2", "tm": null, "res": null, "sNum": 0, "rNum": 1, "ts": 1727777833280, "valido": true}
```

Fuente: Elaboración Propia

## Anexo 19 Comparación Velocidades por Bouts - Paciente 5010.


Velocidad (Paciente 5010)



Fuente: Elaboración Propia

### Anexo 20 Comparación Velocidades por Bouts - Paciente 5011.


Velocidad (Paciente 5011)



Fuente: Elaboración Propia

### Anexo 21 Comparación Velocidades por Bouts - Paciente 5012.


Velocidad (Paciente 5012)



Fuente: Elaboración Propia

### Anexo 22 Comparación Velocidades por Bouts - Paciente 5013.


Velocidad (Paciente 5013)



Fuente: Elaboración Propia

### Anexo 23 Comparación Velocidades por Bouts - Paciente 5014.


Velocidad (Paciente 5014)



Fuente: Elaboración Propia

### Anexo 24 Comparación Velocidades por Bouts - Paciente 5015.


Velocidad (Paciente 5015)



Fuente: Elaboración Propia

### Anexo 25 Comparación Velocidades por Bouts - Paciente 5016.


Velocidad (Paciente 5016)



Fuente: Elaboración Propia

### Anexo 26 Comparación Velocidades por Bouts - Paciente 5017.


Velocidad (Paciente 5017)



Fuente: Elaboración Propia

### Anexo 27 Comparación Velocidades por Bouts - Paciente 5018.


Velocidad (Paciente 5018)



Fuente: Elaboración Propia

### Anexo 28 Comparación Velocidades por Bouts - Paciente 5019.


Velocidad (Paciente 5019)



Fuente: Elaboración Propia

### Anexo 29 Comparación Velocidades por Bouts - Paciente 5020.


Velocidad (Paciente 5020)



Fuente: Elaboración Propia

### Anexo 30 Comparación Velocidades por Bouts - Paciente 5021.


Velocidad (Paciente 5021)



Fuente: Elaboración Propia

### Anexo 31 Comparación Velocidades por Bouts - Paciente 5022.


Velocidad (Paciente 5022)



Fuente: Elaboración Propia

### Anexo 32 Comparación Velocidades por Bouts - Paciente 5023.


Velocidad (Paciente 5023)



Fuente: Elaboración Propia

### Anexo 33 Comparación Velocidades por Bouts - Paciente 5024.


Velocidad (Paciente 5024)



Fuente: Elaboración Propia

### Anexo 34 Comparación Velocidades por Bouts - Paciente 5025.

Velocidad (Paciente 5025)



Fuente: Elaboración Propia

### Anexo 35 Código de preprocesamiento de datos MOTIVA.

```
import pandas as pd
import os

# Montar Google Drive si los archivos están allí
from google.colab import drive
drive.mount('/content/drive')

# Configura las rutas de entrada y salida
input_folder = "/content/drive/MyDrive/motiva/datos/filtrados/"
output_folder = "/content/drive/MyDrive/motiva/datos/filtra2/"
import pandas as pd
import os

# Crear carpeta de salida si no existe
os.makedirs(output_folder, exist_ok=True)

# Diccionario de IDs y partes correspondientes
id_to_part = {
    1: "CINTURA",
    2: "BRAZO DERECHO (BD)",
    3: "BRAZO IZQUIERDO (BI)",
    4: "ANTEBRAZO DERECHO (AD)",
    5: "ANTEBRAZO IZQUIERDO (AI)",
    6: "MUSLO DERECHO (MD)",
    7: "MUSLO IZQUIERDO (MI)",
    8: "PANTORRILLA DERECHO (PD)",
    9: "PANTORRILLA IZQUIERDO (PI)",
}

# Procesar archivos en la carpeta de entrada
for file_name in os.listdir(input_folder):
    # Verificar si el archivo es CSV y contiene "_1" en el nombre
    if file_name.endswith(".csv") and "_1" in file_name:
        file_path = os.path.join(input_folder, file_name)
        try:
            # Leer archivo CSV
            df = pd.read_csv(file_path)

            # Calcular la diferencia de tiempo para detectar
            # discontinuidades directamente en el timestamp
            df['time_diff'] = df['timestamp'].diff()

            # Verificar las primeras filas para depuración
            print(f"Procesando archivo: {file_name}")
            print(df[['timestamp', 'time_diff']].head(10))

            # Asignar un ID único a cada tramo
            df['tramo_id'] = (df['time_diff'] > 1).cumsum() + 1

            # Separar los tramos en diferentes archivos
```

```

        for tramo_id, tramo_data in df.groupby('tramo_id'):
            # Crear nombre del archivo de salida con identificador
claro de tramo
            output_file = os.path.join(
                output_folder, f"{file_name.replace('.csv',
'')}_bout_{tramo_id}.csv"
            )

            # Guardar archivo del tramo
            tramo_data.drop(columns=['time_diff', 'tramo_id'],
inplace=True)
            tramo_data.to_csv(output_file, index=False)

            print(f"Archivo generado: {output_file}")

    except Exception as e:
        print(f"Error procesando {file_name}: {e}")

print("Procesamiento completo.")

```

### **Anexo 36 Función Matlab - Creación Dataset de Amplitudes**

