



Universidad de Concepción
Dirección de Postgrado
Facultad de Ingeniería - Programa de Magíster

Segmentación Automática del Test Timed Up and Go mediante BiLSTM con datos de una IMU: Extracción de Biomarcadores Cinemáticos

Tesis para optar al grado de Magíster en Ciencias de la Ingeniería con
mención en Ingeniería Eléctrica

Loreto Valentina Rojas Sandoval
CONCEPCIÓN-CHILE
DICIEMBRE 2025

Profesor Guía: Pablo Aqueveque Navarro
Dpto. de Ingeniería Eléctrica, Facultad de Ingeniería
Universidad de Concepción

Resumen

El Timed Up and Go (TUG) es una prueba funcional ampliamente utilizada para evaluar la movilidad, el equilibrio y el riesgo de caídas, especialmente en adultos mayores y personas con patologías neurológicas. Sin embargo, su enfoque tradicional basado en el tiempo total presenta limitaciones significativas al no considerar aspectos cualitativos del movimiento, como la estabilidad durante los giros y la coordinación al levantarse. Para abordar estas limitaciones, la integración de unidades de medición inercial (IMU) y algoritmos, ha permitido segmentar el TUG en subetapas específicas, mejorando la precisión en la detección de deficiencias motoras.

Este trabajo propone un método automatizado para la segmentación de las seis subetapas del TUG utilizando una única unidad de medición inercial (IMU) ubicada en la región lumbar y un modelo de aprendizaje profundo basado en arquitecturas BiLSTM.

Se recopilieron 315 ensayos de TUG provenientes de participantes de distintos rangos etarios y niveles funcionales, incluyendo sujetos sanos y personas con disfunción. Las señales inerciales fueron preprocesadas y etiquetadas manualmente en Label Studio para generar el dataset de entrenamiento. El modelo BiLSTM, compuesto por dos capas bidireccionales apiladas y una capa fully connected final, fue entrenado con un split 80/20 utilizando Adam, una tasa de aprendizaje de 0.0005 y 150 épocas. El modelo alcanzó un desempeño robusto, con precisiones y F1-scores superiores al 90% en la mayoría de las subetapas, y errores temporales (MAE) entre 0.28 y 0.40 segundos. La comparación con evaluadores clínicos demostró una alta concordancia, con ICC de hasta 0.98 para el tiempo total del TUG y valores de MAE similares a los observados entre los propios clínicos. Además, la segmentación automática permitió la extracción de 60 biomarcadores cinemáticos y temporales seleccionados mediante Recursive Feature Elimination (RFE), los cuales presentaron una alta capacidad discriminativa entre grupos etarios y funcionales (AUC de hasta 0.98 en la etapa de segundo giro).

Finalmente, se establecieron rangos de referencia estratificados por edad para los biomarcadores derivados, y se observaron correlaciones significativas con la edad en varios de ellos, lo que confirma su relevancia clínica. Los resultados sugieren que este enfoque basado en una única IMU y un modelo BiLSTM constituye una herramienta precisa, reproducible y clínicamente útil para la segmentación automática del TUG y la caracterización del movimiento humano.

Abstract

The Timed Up and Go (TUG) test is a widely used functional assessment to evaluate mobility, balance, and fall risk, particularly in older adults and individuals with neurological conditions. However, its traditional approach based solely on total completion time presents significant limitations, as it fails to capture qualitative aspects of movement, such as stability during turning and coordination when standing up. To address these limitations, the integration of inertial measurement units (IMUs) and algorithmic analysis has enabled the segmentation of the TUG into specific subphases, improving the accuracy in detecting motor impairments.

This work proposes an automated method for segmenting the six TUG subphases using a single inertial measurement unit (IMU) placed on the lumbar region and a deep learning model based on a BiLSTM architecture.

A total of 315 TUG trials were collected from participants spanning different age groups and functional levels, including both healthy individuals and those with mobility impairments. The inertial signals were preprocessed and manually annotated in Label Studio to generate the training dataset. The BiLSTM model, composed of two stacked bidirectional layers and a final fully connected layer, was trained using an 80/20 split with the Adam optimizer, a learning rate of 0.0005, and 150 epochs. The model achieved robust performance, with accuracies and F1-scores above 90% in most subphases and temporal errors (MAE) ranging from 0.28 to 0.40 seconds. Comparison with clinical evaluators showed high agreement, with ICC values up to 0.98 for total TUG time and MAE values similar to those observed between clinicians themselves.

Furthermore, the automatic segmentation enabled the extraction of 60 temporal and kinematic biomarkers selected through RFE, which demonstrated high stability (79%) and strong discriminative capacity across age and functional groups (AUC values up to 0.98 in the second turning phase).

Finally, age-stratified reference ranges were established for all derived biomarkers, and several showed significant correlations with age, confirming their clinical relevance. Overall, the results suggest that this approach, based on a single IMU and a BiLSTM model, provides a precise, reproducible, and clinically meaningful tool for automatic TUG segmentation and human movement characterization.

Agradecimientos

Quisiera agradecer, en primer lugar, a mi familia: a mis padres, a mis hermanos, Isi y Pablo, por su apoyo incondicional, y a mi abuelita Sara, quien fue una gran fuente de motivación e inspiración para trabajar y atreverme por las cosas que quiero.

Agradezco también a mis profesores, en especial al profesor Pablo Aqueveque, por guiarme a lo largo de este proceso, así como a cada uno de los integrantes de IDS Lab, que siempre han aportado con sus buenas ideas y consejos.

Finalmente, extiendo mi agradecimiento a todos mis amigos y amigas. En especial, quiero mencionar a Sofía, Feña, Martín y, muy especialmente, a Paz, por su compañía a lo largo de todos estos años de carrera, desde el inicio.

Tabla de Contenidos

INTRODUCCIÓN	2
1.1. INTRODUCCIÓN GENERAL.....	2
1.2. HIPÓTESIS	3
1.2.1 <i>Objetivo General</i>	3
1.2.2 <i>Objetivos Específicos</i>	3
1.3. ALCANCES	3
1.4. LIMITACIONES.....	4
CAPÍTULO 2. MARCO TEÓRICO.....	5
2.1. TIMED UP AND GO	5
2.2. UNIDAD DE MEDICIÓN INERCIAL	6
2.3. TIMED UP AND GO INSTRUMENTADO (iTUG)	8
2.4. SISTEMA ÓPTICO BASADOS EN MARCADORES	8
2.5. REDES NEURONALES PROFUNDAS (DEEP LEARNING).....	9
2.5.1 <i>Redes Neuronales Recurrentes (RNN)</i>	10
2.5.2 <i>Long Short-Term Memory (LSTM)</i>	11
2.5.3 <i>Redes Bidireccionales Long Short-Term Memory (BiLSTM)</i>	12
2.6. BIOMARCADORES DIGITALES	12
2.7. BIOMARCADORES DE MOVILIDAD FUNCIONAL DERIVADOS DEL iTUG	13
2.7.1 <i>Biomarcadores Temporo-espaciales</i>	13
2.7.2 <i>Biomarcadores Cinemáticos</i>	14
CAPÍTULO 3. ESTADO DEL ARTE: INSTRUMENTACIÓN DEL TEST TIMED UP AND GO.....	15
3.1. ALGORITMOS PARA LA SEGMENTACIÓN AUTOMÁTICA DEL TUG	15
3.1.1 <i>Algoritmos de Segmentación Basados en Reglas</i>	15
3.1.2 <i>Métodos de Aprendizaje Automático y Deep Learning</i>	16
3.1.3 <i>Discusión</i>	18
3.2. CARACTERIZACIÓN DE SEÑALES INERCIALES Y BIOMARCADORES CINEMÁTICOS DEL iTUG	19
3.2.1 <i>Parámetros de Acelerometría</i>	19
3.2.2 <i>Velocidad Angular</i>	20
3.2.3 <i>Ángulos de Navegación y Cinemática Articular</i>	21
CAPÍTULO 4. METODOLOGÍA.....	22
4.1. PARTICIPANTES.....	22
4.1.1 <i>Criterios de Inclusión</i>	22
4.1.2 <i>Criterios de Exclusión</i>	23
4.1.3 <i>Participantes Sanos</i>	23
4.1.4 <i>Participantes con alteraciones de la marcha</i>	23
4.1.5 <i>Comité de Ética</i>	23
4.2. INSTRUMENTACIÓN Y PROTOCOLO EXPERIMENTAL	25
4.2.1 <i>Instrumentación</i>	25
4.2.2 <i>Procedimiento de Adquisición de Datos</i>	26
4.3. PROCESAMIENTO DE SEÑALES Y GENERACIÓN GROUND TRUTH.....	27
4.3.1 <i>Preprocesamiento de señales</i>	27
4.3.2 <i>Protocolo de Etiquetado en Label Studio</i>	29
4.3.3 <i>Ground Truth Clínico Basado en Video (Para Validación)</i>	30
4.4. DESARROLLO DE UN MODELO DE SEGMENTACIÓN AUTOMÁTICA	31
4.4.1 <i>Arquitectura Propuesta: Modelo BiLSTM</i>	32
4.4.2 <i>Entrenamiento del Modelo</i>	33
4.5. ESTRATEGIA DE VALIDACIÓN	34
4.5.1 <i>Validación Técnica</i>	34
4.5.2 <i>Validación Clínica</i>	35
1) <i>Diferencia de Tiempos ΔT</i>	35
2) <i>Mean Absolute Error (MAE)</i>	35