```

function build_regression_dataset(signalset, write2file)
% esta función calcula las amplitudes de las transformadas de Hilbert
de
% cada eje de un bout y las guarda en el dataset.
% Directorio de señales recortadas
signals_dir = '/Users/fatimaalvarado/Documents/TESIS/PROYECTO 2
FUNCIONAL/PROYECTO/filtrados/filtra2';
% Directorio para guardar el dataset transitorio
dataset_dir = '/Users/fatimaalvarado/Documents/TESIS/PROYECTO 2
FUNCIONAL/PROYECTO/filtrados/resultados';
% Leer la lista de nombres de archivos en el directorio
listing = dir(fullfile(signals_dir, 'filtrado_*.csv'));
% Path completo al dataset resultante
dataset_tmp_path = fullfile(dataset_dir, 'amplitudes.csv');
% Definir parámetros al inicio de la función
fs = 18; % Frecuencia de muestreo (Hz)
tam = 2.5; % Duración de ventana (segundos)
flim = 0.5; % Frecuencia límite (Hz)
ang = 0; % Inclinación
g_ns = 0; % Dibujar o no (parámetro gráfico)
% Inicializar variables para almacenar resultados
num_files = length(listing);
AmpF = NaN(num_files, 1);
AmpL = NaN(num_files, 1);
AmpV = NaN(num_files, 1);
SUBJID = NaN(num_files, 1);
fecha = NaN(num_files, 1);
n_bout = NaN(num_files, 1);
real_speed = NaN(num_files, 1);

```

```

% Bucle para procesar cada archivo
for i = 1:num_files
try
% Leer señal del archivo
signal_fname = listing(i).name;
disp(sprintf('Procesando señal: %s', signal_fname));
signal = readtable(fullfile(signals_dir, signal_fname));
signal = table2array(signal);
signal = signal(all(~isnan(signal), 2), :); % Eliminar NaN
signal = signal(:, [1, 3, 4, 5]); % [timestamp, Ax, Ay, Az]
% Extraer SUBJID y n_bout del nombre del archivo
signal_info = sscanf(signal_fname, 'filtrado_%d_%d_%d_bout_%d.csv');
if length(signal_info) < 3
error('El nombre del archivo no tiene el formato esperado: %s',
signal_fname);
end
% Asignar valores extraídos
SUBJID(i) = signal_info(1);
fecha(i) = signal_info(2);
n_bout(i) = signal_info(4);
% Detectar tramos basados en `timestamp`
timestamps = signal(:, 1);
time_diff = diff(timestamps); % Diferencia entre timestamps
consecutivos
threshold = 5; % Define un umbral (ajusta según tus datos)
tramo_indices = [1; find(time_diff > threshold) + 1;
length(timestamps)];
if any(isnan(timestamps)) || ~issorted(timestamps)
disp(sprintf('Timestamps inválidos en archivo: %s', signal_fname));
continue;
end
% Calcular velocidad real (real_speed)
for tramo = 1:(length(tramo_indices) - 1)
start_idx = tramo_indices(tramo);
end_idx = tramo_indices(tramo + 1) - 1;
% Verificar longitud del tramo
if end_idx - start_idx + 1 < fs * tam
continue;
end
% Detectar inicio y fin del tramo
tramo_inicio = timestamps(start_idx);
tramo_final = timestamps(end_idx);
% Calcular velocidad real (real_speed)
distancia = 3; % Distancia conocida en metros
real_speed(i) = distancia / (tramo_final - tramo_inicio); % Velocidad
real m/s
end
if tramo_final <= tramo_inicio || isnan(tramo_inicio) ||
isnan(tramo_final)
disp(sprintf('Tramo inválido: inicio=%f, fin=%f, archivo=%s',
tramo_inicio, tramo_final, signal_fname));
end
end

```

```

% Obtener las amplitudes de Hilbert
try
[F, L, V] = get_hilbert_amplitudes(signal, fs, tam, flim, ang, g_ns,
SUBJID(i), signalset);
AmpF(i) = F;
AmpL(i) = L;
AmpV(i) = V;
catch ME
disp(sprintf('\tError obteniendo amplitudes de Hilbert para archivo:
%s', signal_fname));
disp(sprintf('Descripción del error: %s', ME.message));
end
catch
disp(sprintf('Error procesando el archivo: %s', signal_fname));
end
end
% Guardar tabla en fichero
if write2file == 1
disp('Escribiendo resultados en disco...');
clin_table = table(SUBJID, fecha, n_bout, real_speed, AmpF, AmpL,
AmpV, ...
'VariableNames', {'SUBJID', 'fecha', 'n_bout', 'real_speed', 'AmpF',
'AmpL', 'AmpV'});
writetable(clin_table, dataset_tmp_path);
end
end

```

### **Anexo 37 Función Matlab - Transformada de Hilbert**

```

function [AmpF AmpL AmpV] = get_hilbert_amplitudes(signal, fs, tam,
flim, ang, g_ns, id, signalset)
% esta función se usa para preparar el dataset final.
% se utiliza en buildregression_dataset.m
% reproduce el algoritmo de Mueller pero devuelve las amplitudes de
% Hilbert en vez de la estimación de la velocidad
%
% en su implementación actual no se tienen en cuenta los bouts
% detectados, es decir, la transformada de hilbert se aplica a la
señal
% de entrada entera (signal).
%
% los parámetros significan lo siguiente:
% signal: señal triaxial de acelerometría en m/s
% fs: frecuencia de muestreo(18Hz) tam: tamaño de la ventana (2.5 s)
% flim: frecuencia a partir de la que se considera que se camina (0.5)
% ang: ángulo a partir del que se elimina (si se pone cero no se
realiza este paso)
% g_ns: 1 para sacar la gráfica 0 si no se quiere la gráfica
% id: identificador para mostrar por pantalla al dibujar la señal.
% signalset: nombre del experimento en el que se recogió la señal
('mueller' | 'bringas')

```

```

%%ELIMINAR RUIDO
signal=remove_noise(signal,fs,0.7,3);
%disp(sprintf('signal(1,1) = %.4f\n', signal(1,1)));
%%DIVIDIR EN VENTANAS Y ELIMINAR FRECUENCIAS (NO CAMINAR)
[newsignal,bouts]=new_signal(signal,fs,tam,flim,ang);
%%DIBUJAR MARCAS REALES Y BOUTS
if isempty(bouts)==1
bouts (:1)=-1;
bouts (:2)=-1;
end
start_cell = { bouts(:, 1)};
end_cell = { bouts(:, 2)};
if g_ns ~= 0
%dibujar(id,signal,start_cell,end_cell);
dibujar(id,signal,start_cell,end_cell);
end
%%FILTRO BUTTERWORTH --> FALTA
if isempty(newsignal) == 0
%%TRANSFORMADA DE HILBERT
[Ampx,Ampy,Ampz]=t_hilbert(signal,fs);
if strcmp(signalset, 'bringas') == true
AmpF=Ampx;AmpL=Ampy;AmpV=Ampz;
elseif strcmp(signalset, 'mueller') == true
AmpF=Ampz;AmpL=Ampy;AmpV=Ampx;
elseif strcmp(signalset, 'motiva') == true
%AmpF=-Ampy;AmpL=Ampz;AmpV=-Ampx;% esto es lo que nos dijo juan
AmpF=Ampz;AmpL=Ampx;AmpV=Ampy; % nosotros creemos
end
%%COEFICIENTES CALCULADOS CON MOD.REG.LINEAL
%b=0.1549; bF=0.1768; bL=0.1309; bV=0.2092;
%Vel_res=b+AmpF*bF+AmpL*bL+AmpV*bV;
%VELOCIDAD REAL
%Vel_ref=get_vel_referencia(id,metros,intento);
else
%Vel_res = NaN;
AmpF = NaN; AmpL = NaN; AmpV = NaN;
end
end

```

### **Anexo 38 Código para calcular coeficientes de regresión lineal.**

```

# Este script está diseñado para ejecutarse en Google Colab y permite
cargar archivos desde Google Drive

# Paso 1: Importar librerías necesarias
import pandas as pd
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score,
mean_absolute_error
import numpy as np

```

```

import matplotlib.pyplot as plt

# Paso 2: Configurar Google Drive para cargar el archivo
from google.colab import drive

# Montar Google Drive
print("Montando Google Drive...")
drive.mount('/content/drive')

# Ingresar la ruta del archivo cargado en Google Drive
file_path = '/content/drive/My Drive/datos_con_motiva.csv'

# Paso 3: Cargar y explorar los datos
data = pd.read_csv(file_path)
print("Primeras filas del archivo cargado:")
print(data.head())

# Paso 4: Limpieza de datos
# Eliminar filas con valores faltantes en la columna de velocidad real
('real_speed')
data_cleaned = data.dropna(subset=['real_speed'])

# Seleccionar las variables independientes y dependiente
X_cleaned = data_cleaned[['AmpF', 'AmpL', 'AmpV']] # Variables
independientes: Amplitudes
y_cleaned = data_cleaned['real_speed'] # Variable dependiente:
Velocidad real

# Paso 5: Entrenar el modelo de regresión lineal
print("Entrenando el modelo de regresión lineal...")
model = LinearRegression()
model.fit(X_cleaned, y_cleaned)

# Obtener los coeficientes y el intercepto
intercept_cleaned = model.intercept_
coefficients_cleaned = model.coef_

# Paso 6: Calcular métricas de calidad
# Realizar predicciones
y_pred = model.predict(X_cleaned)

# Añadir la variable 'lineal_motiva_motiva' a data_cleaned
data_cleaned['lineal_motiva_motiva'] = y_pred

# Unir data_cleaned con data en función de las columnas SUBJID, fecha
y n_bout
# Esto es un merge utilizando las claves específicas sin duplicar
columnas
# Eliminar las columnas duplicadas de 'data_cleaned' que ya están en
'data'
data_drop = data_cleaned.drop(columns=['AmpF', 'AmpL', 'AmpV',
'real_speed', 'lineal_mueller_motiva'])

```

```

result = pd.merge(data, data_drop, on=['SUBJID', 'fecha', 'n_bout'],
how='left')

# Opcional: guardar el resultado en un archivo CSV
# result.to_csv('/content/drive/My Drive/datos_con_motiva.csv',
index=False)
result.to_csv('/content/drive/My Drive/datos_con_motiva.csv',
index=False)

print("Fusión completada. Los datos combinados se guardaron en
'data_con_motiva'.")