3)	<i>Coefficiente de correlación de Pearson (r)</i>	35
4)	<i>Coefficiente de Correlación Intraclase (ICC)</i>	36
4.6.	CARACTERIZACIÓN DE BIOMARCADORES CINEMÁTICOS	36
4.6.1	<i>Definición de características a partir de la segmentación</i>	36
4.6.2	<i>Análisis de la duración de subetapas por grupo</i>	37
4.6.3	<i>Selección de Biomarcadores mediante Recursive Feature Elimination (RFE)</i>	38
4.6.4	<i>Validez de la Selección de Características</i>	39
4.6.5	<i>Definición de patrones de normalidad en función de la edad</i>	40
CAPÍTULO 5. RESULTADOS		41
5.1.	RENDIMIENTO DEL MODELO	41
5.1.1	<i>Validación Técnica del Modelo BiLSTM</i>	41
5.1.2	<i>Confiabilidad Inter-evaluador</i>	42
5.1.3	<i>Validación Clínica</i>	43
5.2.	CARACTERIZACIÓN DE BIOMARCADORES.....	45
5.2.1	<i>Biomarcadores Cinemáticos más discriminativos según RFE</i>	45
5.2.2	<i>Análisis de Estabilidad del Algoritmo RFE</i>	45
5.2.3	<i>Poder Discriminativo</i>	46
5.3.	PATRONES DE NORMALIDAD DE BIOMARCADORES EN FUNCIÓN DE LA EDAD.....	47
5.3.1	<i>Caracterización de la población de referencia</i>	47
5.3.2	<i>Duración de las subetapas del TUG por grupo etario</i>	48
5.3.3	<i>Distribución de normalidad de los biomarcadores</i>	50
5.3.4	<i>Rangos de normalidad por etapa</i>	50
5.3.5	<i>Tendencias de cambio con la edad</i>	51
CAPÍTULO 6. DISCUSIONES Y CONCLUSIONES		54
6.1.	DISCUSIÓN	54
6.1.1	<i>Desempeño técnico del modelo de segmentación</i>	54
6.1.2	<i>Concordancia del ground truth: confiabilidad Inter-evaluador</i>	55
6.1.3	<i>Validación clínica del modelo frente a evaluadores</i>	55
6.1.4	<i>Biomarcadores cinemáticos: selección, estabilidad y relevancia clínica</i>	56
6.1.5	<i>Diferencias en la duración de las subetapas entre grupos</i>	57
6.1.6	<i>Establecimiento de rangos de normalidad</i>	58
6.1.7	<i>Tendencias de los biomarcadores con la edad</i>	58
6.2.	LIMITACIONES.....	59
6.3.	CONCLUSIÓN.....	60
6.4.	TRABAJO FUTURO	61
CAPÍTULO 7. ENVÍO ARTÍCULO CIENTÍFICO		63
CAPÍTULO 8. GLOSARIO		64
CAPÍTULO 9. REFERENCIAS		65
CAPÍTULO 10. ANEXOS		71
ANEXO A: RANGOS DE REFERENCIA DE BIOMARCADORES DEL ÍTUG		71
ANEXO B: BOXPLOTS DE DISTRIBUCIÓN DE VALORES BIOMARCADORES EN LAS ETAPAS ÍTUG.....		73
ANEXO C: TENDENCIAS LINEALES CON LA EDAD Y BIOMARCADORES EN ETAPAS DEL ÍTUG		76

Lista de Figuras

Fig. 2-1 Representación del uso de Unidad de Medición Inercial durante la marcha y los ejes de movimiento.....	7
Fig. 2-2 Representación de Redes Neuronales en Deep Learning [36].....	10
Fig. 2-3 Diagrama de funcionamiento de un modelo LSTM [39].....	11
Fig. 2-4 Marco integral para los sistemas portátiles de monitorización de la salud [46]......	13
Fig. 4-1 Diagrama de Flujo Metodología.....	22
Fig. 4-2 Instrumentación durante la prueba. (a) Unidad de Medición Inercial localizada en región L5-S1 y orientación sensor; (b) Identificación de marcador de sistema Optitrack.	26
Fig. 4-3 Secuencia del test Timed Up and Go: (a) Etapa inicial Pararse; (b) Etapa Caminata ida; (c) Inicio Primer Giro; (d) Inicio etapa Caminata Vuelta; (e) Etapa Segundo Giro; (f) Etapa Sentarse.	27
Fig. 4-4 Obtención y etiquetado de datos para entrenamiento del modelo.	30
Fig. 4-5. Metodología general para la segmentación del test TUG: (a) Setup de adquisición de datos; (b) Arquitectura del modelo propuesto; (c) Salida de segmentación que muestra la duración de cada subtarea del TUG.	32
Fig. 4-6 Output del modelo: Segmentación de la prueba TUG en sus subetapas, a través de sus señales de entrada Pitch y Yaw.	34
Fig. 4-7 Planos anatómicos y ejes XYZ del sistema de referencia de la IMU.....	36
Fig. 4-8 Señales inerciales y ángulos de navegación: segmentadas por etapas para un intento del test TUG.....	37
Fig. 4-9 Flujo general de la extracción de biomarcadores mediante RFE.	38
Fig. 4-10 Proceso de selección de biomarcadores mediante RFE.....	39
Fig. 5-1 Matriz de confusión del modelo de segmentación para las subetapas de la prueba TUG, evaluada a nivel de muestras temporales. Los valores representan el número de puntos clasificados por subetapa.....	41
Fig. 5-2 Gráficos de ICC y Diferencia de tiempo promedio (Evaluador 1 vs Evaluador 2).	42
Fig. 5-3 Bland-Altman: Concordancia Inter-evaluador (Tiempo Total TUG).....	43
Fig. 5-4 Error promedio absoluto de segmentación automática vs evaluadores.	44
Fig. 5-5 Duración media por subetapa: Modelo vs evaluadores.	44
Fig. 5-6 Heatmap de la Estabilidad de selección de biomarcadores por RFE según etapa TUG.....	46
Fig. 5-7 Biomarcadores según nivel de confianza por subetapa: (a) Clasificación por nivel de confianza. (b) Distribución de BM por tipo de señal.	46
Fig. 5-8 Heatmap del poder discriminativo (AUC) entre grupos a partir de biomarcadores de cada etapa TUG.	47
Fig. 5-9 Comparaciones de la duración de las subtarefas TUG entre los grupos de participantes: (A) Pararse, (B) Caminata ida, (C) Primer giro, (D) Caminata vuelta, (E) Segundo giro, (F) Sentarse. Se muestran los valores medianos con rangos intercuartílicos (IQR); Niveles de significación: *p < 0.05, **p < 0.01, ***p < 0.001 (prueba de Dunn con corrección de Bonferroni).	49
Fig. 5-10 Boxplots de Rangos percentílicos (2.5–97.5) de biomarcadores correspondientes a la etapa Primer Giro del test iTUG: (a) <i>Vyrms</i> ; (b) <i>Vymax</i> ; (c) <i>axstd</i> ; (d) <i>Vxmean</i> ; (e) <i>aystd</i> ; (f) <i>axrms</i>	51
Fig. 5-11 Tendencias Lineales entre biomarcadores y la edad en etapa Caminata Vuelta.	52
Fig. 5-12 Los seis biomarcadores con mayor relación con la edad en el análisis global del TUG. Cada gráfico presenta la regresión lineal entre la edad y un parámetro cinemático (biomarcador) específico, ordenados por fuerza de correlación (R^2 descendente).	53