# Métricas de calidad
mse = mean_squared_error(y_cleaned, y_pred) # Error Cuadrático Medio
r2 = r2_score(y_cleaned, y_pred) # Coeficiente de Determinación R^2
mae = mean_absolute_error(y_cleaned, y_pred) # Error Absoluto Medio

# Calcular ICC (Coeficiente de Correlación Intraclase)
mean_y = np.mean(y_cleaned)
icc_numerator = np.sum((y_cleaned - mean_y) * (y_pred - mean_y))**2
icc_denominator = np.sum((y_cleaned - mean_y)**2) * np.sum((y_pred -
mean_y)**2)
icc = icc_numerator / icc_denominator if icc_denominator != 0 else 0

# Paso 7: Mostrar resultados
print("\nMétricas de calidad del modelo:")
print(f"Error Cuadrático Medio (MSE): {mse:.4f}")
print(f"Coeficiente de Determinación (R²): {r2:.4f}")
print(f"Error Absoluto Medio (MAE): {mae:.4f}")
print(f"Coeficiente de Correlación Intraclase (ICC): {icc:.4f}")

print("\nCoeficientes del modelo de regresión:")
print(f"Intercepto (b): {intercept_cleaned:.4f}")
print(f"Coeficiente AmpF (bF): {coefficients_cleaned[0]:.4f}")
print(f"Coeficiente AmpL (bL): {coefficients_cleaned[1]:.4f}")
print(f"Coeficiente AmpV (bV): {coefficients_cleaned[2]:.4f}")

# Paso 8: Guardar resultados en un archivo CSV
results = {
    "Métrica": [
        "Error Cuadrático Medio (MSE)",
        "Coeficiente de Determinación (R²)",
        "Error Absoluto Medio (MAE)",
        "Coeficiente de Correlación Intraclase (ICC)",
        "Intercepto (b)",
        "Coeficiente AmpF (bF)",
        "Coeficiente AmpL (bL)",
        "Coeficiente AmpV (bV)"
    ],
    "Valor": [
        round(mse, 4),

```

```

        round(r2, 4),
        round(mae, 4),
        round(icc, 4),
        round(intercept_cleaned, 4),
        round(coefficients_cleaned[0], 4),
        round(coefficients_cleaned[1], 4),
        round(coefficients_cleaned[2], 4)
    ]
}

results_df = pd.DataFrame(results)
output_path = '/content/drive/My Drive/resultados_regresion.csv'
results_df.to_csv(output_path, index=False)
print(f"\nResultados guardados en: {output_path}")

# Paso 9: Generar imagen de la tabla
fig, ax = plt.subplots(figsize=(8, 4))
ax.axis('tight')
ax.axis('off')
table = ax.table(cellText=results_df.values,
                 colLabels=results_df.columns, loc='center')

# Ajustar el tamaño de la fuente para que sea legible
table.auto_set_font_size(False)
table.set_fontsize(10)
table.auto_set_column_width(col=list(range(len(results_df.columns))))

# Guardar la tabla como imagen
image_path = '/content/drive/My Drive/resultados_regresion.png'
plt.savefig(image_path, bbox_inches='tight', dpi=300)
print(f"\nImagen de la tabla guardada en: {image_path}")

```

### **Anexo 39 Código Cálculo SVM Lineal.**

```

# Este script está diseñado para ejecutarse en Google Colab y permite
cargar archivos desde Google Drive

# Paso 1: Importar librerías necesarias
import pandas as pd
from sklearn.svm import SVR
from sklearn.metrics import mean_squared_error, r2_score,
mean_absolute_error
from sklearn.model_selection import learning_curve
import numpy as np
import matplotlib.pyplot as plt

# Paso 2: Configurar Google Drive para cargar el archivo
from google.colab import drive

# Montar Google Drive

```

```

print("Montando Google Drive...")
drive.mount('/content/drive')

# Ingresar la ruta del archivo cargado en Google Drive
file_path = '/content/drive/My Drive/datos_con_motiva.csv'

# Paso 3: Cargar y explorar los datos
data = pd.read_csv(file_path)
print("Primeras filas del archivo cargado:")
print(data.head())

# Paso 4: Limpieza de datos
# Eliminar filas con valores faltantes en la columna de velocidad real
('real_speed')
data_cleaned = data.dropna(subset=['real_speed']).copy()

# Seleccionar las variables independientes y dependiente
X_cleaned = data_cleaned[['AmpF', 'AmpL', 'AmpV']] # Variables
independientes: Amplitudes
y_cleaned = data_cleaned['real_speed'] # Variable dependiente:
Velocidad real

# Paso 5: Entrenar el modelo SVM lineal
print("Entrenando el modelo SVM lineal...")
model = SVR(kernel='linear')
model.fit(X_cleaned, y_cleaned)

# Obtener los coeficientes del modelo
intercept = model.intercept_[0] # Intercepto del modelo
coeficients = model.coef_[0] # Coeficientes de las características

# Paso 6: Calcular métricas de calidad
# Realizar predicciones
y_pred = model.predict(X_cleaned)

# Añadir la variable 'lineal_motiva_motiva' a data_cleaned
data_cleaned['svm_motiva'] = y_pred

# Unir data_cleaned con data en función de las columnas SUBJID, fecha
y n_bout
# Esto es un merge utilizando las claves específicas sin duplicar
columnas
# Eliminar las columnas duplicadas de 'data_cleaned' que ya están en
'data'
data_drop = data_cleaned.drop(columns=['AmpF', 'AmpL', 'AmpV',
'real_speed', 'lineal_mueller_motiva', 'lineal_motiva_motiva',
'rf_motiva'])

result = pd.merge(data, data_drop, on=['SUBJID', 'fecha', 'n_bout'],
how='left')

# Opcional: guardar el resultado en un archivo CSV

```

```

# result.to_csv('/content/drive/My Drive/datos_con_motiva.csv',
index=False)
result.to_csv('/content/drive/My Drive/datos_con_motiva.csv',
index=False)

print("Fusión completada. Los datos combinados se guardaron en
'data_con_motiva'.")

# Métricas de calidad
mse = mean_squared_error(y_cleaned, y_pred) # Error Cuadrático Medio
r2 = r2_score(y_cleaned, y_pred) # Coeficiente de Determinación R^2
mae = mean_absolute_error(y_cleaned, y_pred) # Error Absoluto Medio

# Calcular ICC (Coeficiente de Correlación Intraclase)
mean_y = np.mean(y_cleaned)
icc_numerator = np.sum((y_cleaned - mean_y) * (y_pred - mean_y))**2
icc_denominator = np.sum((y_cleaned - mean_y)**2) * np.sum((y_pred -
mean_y)**2)
icc = icc_numerator / icc_denominator if icc_denominator != 0 else 0

# Paso 7: Mostrar resultados tabulados
results = {
    "Métrica": [
        "Error Cuadrático Medio (MSE)",
        "Coeficiente de Determinación (R^2)",
        "Error Absoluto Medio (MAE)",
        "Coeficiente de Correlación Intraclase (ICC)",
        "Intercepto (b)",
        "Coeficiente AmpF (bF)",
        "Coeficiente AmpL (bL)",
        "Coeficiente AmpV (bV)"
    ],
    "Valor": [
        round(mse, 4),
        round(r2, 4),
        round(mae, 4),
        round(icc, 4),
        round(intercept, 4),
        round(coefficients[0], 4),
        round(coefficients[1], 4),
        round(coefficients[2], 4)
    ]
}

results_df = pd.DataFrame(results)

# Mostrar la tabla de resultados
print("\nResultados Tabulados:")
print(results_df.to_string(index=False))

# Mostrar las velocidades estimadas

```

```

print("\nVelocidades estimadas:")
print(data_cleaned[['real_speed']].head())

# Paso 8: Generar curva de aprendizaje
train_sizes, train_scores, test_scores = learning_curve(model,
X_cleaned, y_cleaned, cv=5, scoring='neg_mean_squared_error',

train_sizes=np.linspace(0.1, 1.0, 10), random_state=42)

# Calcular promedios y desviaciones estándar
train_scores_mean = -np.mean(train_scores, axis=1)
test_scores_mean = -np.mean(test_scores, axis=1)
train_scores_std = np.std(train_scores, axis=1)
test_scores_std = np.std(test_scores, axis=1)

# Graficar la curva de aprendizaje
plt.figure(figsize=(10, 6))
plt.fill_between(train_sizes, train_scores_mean - train_scores_std,
train_scores_mean + train_scores_std, alpha=0.1, color="r")
plt.fill_between(train_sizes, test_scores_mean - test_scores_std,
test_scores_mean + test_scores_std, alpha=0.1, color="g")
plt.plot(train_sizes, train_scores_mean, 'o-', color="r",
label="Puntaje en entrenamiento")
plt.plot(train_sizes, test_scores_mean, 'o-', color="g",
label="Puntaje en validación")
plt.title("Curva de Aprendizaje del Modelo SVM Lineal")
plt.xlabel("Tamaño del conjunto de entrenamiento")
plt.ylabel("Error cuadrático medio")
plt.legend(loc="best")
plt.grid()
plt.show()

```

#### **Anexo 40 Código Cálculo Random Forest (RF).**

```

# Código para calcular resultados usando Random Forest
# Este script está diseñado para ejecutarse en Google Colab y permite
cargar archivos desde Google Drive

# Paso 1: Importar librerías necesarias
import pandas as pd
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, r2_score,
mean_absolute_error
from sklearn.model_selection import learning_curve
import numpy as np
import matplotlib.pyplot as plt

# Paso 2: Configurar Google Drive para cargar el archivo
from google.colab import drive

```

```

# Montar Google Drive
print("Montando Google Drive...")
drive.mount('/content/drive')

# Ingresar la ruta del archivo cargado en Google Drive
file_path = '/content/drive/My Drive/datos_con_motiva.csv'
# Paso 3: Cargar y explorar los datos
data = pd.read_csv(file_path)
print("Primeras filas del archivo cargado:")
print(data.head())

# Paso 4: Limpieza de datos
# Eliminar filas con valores faltantes en la columna de velocidad real
('real_speed')
data_cleaned = data.dropna(subset=['real_speed']).copy()

# Seleccionar las variables independientes y dependiente
X_cleaned = data_cleaned[['AmpF', 'AmpL', 'AmpV']] # Variables
independientes: Amplitudes
y_cleaned = data_cleaned['real_speed'] # Variable dependiente:
Velocidad real

# Paso 5: Entrenar el modelo Random Forest
print("Entrenando el modelo Random Forest...")
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_cleaned, y_cleaned)

# Paso 6: Calcular métricas de calidad
# Realizar predicciones
y_pred = model.predict(X_cleaned)

# Añadir la variable 'lineal_motiva_motiva' a data_cleaned
data_cleaned['rf_motiva'] = y_pred

# Unir data_cleaned con data en función de las columnas SUBJID, fecha
y n_bout
# Esto es un merge utilizando las claves específicas sin duplicar
columnas
# Eliminar las columnas duplicadas de 'data_cleaned' que ya están en
'data'
data_drop = data_cleaned.drop(columns=['AmpF', 'AmpL', 'AmpV',
'real_speed', 'lineal_mueller_motiva', 'lineal_motiva_motiva'])

result = pd.merge(data, data_drop, on=['SUBJID', 'fecha', 'n_bout'],
how='left')

# Opcional: guardar el resultado en un archivo CSV
# result.to_csv('/content/drive/My Drive/datos_con_motiva.csv',
index=False)
result.to_csv('/content/drive/My Drive/datos_con_motiva.csv',
index=False)

```

```

print("Fusión completada. Los datos combinados se guardaron en
'data_con_motiva'.")