Lista de Tablas

Tabla I Tiempos TUG Riesgo de caídas en población chilena	6
Tabla II Características demográficas de participantes con alteraciones de la marcha.....	24
Tabla III Características Técnicas de la IMU.....	25
Tabla IV. Criterios biomecánicos utilizada por los observadores clínicos para la identificación de Subetapas del test TUG [75].	31
Tabla V Métricas de rendimiento del modelo de segmentación.	41
Tabla VI. Análisis Confiabilidad Inter-evaluador.....	42
Tabla VII Métricas de concordancia entre algoritmo de segmentación automática y cada evaluador clínico.....	43
Tabla VIII Biomarcadores seleccionados por etapa TUG mediante algoritmo RFE.	45
Tabla IX Características demográficas y antropométricas de los participantes.....	48
Tabla X. Resultados de la prueba de Kruskal-Wallis para las duraciones en los distintos grupos de participantes.	49
Tabla XI Métricas de correlación entre la edad y valor de biomarcador: 10 más significativos.	52
Tabla XII Rangos de referencia de Biomarcadores del iTUG según grupo etario.....	71

Introducción

1.1. Introducción General

Las caídas son eventos imprevistos en los que una persona pierde el control de su centro de gravedad, y el intento de recuperar el equilibrio resulta insuficiente [1]. Aproximadamente el 25% de las personas mayores experimenta al menos una caída cada año [2], cifra que aumenta a dos caídas anuales en individuos mayores de 70 años [3]. Por ello, el riesgo de caídas se ha convertido en un desafío importante para la salud pública, siendo una de las principales causas de lesiones graves en adultos mayores y la tercera causa de muerte por lesiones accidentales [4], [5], [6].

Una de las pruebas más comúnmente empleadas por el personal clínico para evaluar movilidad y el riesgo de caídas es el Timed Up and Go (TUG), la cual permite medir el equilibrio dinámico y la movilidad funcional [7], [8]. Sin embargo, su enfoque basado en el tiempo total de ejecución presenta limitaciones, ya que no considera aspectos cualitativos del movimiento, como la estabilidad en los giros o la coordinación al levantarse. Además, la evaluación manual del test puede verse afectada por la variabilidad entre evaluadores, reduciendo su fiabilidad clínica [9].

Estudios recientes utilizando sensores inerciales (IMU) han mostrado que segmentar el TUG en fases individuales (levantarse, caminar, girar, y sentarse) permite identificar con precisión las dificultades que enfrenta el sujeto en cada fase del movimiento [10]. Esto proporciona información crítica que puede pasar desapercibida en una evaluación clínica convencional. En enfoques previos, la segmentación del TUG en subtareas se ha abordado principalmente a través de algoritmos basados en reglas (Rule-based algorithms), los cuales implementan técnicas de procesamiento digital de señales, y más recientemente, se han comenzado a utilizar técnicas de Machine Learning. Esta situación evidencia la necesidad de investigar y evaluar de manera rigurosa el desempeño de distintos algoritmos de segmentación bajo diversas condiciones, con el fin de determinar su precisión, robustez y aplicabilidad clínica. Dicho análisis resulta fundamental para fortalecer la capacidad de los profesionales de la salud de objetivar la evaluación funcional e integrar estas herramientas, junto con unidades de medición inercial, en la evaluación del riesgo de caídas y otras alteraciones del movimiento [11].

1.2. Hipótesis

La segmentación automática del test Timed Up and Go (TUG) mediante algoritmos basados en datos adquiridos de una unidad de medición inercial (IMU) permite identificar diferencias significativas en los parámetros temporales y cinemáticos de las fases del TUG entre personas sanas y aquellas con disfunción.

1.2.1 Objetivo General

Desarrollar y validar un algoritmo de segmentación automática del test Timed Up and Go utilizando datos provenientes de una unidad de medición inercial (IMU) para identificar diferencias significativas en las subetapas del TUG entre personas sanas y aquellas con disfunción, con el fin de mejorar la precisión en la detección de alteraciones en el equilibrio y la movilidad funcional.

1.2.2 Objetivos Específicos

- Analizar críticamente metodologías existentes para la segmentación del test Timed Up and Go (TUG) basadas en datos de sensores inerciales, con el propósito de valorar su precisión y fiabilidad.
- Desarrollar un nuevo algoritmo de segmentación para el test TUG y evaluar su desempeño en datos obtenidos de personas, tanto sanas como con disfunción.
- Evaluar el desempeño del algoritmo de segmentación automática del test TUG, mediante la comparación con la segmentación obtenida a través de un sistema óptico.
- Identificar y caracterizar patrones de normalidad en cada etapa del test TUG utilizando algoritmos de segmentación, con el fin de detectar desviaciones en las señales que puedan indicar anomalías en la movilidad.

1.3. Alcances

- i. El desarrollo del modelo utilizará técnicas de Deep Learning para la segmentación automática de las subetapas del test Timed Up and Go (TUG).
- ii. Las entradas del algoritmo serán: i) los datos brutos de la IMU (acelerometría y velocidad angular), y ii) los ángulos de navegación (calculados y proporcionados por la IMU a partir de cuaterniones).
- iii. El algoritmo está diseñado exclusivamente para el test Timed Up and Go (TUG), sin contemplar su aplicación en otras pruebas de movilidad funcional.

1.4. Limitaciones

- i. En cuanto a las limitaciones, el algoritmo diseñado estará inicialmente optimizado para una unidad de medición inercial en específico, por lo que su aplicabilidad podría estar limitada a otros tipos de sensores inerciales, requiriendo ajustes o calibraciones adicionales.
- ii. Asimismo, otra limitación está relacionada con la heterogeneidad presente en el grupo de participantes con alteraciones de la marcha. Las patologías incluidas muestran manifestaciones biomecánicas diversas, lo que introduce una alta variabilidad inter-sujeto y puede afectar la consistencia de la segmentación en ciertos casos. En este contexto, los rangos de referencia obtenidos para este grupo deben interpretarse como descriptores generales de patrones de “marcha no normativa”, sin pretensión de diferenciar entre diagnósticos específicos ni de establecer valores clínicos referenciales.

Capítulo 2. Marco Teórico

2.1. Timed Up and Go

El Timed Up and Go (TUG) es una prueba funcional ampliamente utilizada en el ámbito clínico y de investigación para evaluar la movilidad, el equilibrio y el riesgo de caídas en personas de diferentes edades y condiciones de salud. Introducida por Podsiadlo y Richardson en 1991 como una versión modificada de la prueba "Get Up and Go" diseñada por Mathias et al. en 1986, el TUG se caracteriza por ser una herramienta simple, rápida y no invasiva, adecuada para evaluar poblaciones geriátricas y personas con condiciones neurológicas [12] [13].

La prueba consiste en medir el tiempo que tarda un individuo en realizar una secuencia de acciones específicas: levantarse de una silla, caminar tres metros hacia adelante, girar 180 grados, regresar al punto de partida y sentarse nuevamente en la silla. Este tiempo se utiliza como indicador del nivel de movilidad funcional del individuo [8].

En Chile, esta prueba forma parte del Examen de Medicina Preventiva del Adulto Mayor (EMPAM), en el cual un tiempo menor o igual a 10 segundos se considera normal, entre 11 y 20 segundos indica un riesgo leve de caída, y valores superiores a 20 segundos corresponden a un alto riesgo de caída [14]. Además, estudios realizados en el país sugieren nuevos tiempos de corte, correspondientes a un tiempo promedio de $8,9 \pm 3,6$ segundos en adultos mayores de entre 60 y 89 años, destacando diferencias según el nivel de funcionalidad: un promedio de $7,9 \pm 2,3$ segundos en personas independientes y $11,7 \pm 5,3$ segundos en aquellas en riesgo de dependencia [17]. Generalmente, un tiempo superior a 12-14 segundos se asocia con un mayor riesgo de caídas, especialmente en adultos mayores o en personas con enfermedades como Parkinson, esclerosis múltiple o después de un accidente cerebrovascular [15]. Por esta razón, el TUG es considerado un estándar en la evaluación del riesgo de caídas y la movilidad funcional en estas poblaciones.

Asimismo, diversos estudios han demostrado una excelente confiabilidad intra- e interevaluador del TUG, con coeficientes de correlación intraclase (ICC) superiores a 0.95, y un valor predictivo adecuado para la detección de caídas tanto en adultos mayores como en pacientes post-ACV [16].