# Agregar las predicciones al DataFrame original
data_cleaned.loc[: 'predicted_speed'] = y_pred

# Guardar las velocidades estimadas en un archivo CSV incluyendo
subjid, fecha y n_bout
output_file_path = '/content/drive/My Drive/velocidades_estimadas.csv'
data_cleaned[['SUBJID', 'fecha', 'n_bout', 'real_speed',
'predicted_speed']].to_csv(output_file_path, index=False)
print(f"\nArchivo guardado en: {output_file_path}")

# Métricas de calidad
mse = mean_squared_error(y_cleaned, y_pred) # Error Cuadrático Medio
r2 = r2_score(y_cleaned, y_pred) # Coeficiente de Determinación R^2
mae = mean_absolute_error(y_cleaned, y_pred) # Error Absoluto Medio

# Calcular ICC (Coeficiente de Correlación Intraclase)
mean_y = np.mean(y_cleaned)
icc_numerator = np.sum((y_cleaned - mean_y) * (y_pred - mean_y))**2
icc_denominator = np.sum((y_cleaned - mean_y)**2) * np.sum((y_pred -
mean_y)**2)
icc = icc_numerator / icc_denominator if icc_denominator != 0 else 0

# Paso 7: Mostrar resultados tabulados
results = {
    "Métrica": [
        "Error Cuadrático Medio (MSE)",
        "Coeficiente de Determinación (R²)",
        "Error Absoluto Medio (MAE)",
        "Coeficiente de Correlación Intraclase (ICC)"
    ],
    "Valor": [
        round(mse, 4),
        round(r2, 4),
        round(mae, 4),
        round(icc, 4)
    ]
}

results_df = pd.DataFrame(results)

# Mostrar la tabla de resultados
print("\nResultados Tabulados:")
print(results_df.to_string(index=False))

# Mostrar las velocidades estimadas
print("\nVelocidades estimadas:")
print(data_cleaned[['SUBJID', 'fecha', 'n_bout', 'real_speed',
'predicted_speed']].head())

```

```

# Paso 8: Generar curva de aprendizaje
train_sizes, train_scores, test_scores = learning_curve(model,
X_cleaned, y_cleaned, cv=5, scoring='neg_mean_squared_error',

train_sizes=np.linspace(0.1, 1.0, 10), random_state=42)

# Calcular promedios y desviaciones estándar
train_scores_mean = -np.mean(train_scores, axis=1)
test_scores_mean = -np.mean(test_scores, axis=1)
train_scores_std = np.std(train_scores, axis=1)
test_scores_std = np.std(test_scores, axis=1)

# Graficar la curva de aprendizaje
plt.figure(figsize=(10, 6))
plt.fill_between(train_sizes, train_scores_mean - train_scores_std,
train_scores_mean + train_scores_std, alpha=0.1, color="r")
plt.fill_between(train_sizes, test_scores_mean - test_scores_std,
test_scores_mean + test_scores_std, alpha=0.1, color="g")
plt.plot(train_sizes, train_scores_mean, 'o-', color="r",
label="Puntaje en entrenamiento")
plt.plot(train_sizes, test_scores_mean, 'o-', color="g",
label="Puntaje en validación")
plt.title("Curva de Aprendizaje del Modelo fc")
plt.xlabel("Tamaño del conjunto de entrenamiento")
plt.ylabel("Error cuadrático medio")
plt.legend(loc="best")
plt.grid()
plt.show()

```

#### **Anexo 41 Código Adaptado de Mueller - MATLAB**

```

function Vel_res = mueller(signal, fs, tam, flim, ang, g_ns, id,
signalset, model)
% Validar entrada de signal
if isempty(signal) || size(signal, 2) < 4
error('La señal de entrada es inválida o no tiene suficientes
columnas.');
```

```

end
% Eliminar ruido
signal = remove_noise(signal, fs, 0.7, 3);
% Calcular amplitudes usando Hilbert
[Ampx, Ampy, Ampz] = t_hilbert (signal, fs);
% Asignar las amplitudes según el conjunto de señales
if strcmp (signalset, 'bringas')
AmpF = Ampx; AmpL = Ampy; AmpV = Ampz;
elseif strcmp (signalset, 'mueller')
AmpF = Ampz; AmpL = Ampy; AmpV = Ampx;
elseif strcmp (signalset, 'motiva')
AmpF = Ampz; AmpL = Ampx; AmpV = Ampy;
else
error ('Conjunto de señales no reconocido: %s', signalset);

```

```

end
% Verificar amplitudes
if any (isnan([AmpF, AmpL, AmpV]))
error ('Amplitudes de Hilbert contienen valores NaN.');
```

```

end
% Seleccionar modelo
switch model
case 'pau'
b = 0.1549; bF = 0.1768; bL = 0.1309; bV = 0.2092;
case 'new'
b = 0.36114; bF = 0.10164; bL = -0.01899; bV = 0.22733;
case 'lineal_motiva'
b = 0.3160; bF = 0.0610; bL = -0.0467; bV = 0.2769;
case 'SVM_motiva'
b = 0.3350; bF = 0.0356; bL = -0.0675; bV = 0.2898;
otherwise
error ('Modelo no reconocido: %s', model);
end
% Verificar coeficientes
if any (isnan([b, bF, bL, bV]))
error ('Coeficientes del modelo contienen valores NaN.');
```