Tabla I Tiempos TUG Riesgo de caídas en población chilena

Riesgo	Tiempo
Normal	≤ 10 seg
Riesgo leve de caída	11 a 20 seg
Alto riesgo de caída	> 20 seg

Además de su uso en la identificación del riesgo de caídas, el TUG se emplea para monitorear el progreso de los pacientes en programas de rehabilitación, permitiendo evaluar mejoras en la movilidad funcional tras intervenciones como la terapia física o cirugías [17]. También es utilizado para comparar grupos de estudio, destacando diferencias significativas en parámetros de movilidad entre personas sanas y aquellas con patologías neurológicas [18].

Recientemente, el análisis del TUG ha evolucionado mediante el uso de sensores inerciales (IMU), los cuales permiten identificar y segmentar etapas específicas del movimiento, como levantarse, caminar, girar y sentarse [19]. Aunque el TUG es ampliamente utilizado por su simplicidad y capacidad para proporcionar información general sobre la movilidad funcional, presenta limitaciones en su aplicación clínica tradicional. Entre estas, se encuentra la dependencia de la medición manual del tiempo, que puede introducir errores interevaluadores y limitar la sensibilidad para detectar sutiles alteraciones en el patrón de movimiento [20]. Además, el TUG convencional no proporciona información detallada sobre las fases específicas del movimiento ni sobre las estrategias biomecánicas empleadas por el paciente, lo que dificulta identificar las causas subyacentes de las limitaciones funcionales. Estas limitaciones justifican la instrumentalización del TUG mediante el uso de IMU, que permiten un análisis más detallado y objetivo [21].

2.2. Unidad de Medición Inercial

Las unidades de medición inercial (IMU) son sistemas portátiles que integran varios sensores para capturar datos cinemáticos en los tres ejes del espacio. En su configuración básica incluyen acelerómetros tri-axiales, que miden las aceleraciones lineales en los ejes anteroposterior, mediolateral y vertical; giroscopios tri-axiales, que registran la velocidad angular de rotación alrededor de cada uno de esos ejes; y, en muchos casos, magnetómetros, que cuantifican las variaciones en el campo magnético terrestre para mejorar la estimación de la orientación espacial [22].

La navegación inercial se fundamenta en la medición interna de la aceleración, según la segunda ley de Newton, es proporcional a la fuerza que actúa sobre un cuerpo rígido; al integrar numéricamente estas aceleraciones, es posible obtener estimaciones de velocidad y cambio de posición sin recurrir a referencias externas como cámaras o emisores de ultrasonido. En paralelo, los giroscopios proporcionan el ritmo de rotación instantáneo, con aplicaciones que van desde la detección de giro en vehículos hasta la estabilización de plataformas y sistemas de guiado inercial [23].

El procesamiento de las señales generadas por la IMU combina algoritmos de filtrado e integración que corrigen sesgos y atenúan ruido, permitiendo calcular parámetros clave como velocidad, posición y orientación (ángulos de pitch, roll y yaw). Estos cálculos resultan especialmente valiosos en contextos clínicos y de rehabilitación, donde el monitoreo detallado de posturas y patrones de movimiento, por ejemplo, la simetría en la marcha o la amplitud articular, ofrece información objetiva sobre el estado funcional del usuario. Frente a otros métodos de captura de movimiento, las IMU presentan un balance óptimo entre precisión, portabilidad y accesibilidad. Al mismo tiempo, reducen la dependencia de infraestructura externa y siendo elementos menos invasivos [24], [25].




Fig. 2-1 Representación del uso de Unidad de Medición Inercial durante la marcha y los ejes de movimiento.

2.3. Timed Up and Go Instrumentado (iTUG)

El Timed Up and Go Instrumentado (iTUG) constituye una extensión del test tradicional Timed Up and Go (TUG), incorporando una unidad de medición inercial (IMU) para capturar, además del tiempo total, parámetros cinemáticos detallados de cada subetapa del movimiento [11], [26]. A diferencia del TUG convencional, en el que solo se registra el tiempo total de ejecución, el iTUG sitúa una IMU en la región lumbar, cerca del centro de masa corporal, con el fin de obtener señales de aceleración y velocidad angular en los tres ejes durante toda la prueba. Mediante algoritmos de detección de eventos, el iTUG segmenta el recorrido en fases definidas como levantarse (sit-to-stand); inicio de la marcha y desplazamiento; primer giro; retorno de la marcha; y sentarse (stand-to-sit), lo que permite analizar y caracterizar cada una de ellas [20], [21], [26].

La colocación lumbar de la IMU permite capturar fielmente las dinámicas del tronco, reflejo de la movilidad global, y reduce artefactos derivados de movimientos segmentarios [27]. A partir de cada segmento, se extraen métricas como la duración individual, aceleraciones peak, velocidades angulares máximas y ángulos de orientación (roll, pitch, yaw), proporcionando un perfil cinemático completo de la ejecución [28].

Este nivel de detalle incrementa la sensibilidad del iTUG para detectar alteraciones sutiles en el patrón de movimiento, como variaciones en el tiempo de apoyo o en la estrategia de giro. Además, la objetividad y reproducibilidad que aportan los datos inerciales facilitan tanto la comparación entre diferentes cohortes de estudio como el seguimiento longitudinal de pacientes en programas de rehabilitación, lo cual permite personalizar las intervenciones clínicas en función de déficits cinemáticos específicos [29].

2.4. Sistema Óptico basados en Marcadores

Un sistema óptico basado en marcadores es una tecnología de captura de movimiento tridimensional (del inglés, motion capture, o motion tracking, también abreviada mocap) en la cual se adhieren pequeños marcadores reflectivos (pasivos) o emisores activos a puntos anatómicos del sujeto; múltiples cámaras infrarrojas, sincronizadas en alta frecuencia, registran la posición de dichos

marcadores en cada cuadro mediante triangulación estereoscópica [30]. A partir de un proceso de calibración inicial del volumen de captura y de etiquetado, el software reconstruye un esqueleto virtual que permite conocer con alta precisión (submilimétrica) las trayectorias y orientaciones de segmentos corporales.

En el contexto de este trabajo se emplea el Sistema OptiTrack®, ampliamente reconocido en el análisis de movimiento por su alta precisión, flexibilidad y capacidad de adaptación a múltiples aplicaciones [31]. Este sistema utiliza tecnología óptica avanzada para registrar movimientos tridimensionales en tiempo real, combinando cámaras de alta resolución, software especializado y marcadores reflectantes. Posee precisión submilimétrica y capacidad para capturar movimientos complejos, por lo que lo convierten en una herramienta esencial en campos como la biomecánica, la rehabilitación, los deportes, la animación digital y la realidad virtual [32] [33].

Una de las características más destacadas del Sistema OptiTrack® es su capacidad para generar un esqueleto virtual a partir de los datos obtenidos por sus cámaras. Este esqueleto, se construye a partir de la posición de marcadores estratégicamente colocados en puntos clave del cuerpo del sujeto. Mediante su software integrado (Motive), el sistema procesa estas posiciones en tiempo real y crea una representación precisa del movimiento humano, permitiendo observar y analizar dinámicamente la cinemática del sujeto [34].

2.5. Redes Neuronales Profundas (Deep Learning)

El Aprendizaje Profundo o Deep Learning (DL) es una subdisciplina del Machine Learning basada en Redes Neuronales Artificiales (RNA) con múltiples capas ocultas, lo que se conoce como arquitecturas profundas. Estas permiten aprender representaciones de datos con distintos niveles de abstracción. A diferencia de los algoritmos de aprendizaje automático tradicionales, que dependen en gran medida de la extracción manual de características (feature engineering), los modelos de DL pueden aprender jerarquías de características de forma automática y directa a partir de los datos crudos [35].

La arquitectura de una red neuronal profunda consta de una capa de entrada, múltiples capas ocultas y una capa de salida. Cada capa contiene unidades de procesamiento o "neuronas" que aplican

una transformación no lineal a sus entradas. Al apilar estas capas, el modelo puede aprender características progresivamente más complejas y abstractas: las primeras capas detectan rasgos simples, mientras que las más profundas combinan estos para reconocer patrones de alto nivel [36].