```

end
% Calcular velocidad
Vel_res = b + AmpF * bF + AmpL * bL + AmpV * bV;
% Verificar resultado
if isnan (Vel_res)
error ('Velocidad estimada es NaN.');
```

```

end
end

```

#### **Anexo 42 Función Matlab – Transformada de Hilbert Amplitudes**

```

function [Ampx, Ampy, Ampz] = t_hilbert (signal, fs)
% Esta función calcula las transformadas de Hilbert para los ejes de
aceleración.
% Parámetros:
% - signal: Matriz de datos, donde la primera columna es el tiempo y
las columnas 2-4 son Ax, Ay, Az.
% - fs: Frecuencia de muestreo (Hz).
%
% Devuelve:
% - Ampx, Ampy, Ampz: Amplitudes medias en los ejes X, Y, Z.
% Validar entrada
if isempty(signal) || size (signal, 2) < 4
error ('La matriz "signal" debe contener al menos 4 columnas
(timestamp, Ax, Ay, Az).');
```

```

end
% Inicializar matrices de resultados
amp = zeros (3, size(signal, 1));
% Procesar cada eje
for i = 1:3
% Transformada de Hilbert

```

```

y = (:signal(:, i + 1)); % i+1 porque Ax, Ay, Az son columnas 2-4
% Frecuencia instantánea
frq = fs / (2 * pi) * diff(unwrap(angle(y)));
% Fase instantánea
fase = atan(imag(y)./ real(y));
% Amplitud
amp (i, :) = sqrt(real(y).^2 + imag(y).^2);
end
% Calcular amplitudes medias
Ampx = mean (amp(1, :), 'omitnan');
Ampy = mean (amp(2, :), 'omitnan');
Ampz = mean (amp(3, :), 'omitnan');
end

```

### **Anexo 43 Código Matlab – Obtención de velocidades por modelo y creación de dataset.**

```

function run_mueller_on_bringas(write2file)
% Silenciar los mensajes de warning
warning('off');
% Directorio de señales recortadas
signals_dir = 'C:\Users\aldai\Downloads\filtrados\filtra2';
% Directorio para guardar el dataset transitorio
dataset_dir = 'C:\Users\aldai\Downloads\filtrados\resultados';
% Nombre del fichero transitorio
bringas_fname = 'motiva_velocidades_modelos.csv';
% Leer la lista de nombres de archivos en el directorio
listing = dir (fullfile(signals_dir, 'filtrado_*.csv'));
% Cargar velocidades adicionales desde archivo
velocidades_adicionales =
readtable('C:\Users\aldai\Downloads\filtrados\resultados\velocidades_e
stimadas.csv');
% Inicializar variables
results_table = table ();
% Definir parámetros al inicio de la función
fs = 18; % Frecuencia de muestreo (Hz)
tam = 2.5; % Duración de ventana (segundos)
flim = 0.5; % Frecuencia límite (Hz)
ang = 0; % Inclinación
g_ns = 0; % Dibujar o no (parámetro gráfico)
% Modelos a evaluar
modelos = {'lineal_motiva', 'pau', 'new', 'SVM_motiva'};
for i = 1: length(listing)
% Leer señal del archivo
signal_fname = listing(i).name;
disp (sprintf('Procesando señal: %s\n', signal_fname));
try
% Leer la señal desde el archivo
signal = readtable (fullfile(signals_dir, signal_fname));
signal = table2array(signal);
signal = signal(all(~isnan(signal), 2), :); % Eliminar NaN

```

```

signal = signal(: [1, 3, 4, 5]); % [timestamp, Ax, Ay, Az]
% Extraer SUBJID y repeat_in_visit del nombre del archivo
signal_info = sscanf (signal_fname, 'filtrado_%d_%d_%d_bout_%d.csv');
if length(signal_info) <4
error ('El nombre del archivo no tiene el formato esperado: %s',
signal_fname);
end
SUBJID = signal_info (1);
fecha = signal_info (2);
repeat_in_visit = signal_info (4);
% Detectar inicio y fin del tramo
timestamps = signal(: 1);
tramo_inicio = timestamps (1);
tramo_final = timestamps(end);
% Calcular velocidad real
if tramo_final > tramo_inicio
real_speed = 3 / (tramo_final - tramo_inicio); % Velocidad en m/s
else
real_speed = NaN;
end
% Calcular velocidades estimadas para cada modelo
velocidades = NaN (1, length(modelos));
for m = 1: length(modelos)
modelo = modelos{m};
try
velocidades(m) = mueller (signal, fs, tam, flim, ang, g_ns, SUBJID,
'motiva', modelo);
catch muellerError
disp (sprintf('Error calculando velocidad con modelo %s: %s', modelo,
muellerError.message));
end
end
% Buscar velocidades adicionales en el archivo
idx_adicional = find (velocidades_adicionales.SUBJID == SUBJID &
velocidades_adicionales.n_bout == repeat_in_visit, 1);
if ~isempty(idx_adicional)
vel_rf_motiva = velocidades_adicionales.
predicted_speed(idx_adicional);
else
vel_rf_motiva = NaN;
end
% Agregar resultados a la tabla
results_table_temp = table (SUBJID, fecha, repeat_in_visit,
tramo_inicio, tramo_final, real_speed, ...
velocidades (1), velocidades(2), velocidades(3), velocidades(4), ...
vel_rf_motiva, ...
'VariableNames', {'SUBJID', 'fecha', 'repeat_in_visit',
'tramo_inicio', 'tramo_final', 'real_speed', ...
'vel_lineal_motiva', 'vel_pau', 'vel_new', 'vel_SVM_motiva', ...
'vel_rf_motiva'});
results_table = [results_table; results_table_temp];
catch ME

```