Esta capacidad de aprendizaje automático de representaciones ha demostrado ser especialmente efectiva en el análisis de datos complejos y de alta dimensionalidad, como las series temporales provenientes de sensores inerciales. En el contexto del análisis del movimiento humano, donde los patrones son sutiles y variables, el DL permite descubrir relaciones temporales y características discriminativas que serían difíciles de definir y extraer mediante métodos convencionales, lo que justifica su elección para la segmentación automática del test Timed Up and Go (TUG) [37], [38].




Fig. 2-2 Representación de Redes Neuronales en Deep Learning [36].

2.5.1 Redes Neuronales Recurrentes (RNN)

Las Redes Neuronales Recurrentes (RNN) son una clase de redes neuronales diseñadas específicamente para procesar datos secuenciales o series temporales. Su característica fundamental son las conexiones recurrentes, que les permiten mantener una memoria o "estado oculto" que se actualiza en cada paso de tiempo. Este estado interno actúa como un resumen de la información procesada en los pasos anteriores [39].

En una RNN, la salida en un tiempo t depende no solo de la entrada en ese instante, sino también del estado oculto del paso anterior. Esta arquitectura les permite capturar dependencias temporales en los datos. Sin embargo, las RNN simples sufren del problema del gradiente desvanecido o explosivo [40]. Al propagar el gradiente a través de muchos pasos de tiempo durante el entrenamiento, este puede disminuir exponencialmente hasta volverse insignificante (desvanecimiento) o crecer sin control (explosión), lo que dificulta el aprendizaje de dependencias a largo plazo [41]. Esta limitación las hace poco adecuadas para secuencias compuestas por etapas, como las señales completas de un test TUG, donde eventos al inicio de la prueba pueden influir en fases posteriores.

2.5.2 Long Short-Term Memory (LSTM)

Las redes de Memoria a Corto y Largo Plazo (LSTM) son una variante avanzada de las RNN, diseñadas para superar la limitación de las dependencias a largo plazo [42]. Su arquitectura introduce una unidad de memoria más compleja, denominada celda, cuyo flujo de información es regulado por un mecanismo de compuertas. Este sistema se compone de:

- Una compuerta de olvido, que decide qué información descartar del estado de la celda.
- Una compuerta de entrada, que gestiona la incorporación de nuevos datos.
- Una compuerta de salida, que modula la información del estado de la celda que se utilizará para la predicción [42].

Esta estructura de control selectivo permite a la red retener información relevante durante períodos extensos, una capacidad crucial para el análisis de secuencias biomecánicas complejas.

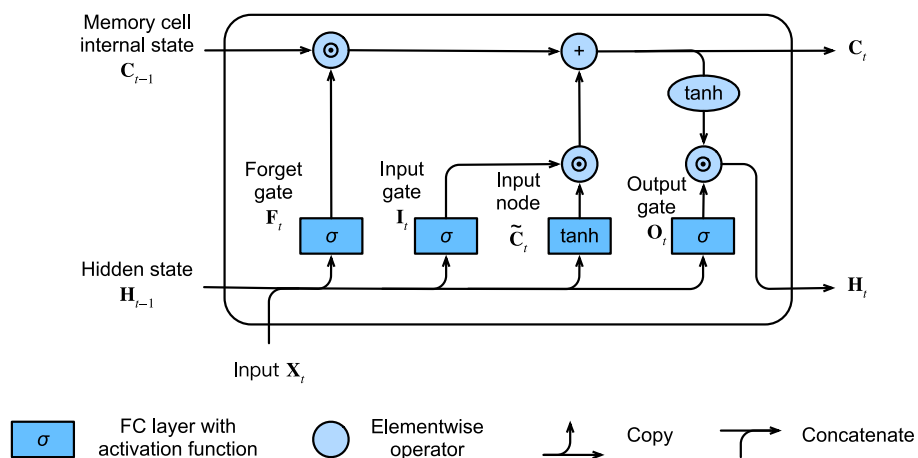


Fig. 2-3 Diagrama de funcionamiento de un modelo LSTM [39].

2.5.3 Redes Bidireccionales Long Short-Term Memory (BiLSTM)

Una Red LSTM Bidireccional (BiLSTM) extiende la arquitectura LSTM para procesar la información secuencial en ambas direcciones temporales [43]. Mientras que una LSTM estándar analiza la secuencia cronológicamente, una BiLSTM emplea dos capas LSTM paralelas: una procesa los datos en el sentido directo (del pasado al futuro) y la otra en el sentido inverso (del futuro al pasado). En cada punto temporal, las salidas de ambas capas se combinan, dotando al modelo de un conocimiento contextual completo [44].

Para tareas de segmentación como la del test TUG, esta capacidad es fundamental, ya que el conocimiento de un evento futuro (p. ej., el inicio de un giro) permite una delimitación más precisa del final del evento actual (p. ej., la caminata ida), lo que resulta en una clasificación más robusta y precisa.

2.6. Biomarcadores Digitales

En los últimos años, la digitalización del entorno clínico y del ámbito cotidiano ha ampliado el espectro de fuentes y métodos utilizados para medir biomarcadores, dando origen a una nueva categoría denominada biomarcadores digitales (digital biomarkers). Según la definición adoptada por la FDA, un biomarcador digital corresponde a una característica o conjunto de características obtenidas a través de tecnologías digitales de salud, que se miden como indicadores de procesos biológicos normales, patológicos o de respuestas ante una intervención [45].

Estas tecnologías pueden incluir dispositivos portátiles, sensores inerciales, teléfonos inteligentes, relojes inteligentes o plataformas digitales capaces de recopilar información de manera continua y no invasiva en el entorno cotidiano del individuo [45].

A diferencia de los biomarcadores tradicionales, los biomarcadores digitales presentan ventajas como su alta resolución temporal, su objetividad (al no depender de la variabilidad Inter-observador) y su validez ecológica, al permitir la medición del comportamiento o la función del paciente en contextos naturales fuera del ambiente clínico.

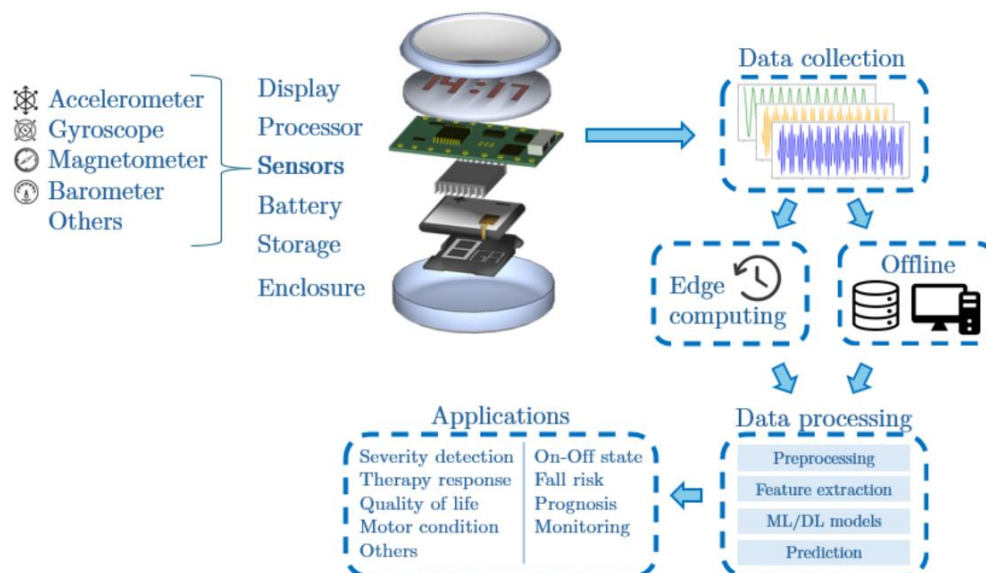


Fig. 2-4 Marco integral para los sistemas portátiles de monitorización de la salud [46].

En este contexto, los biomarcadores digitales derivados de sensores inerciales y sistemas de captura de movimiento han adquirido especial relevancia en el estudio de la movilidad funcional. Estos permiten cuantificar de manera precisa parámetros relacionados con la marcha, el equilibrio y la coordinación motora, facilitando el análisis objetivo del desempeño funcional de pacientes en pruebas estandarizadas como el Timed Up and Go (iTUG). Dichos biomarcadores ofrecen un potencial considerable para detectar alteraciones sutiles en la movilidad asociadas a envejecimiento, patologías neuromusculares o trastornos del equilibrio, aportando información cuantitativa de alto valor clínico para la rehabilitación y el seguimiento funcional [46].

2.7. Biomarcadores de Movilidad Funcional Derivados del iTUG

2.7.1 Biomarcadores Temporo-espaciales

Incluyen la duración total y parcial de cada subetapa (levantarse, marcha ida, giro, marcha retorno y sentarse), los tiempos de transición y la cadencia. Estos indicadores permiten identificar retrasos o asimetrías temporales que pueden evidenciar déficits motores o problemas de coordinación [47].

2.7.2 Biomarcadores Cinemáticos

Los biomarcadores cinemáticos derivan de las mediciones de aceleración y velocidad angular obtenidas mediante la IMU durante el iTUG, permitiendo caracterizar la dinámica y eficiencia del movimiento [37]. La velocidad angular, especialmente durante las fases de giro y marcha, refleja la coordinación y el control postural del sujeto [48]. Las aceleraciones máximas en los ejes anteroposterior, mediolateral y vertical permiten evaluar la suavidad del movimiento e identificar hesitaciones o brusquedades [48]. Finalmente, los ángulos de orientación (pitch, roll y yaw) describen la postura y las estrategias de compensación empleadas durante las distintas fases del TUG [49].

Capítulo 3. Estado del Arte: Instrumentación del Test Timed Up and Go

3.1. Algoritmos para la Segmentación Automática del TUG

La automatización de la segmentación del test Timed Up and Go (TUG) mediante Unidades de Medición Inercial (IMU) ha experimentado una notable evolución tecnológica. El campo ha transitado desde algoritmos iniciales fundamentados en reglas heurísticas simples hacia la adopción de paradigmas complejos de aprendizaje automático. Este capítulo realiza un análisis crítico de dichos enfoques, evaluando su contribución al avance de la precisión métrica y, fundamentalmente, de la utilidad clínica de la segmentación automatizada.

3.1.1 Algoritmos de Segmentación Basados en Reglas

Las investigaciones de [47] se enfocaron en la transición cinemáticamente crítica entre el giro y sentarse, un marcador pronóstico del riesgo de caídas en la gerontología. El estudio cataloga dos estrategias motoras distintivas: una transición secuencial, donde el giro se completa antes de iniciar el descenso, y una transición superpuesta, caracterizada por la concomitancia de ambos movimientos. Al emplear regresión lineal sobre datos de sensores inerciales posicionados en el segmento lumbar, los autores establecieron correlaciones significativas entre la duración de estas transiciones y el deterioro motor-cognitivo. Este hallazgo sugiere que una transición más lenta y deliberada es un indicador de un control motor deficiente. No obstante, la aplicabilidad clínica de este método basado en reglas se ve comprometida por la inherente variabilidad inter-sujeto, que impide la definición de un patrón universalmente predictivo.

La validación de la métrica instrumental fue abordada por Beyea et al. [9], quienes realizaron una comparativa entre unidades de medición inercial (IMU) y un sistema de captura de movimiento óptico (Gold standard). Si bien se logró una alta concordancia ($r > 0.9$) en la medición de la fase de deambulación y la duración total del TUG, la correlación fue sustancialmente menor ($r < 0.4$) para las transiciones que involucran la silla y los giros. Esta discrepancia subraya una limitación fundamental de los algoritmos: su escasa precisión para capturar movimientos rotacionales complejos, los cuales son esenciales para una evaluación geriátrica integral.

Innovando en el contexto de la prueba, Yang et al. [50] desarrollaron el sistema SITUG, que incorpora plantillas inteligentes instrumentadas con IMUs. Este sistema introduce la variable

ecológica al permitir la evaluación en entornos con obstáculos o desniveles, superando así la artificialidad del laboratorio. Aunque reportó una precisión global del 92.23% en la segmentación de cinco fases principales, su desempeño se degradó notablemente durante la fase de giro, atribuido a la alta variabilidad biomecánica entre individuos. Este hallazgo es coherente con los resultados de Ansai et al. [18], quienes identificaron el giro como el discriminante principal entre adultos mayores frágiles, prefrágiles y robustos, pero también destacaron la insensibilidad de los métodos actuales para detectar el deterioro incipiente en la prefragilidad.

En el plano de los algoritmos basados en reglas, la tesis de Gómez [51] implementó una solución basada en el procesamiento digital de señales, utilizando los ángulos de inclinación (Pitch) y rotación (Yaw) para identificar eventos clave. Si bien la técnica demostró una alta correlación con la observación visual, su arquitectura presenta dos limitaciones estructurales críticas: (1) su naturaleza secuencial, donde un error en una etapa se propaga a las siguientes, y (2) la utilización de umbrales fijos, que carecen de robustez ante patrones de marcha atípicos o patológicos. Una dirección prometedora para superar estas barreras sería la implementación de detectores de eventos independientes con umbrales adaptativos, confiriendo al sistema mayor precisión.

La problemática de la segmentación de giros trasciende al test TUG. Romijnders et al. [52] validaron la detección de eventos de la marcha (contacto inicial y final del pie) con IMUs en la pierna, logrando una precisión casi perfecta en la marcha rectilínea. Sin embargo, durante los giros, la sensibilidad del algoritmo decayó al 85%, generando un número significativo de falsos positivos y negativos. Este resultado consolida la noción de que las transiciones rotacionales constituyen una dificultad en la segmentación basada en reglas, independientemente del protocolo de evaluación utilizado.

3.1.2 Métodos de Aprendizaje Automático y Deep Learning

El reconocimiento de las limitaciones de los métodos basados en reglas ha catalizado la adopción de modelos de aprendizaje automático, los cuales ofrecen una capacidad superior para manejar la variabilidad y complejidad de las señales biomecánicas.

En el trabajo realizado por [53] realizaron una comparativa sistemática de cuatro métodos de segmentación en pacientes con Parkinson. Mientras que en tareas simples todos los algoritmos

mostraron un rendimiento similar, en secuencias complejas como el TUG, los modelos ocultos de Markov jerárquicos (hHMM) demostraron ser superiores, alcanzando un 96% de precisión. Este paradigma probabilístico permite diferenciar eficazmente entre la locomoción y movimientos parásitos, una ventaja crucial en poblaciones con patrones motores patológicos. La contrapartida de esta mayor precisión es la complejidad computacional y el costo asociado a su implementación. Esta búsqueda de robustez se extiende a otros contextos clínicos. Hsieh et al. [54], en el ámbito de la artroplastia de rodilla, desarrollaron un clasificador multi-etapa que combina aprendizaje automático con reglas basadas en conocimiento, logrando una precisión del 92%. Para abordar la variabilidad postoperatoria, incorporaron una ventana deslizante que mejora la identificación de eventos ambiguos, como los giros, donde es común la superposición de patrones cinemáticos.

Paralelamente, han emergido enfoques sensoriales alternativos. En [38] abandonaron el uso de IMUs a favor de cámaras RGB-D y una red neuronal convolucional-temporal (TCN), alcanzando precisiones superiores al 93% incluso en pacientes con accidente cerebrovascular. La elección de utilizar únicamente el punto de la pelvis como feature optimizó radicalmente el procesamiento, permitiendo la inferencia en tiempo real. Sin embargo, la viabilidad clínica de esta solución se ve obstaculizada por la ingente demanda de datos etiquetados para el entrenamiento. Investigadores en [55], exploraron una vía de bajo costo mediante el uso de videografía convencional, demostrando una alta correlación con el gold standard, aunque su precisión sigue siendo vulnerable a factores ambientales y de calibración.

La vanguardia en este campo la representan los modelos de aprendizaje profundo para la predicción de riesgo. Maiora et al. [37] emplearon redes LSTM bidireccionales para predecir el riesgo de caídas a partir de señales crudas de IMU, logrando un AUC de 0.73. Este enfoque end-to-end evita la necesidad de una segmentación previa explícita, extrayendo características de alto nivel directamente de la serie temporal. El principal escollo, común a todas estas arquitecturas profundas, es su dependencia de grandes volúmenes de datos balanceados, un recurso escaso en entornos clínicos reales. Finalmente, el estudio de [56] con amputados de miembros inferiores utilizando un algoritmo de Random Forest, corroboró la utilidad de estos métodos en poblaciones con patrones de movilidad severamente alterados. Si bien se alcanzó una alta especificidad (>95%), la sensibilidad se resintió notablemente durante los giros, reafirmando que esta transición sigue siendo el desafío pendiente para los algoritmos de segmentación.