```

disp (sprintf('Error procesando el archivo: %s', signal_fname));
disp (sprintf('Descripción del error: %s', ME.message));
end
end
% Guardar resultados en fichero
if write2file == 1 && ~isempty(results_table)
disp ('Escribiendo resultados en disco...\n');
writetable (results_table, fullfile(dataset_dir, bringas_fname),
'WriteMode', 'overwrite');
end
end

```

#### **Anexo 44 Función Matlab Filtro de señales.**

```

function [newsignal, bouts, angulo] = new_signal (ns, fs, tam, flim,
ang)
% Validar entrada
if isempty(ns) || size (ns, 2) < 4
error ('La matriz "ns" debe contener al menos 4 columnas (timestamp,
Ax, Ay, Az).');
end
% Mostrar dimensiones iniciales
disp ('Dimensiones iniciales de ns:');
disp(size(ns));
% Concatenar columna adicional (siempre será válida)
vector_to_add = (1: size(ns, 1))';
disp ('Dimensiones del vector a concatenar:');
disp(size(vector_to_add));
ns = [ns, vector_to_add];
% Mostrar dimensiones después de la concatenación
disp ('Dimensiones de ns después de concatenar:');
disp(size(ns));
% Inicializar variables
cont = 1;
n = 1;
Ax = [];
Ay = [];
Az = [];
time2 = [];
% Dividir la señal en ventanas y eliminar frecuencias no deseadas
for j = round (ns(1, 1) / tam) * tam : tam : floor(ns(end, 1) / tam) *
tam
cont1 = 1;
for i = cont: size(ns, 1)
if ns (i, 1) >= j && ns(i, 1) < (j + tam)
Ax (n, cont1) = ns(i, 3);
Ay (n, cont1) = ns(i, 4);
Az (n, cont1) = ns(i, 5);
time (n, cont1) = ns(i, 1) - j;
cont1 = cont1 + 1;
cont = cont + 1;

```

```

end
end
if cont1 > 1
% Calcular frecuencias de Ax y Az
[plx, ~] = freq (Ax, n, cont1, fs);
[plz, ~] = freq (Az, n, cont1, fs);
if (max(plx) > flim) || (max(plz) > flim)
time2(n, 1: cont1 - 1) = time(n, 1:cont1 - 1) + j;
end
end
n = n + 1;
end
% Reshape de time2 para manejar datos únicos
if exist ('time2', 'var') && ~isempty(time2)
time3 = reshape (time2, 1, []);
time3 = unique(sort(time3)); % Eliminar duplicados y ordenar
else
time3 = [];
end
% Detectar bouts
if ~isempty(time3)
bouts = sacar_bouts (ns, time3)';
NS = filtrar_signal (ns, time3);
else
bouts = [];
NS = [];
end
% Filtrar por inclinación si aplica
if ~isempty (NS)
if ang ~= 0
angulo = inclinacion (NS);
time4 = elimar_inc (NS, angulo, ang)';
bouts = sacar_bouts(NS, time4)';
newsignal = filtrar_signal(NS, time4);
else
newsignal = NS;
end
else
newsignal = [];
end
end
function NS_filtered = filtrar_signal(ns, time_indices)
% Filtrar señal basado en índices de tiempo
NS_filtered = [];
n = 1;
for j = 1:length(time_indices)
[row, ~] = find(abs(ns(:, 1) - time_indices(j)) < 1e-6); % Tolerancia
flotante
if ~isempty(row)
NS_filtered(n, :) = ns(row(1), :); % Tomar primera coincidencia
n = n + 1;
end
end

```

```
end
end
```

### Anexo 45 Funcion Matlab - Obtención Bouts.

```
function bouts = sacar_bouts(signal, time)
% Esta función delimita los bouts en la señal
% Inicializar arrays
time(time == 0) = [];
n = 1;
row = [];
col = [];
% Iterar sobre los valores de `time`
for i = 1:length(time)
indices = find(abs(signal(:, 1) - time(i)) < 1e-6); % Tolerancia para
flotantes
if isempty(indices)
% Si no hay coincidencias
warning('No se encontró coincidencia para time(%d) = %f', i, time(i));
continue;
elseif length(indices) > 1
% Si hay múltiples coincidencias, tomar la primera
warning('Múltiples coincidencias para time(%d) = %f. Usando la
primera.', i, time(i));
indices = indices(1);
end
% Guardar resultado
row(n) = indices;
n = n + 1;
end
% Detectar transiciones entre índices consecutivos
transitions = diff(row) == 1; % Transiciones continuas
transitions = [transitions, 0]; % Para alinear con `row`
% Inicializar inicios y finales de bouts
start_b = [];
end_b = [];
m = 1;
for i = 1:length(transitions)
if transitions(i) && (isempty(start_b) || row(i) ~= start_b(end))
start_b(m) = row(i);
elseif ~transitions(i) && ~isempty(start_b) && length(start_b) >
length(end_b)
end_b(m) = row(i);
m = m + 1;
end
end
% Si `start_b` y `end_b` tienen tamaños diferentes, alinear
if length(start_b) > length(end_b)
end_b(end + 1) = row(end); % Final del último bout
end
% Salida
```

```
bouts = [start_b; end_b];  
end
```