3.1.3 Discusión

La revisión bibliográfica realizada delinea un campo en maduración, donde la evolución desde los algoritmos basados en reglas hacia los modelos de aprendizaje automático y profundo ha sido impulsada por la necesidad de capturar la complejidad biomecánica humana, particularmente en las transiciones no lineales como los giros.

Los métodos tradicionales [48-53] proveen una base computacionalmente eficiente e interpretable, pero su rigidez (umbrales fijos, detección secuencial) los hace frágiles ante la heterogeneidad de los pacientes. Sistemas más modernos como SITUG [50] enriquecen el contexto ecológico, pero no resuelven el problema central de la variabilidad del giro, un hallazgo consistentemente reportado [51], [53]. Los paradigmas de aprendizaje automático [55], [56] y Deep Learning [57] representan un salto cualitativo al manejar esta variabilidad mediante modelos probabilísticos y de representación automática de características. No obstante, este progreso tiene un costo: una mayor opacidad ("caja negra"), requerimientos computacionales elevados y, sobre todo, una dependencia crítica de grandes conjuntos de datos anotados.

En conclusión, se identifica una clara disyuntiva entre la precisión y la practicidad. El futuro de la segmentación del TUG parece dirigirse hacia modelos híbridos que combinen la eficiencia de las reglas heurísticas con la potencia de generalización del aprendizaje automático, o hacia arquitecturas de Deep Learning más eficientes, capaces de operar robustamente en las condiciones de restricción de datos típicas de los entornos clínicos reales. Si bien el enfoque de esta tesis comparte con estos modelos la necesidad de un conjunto de datos etiquetado para su entrenamiento, busca dar un paso adelante en términos de rendimiento y robustez. Para ello, se propone una arquitectura de red neuronal Long Short-Term Memory Bidireccional (BiLSTM). La diferencia fundamental y la principal contribución de este trabajo radica en el carácter bidireccional del modelo. A diferencia de un LSTM estándar que solo procesa información del pasado, el BiLSTM utiliza el contexto temporal completo, tanto pasado como futuro, para cada decisión de segmentación. De esta manera, se busca desarrollar un modelo que no solo aumente la precisión, sino que también ofrezca una solución robusta y generalizable para la evaluación clínica automatizada y objetiva del TUG.

3.2. Caracterización de Señales inerciales y Biomarcadores Cinemáticos del iTUG

La utilidad clínica final de los algoritmos de segmentación analizados en las secciones previas se materializa en la capacidad de extraer biomarcadores cinemáticos cuantitativos. La instrumentalización del TUG permite, efectivamente, trascender la simple medición temporal para adentrarse en el análisis exhaustivo de la calidad del movimiento. Este análisis se sustenta en la caracterización de las señales provenientes de la unidad de medición inercial (IMU), que la literatura ha dedicado esfuerzos en definir para establecer parámetros objetivos de movilidad funcional.

3.2.1 Parámetros de Acelerometría

El análisis de la acelerometría es clave para identificar transiciones y fases de la prueba. Durante la fase de Sit-to-Stand (STS), se observan peaks de aceleración que reflejan el impulso generado para levantarse. Estudios en mujeres con obesidad han reportado peaks de aceleración vertical de hasta 1.25 g, en contraste con los 1.48 g observados en grupos de control de peso normal [57]. Es importante destacar que el sensor fue ubicado a la altura de L2, y de acuerdo a [58], el cual exploró valores de la IMU durante el sit to stand, los valores de acelerometría dados de por la IMU pueden variar de acuerdo según la ubicación de esta.

En adultos mayores, [59], [60] encontraron que los valores RMS de la aceleración (vertical, anteroposterior y medio-lateral) durante las fases de caminata y las transferencias del TUG eran generalmente más bajos en individuos con alto riesgo de caídas (HFR) en comparación con aquellos con bajo riesgo (LFR). Por ejemplo, el RMS de la aceleración vertical en la primera caminata fue de $0.28 \pm 0.091 \text{ m/s}^2$ para LFR y $0.15 \pm 0.055 \text{ m/s}^2$ para HFR [59]. Los "fallers" (individuos con historial de caídas) también exhibieron un menor rango y jerk, así como una menor desviación estándar de aceleración ($0.17 \pm 0.02 \text{ g}$ para fallers vs. $0.21 \pm 0.02 \text{ g}$ para controles) en comparación con los "non-fallers" [61].

En pacientes post-accidente cerebrovascular (ACV) [48], [62] observaron reducciones significativas en las aceleraciones máximas, mínimas y RMS en comparación con controles sanos. Durante movimientos de giro (Walk–Turn–Walk), la aceleración vertical máxima (Maximum αV) fue de $3.60 \pm 0.85 \text{ m/s}^2$ para el grupo de alto riesgo de ACV, $3.70 \pm 1.00 \text{ m/s}^2$ para el de bajo riesgo, y

$6.67 \pm 3.29 \text{ m/s}^2$ para los controles. Los valores de RMS de α_V , α_{ML} y α_{AP} se correlacionaron moderadamente con la Escala de Equilibrio de Berg (BBS) [48]. Los algoritmos de recuperación de estados articulares también han reportado residuales del acelerómetro de aproximadamente 0.05 (0.19) g para algoritmos basados únicamente en IMUs [63].

3.2.2 Velocidad Angular

La velocidad angular, medida por giroscopios, cuantifica la tasa de rotación de los segmentos corporales, siendo fundamental para el análisis de movimientos dinámicos como giros y transferencias.

Para la enfermedad de Parkinson, [64] mostraron que la velocidad peak de giro fue menor en el grupo FoG+ (Freezing of Gait) alcanzando valores de 104.51 (19.82) °/s para giros de 180° y 92.73 (26.82) °/s para giros de 360° en comparación con el grupo sin FoG (131.48 (31.11) °/s y 133.22 (39.21) °/s, respectivamente), lo que sugiere estrategias de giro más lentas y menos eficientes [64]. Nuevamente en [65] se observaron en niños con TBI que las tareas cognitivo-motoras resultaron en valores significativamente más bajos de la velocidad angular media y peak de giro durante los giros en el TUG en comparación con los controles TD. Por ejemplo, la velocidad angular peak de flexión durante la subtarea de ponerse de pie a sentarse también fue menor en el grupo TBI.

En pacientes post-ACV, la velocidad angular también presenta una disminución notable. En [48], durante la fase de giro (Walk–Turn–Walk), se reportaron valores de velocidad angular máxima en el eje vertical ($\text{Max } \omega_{yaw}$) de 65.60 (15.56) deg/s en el grupo de alto riesgo, 103.38 (26.93) deg/s en el de bajo riesgo y 174.29 (26.47) deg/s en los controles. El RMS de ω_{yaw} mostró una tendencia similar, con 25.50 (5.02) deg/s, 48.00 (12.15) deg/s y 83.65 (14.16) deg/s en los mismos grupos, respectivamente. En adultos jóvenes sanos, la velocidad máxima de rotación del tronco durante los giros del iTUG ha sido reportada en $67.0 \pm 22.8 \text{ deg/s}$ [66]. Asimismo, Stuart et al. [67] observaron en pacientes con traumatismo craneoencefálico leve (mTBI) que tanto la velocidad pico como la velocidad promedio de giro en condiciones de vida libre fueron significativamente menores que en los controles. Por otra parte, en [62], se compararon sobrevivientes de ACV (SS) con individuos sanos (HI) durante giros de 360°, evidenciando que los HI exhibieron mayores velocidades angulares en flexo-extensión en los cuatro segmentos corporales evaluados. Finalmente, en niños con parálisis

cerebral, los autores de [68] identificaron correlaciones moderadamente positivas y significativas entre la velocidad angular mínima y las puntuaciones de frecuencia y calidad del PMAL-R ($r = 0.416$, $p = 0.008$; $r = 0.418$, $p = 0.007$, respectivamente).

3.2.3 Ángulos de Navegación y Cinemática Articular

Los ángulos de navegación y la cinemática articular, obtenidos a menudo mediante datos de IMU y MOCAP, proporcionan información sobre la orientación y los rangos de movimiento (ROM) de los segmentos corporales y las articulaciones, lo que es esencial para evaluar el control postural y la coordinación.

En el trabajo de [65] se encontró que en niños con TBI, el ángulo máximo de flexión/extensión del torso (Max Torso Flx/Ext Angle) durante la fase de Sit-to-stand fue de 38.11 (12.04) deg para el grupo TBI y 49.15 (7.93) deg para el grupo TD, lo que sugiere una reducción del movimiento del torso en la población con TBI [65]. En niños con mochila, se observó que la extensión pico y el rango de extensión del torso cambiaron, siendo la extensión pico en la fase de levantarse de 21.64 ± 9.67 grados sin mochila y 21.79 ± 8.46 grados con mochila [69].

En el trabajo de [66] Kowal et al. (2025) reportaron que en adultos jóvenes sanos, el rango de movimiento de flexión del tronco durante la fase de sentarse del iTUG fue de 51.7 ± 20.1 grados, y el rango de movimiento de rotación del tronco fue de 163.5 ± 70.4 grados. En [70] validaron el uso de IMU para medir la cinemática de flexión de rodilla durante actividades de la vida diaria en pacientes con artroplastia total de rodilla. Además, en [71] mostraron que el iTUG puede distinguir individuos con deafferentación vestibular unilateral, con una mejora en la capacidad de giro después de la fisioterapia vestibular [71].

En conclusión, la integración de parámetros cinemáticos (aceleración, velocidad angular, orientación) mediante sensores inerciales ha enriquecido profundamente el análisis del movimiento humano. Estas mediciones van más allá del tiempo total de ejecución, proporcionando datos objetivos que exponen la calidad del movimiento, las compensaciones motoras y los déficits sutiles que las evaluaciones tradicionales no logran captar. La continua validación de estas tecnologías en diversas poblaciones impulsa avances hacia el diagnóstico precoz, la rehabilitación personalizada y intervenciones clínicas más eficaces.

Capítulo 4. Metodología

Para cumplir con los objetivos propuestos en este trabajo, se implementó la siguiente metodología:

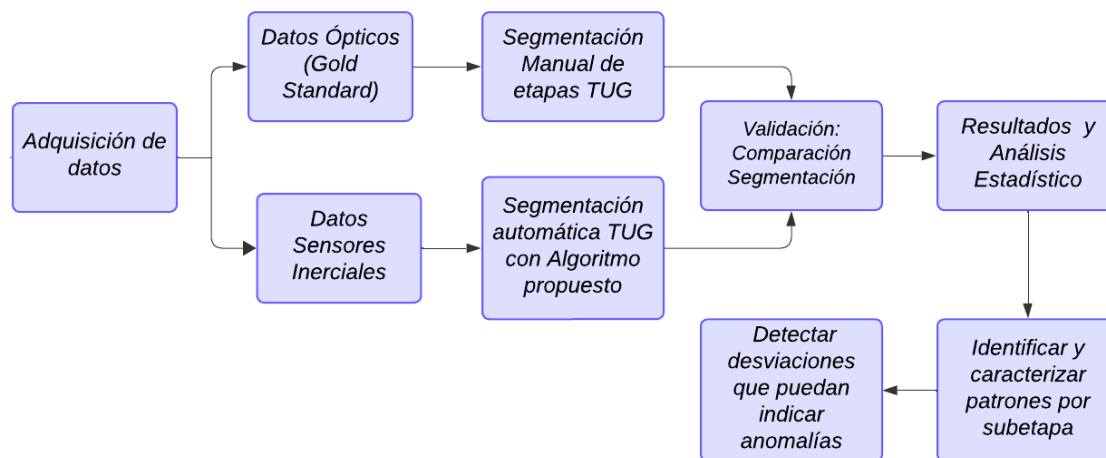


Fig. 4-1 Diagrama de Flujo Metodología.

4.1. Participantes

El estudio consideró una muestra de 105 sujetos, con el fin de evaluar la aplicabilidad del modelo en distintos rangos etarios, condiciones funcionales. La muestra se compone de una combinación de participantes sanos y aquellos con patologías neurológicas y/o musculoesqueléticas, con el objetivo de capturar la variabilidad en los patrones de marcha en un contexto clínico.

La muestra total se dividió en dos grupos principales: Participantes Sanos (Sin diagnósticos de patologías asociadas a la marcha) y Participantes con Alteraciones asociadas a la marcha (Grupo Clínico). Esta clasificación permite un análisis comparativo del rendimiento del modelo en ambos contextos. Sus características demográficas y antropométricas de la totalidad del grupo se presentan en la Tabla II.

4.1.1 Criterios de Inclusión

- Adultos mayores de 18 años con o sin diagnóstico de alguna enfermedad.
- Personas de ambos sexos.
- Personas con capacidad de realizar marcha con o sin ayuda técnica.

4.1.2 Criterios de Exclusión

- Adultos que no puedan seguir órdenes simples.
- Con intolerancia al esfuerzo físico, con diagnóstico de patologías descompensadas.
- Con intervenciones quirúrgicas de miembros inferiores o tronco en los últimos 6 meses.
- Con dolor osteomuscular de miembros inferiores mayor a 5 en la Escala Numérica Análoga (ENA).
- Puntaje menor a 16 en el Mini mental Test Abreviado [72].

4.1.3 Participantes Sanos

Este grupo, compuesto por 79 sujetos, fue incluido con el propósito de establecer un patrón de marcha de referencia o 'normalidad' en función de la edad, a partir del cual se pudieran comparar los patrones de marcha patológicos. La inclusión de un grupo asintomático es fundamental para validar la capacidad del modelo de discriminar entre una marcha típica y una alterada. Para analizar la variabilidad en función de la edad, los participantes se distribuyeron en tres subgrupos etarios diferenciados (Véase Tabla IX):

- Adultos Jóvenes: Participantes de 18 a 40 años (N = 25).
- Adultos de Mediana Edad: Participantes de 41 a 64 años (N = 30).
- Adultos Mayores: Participantes de 65 años o más (N = 24).

4.1.4 Participantes con alteraciones de la marcha

Este grupo está formado por 26 sujetos con antecedentes de patologías neurológicas y/o musculoesqueléticas que afectan la marcha. La inclusión de esta muestra permite evaluar el desempeño del modelo de segmentación en condiciones que modifican el patrón de marcha. Los diagnósticos específicos dentro de este grupo incluyen (véase Tabla II):

4.1.5 Comité de Ética

Este proyecto fue evaluado y aprobado por el Comité de Ética, Bioética y Bioseguridad de la Vicerrectoría de Investigación y Desarrollo de la Universidad de Concepción, cumpliendo con los

estándares éticos y de bioseguridad requeridos para investigaciones con seres humanos. El código de aprobación otorgado por el comité es CEBS 687-2020.

Tabla II Características demográficas de participantes con alteraciones de la marcha.

Sexo	Edad	Peso (kg)	Estatura (m)	Diagnósticos
F	74	52	1.43	Osteoartritis espinal.
F	70	59	1.24	Vértigo; DM tipo 2.
M	80	74	1.68	Enfermedad de Parkinson.
M	62	94.7	1.89	Espolón calcáneo.
F	58	68.1	1.52	Vértigo; Hipercolesterolemia.
F	72	55.5	1.59	Vértigo; Migraña.
F	64	64.9	1.65	Accidente cerebrovascular isquémico; Dislipidemia.
F	71	42	1.43	Enfermedad de Parkinson.
F	76	55.8	1.39	Enfermedad de Parkinson; Hipertensión; Prediabetes.
M	70	81	1.45	Enfermedad de Parkinson; Hipotiroidismo.
M	75	84	1.72	Enfermedad de Parkinson; Cataratas.
F	79	74.6	1.57	Enfermedad de Parkinson; Arritmia cardíaca; Hipotiroidismo
F	62	72	1.54	Enfermedad de Parkinson; Hipertensión; Hipotiroidismo
M	76	86.7	1.65	Enfermedad de Parkinson; Cáncer de próstata
F	68	62.5	1.51	Enfermedad de Parkinson; Hipotiroidismo
F	77	68	1.48	Enfermedad de Parkinson; DM tipo 2; HTN; Dislipidemia
F	79	70	1.48	Enfermedad de Parkinson
M	61	69.2	1.7	Enfermedad de Parkinson; DM; HTN
F	60	75.4	1.52	Enfermedad de Parkinson
F	79	98.2	1.58	Poliomielitis; Artrosis bilateral de rodilla; Artrosis espinal; Hipotiroidismo; Asma; DM tipo 2; HTN
F	69	71.6	1.53	Enfermedad de Parkinson
F	49	54	1.59	Enfermedad de Parkinson
M	58	76	1.65	Enfermedad de Parkinson
M	26	77.5	1.64	Hemiplejía izquierda (TCE); Diabetes insípida
M	25	68.3	1.82	TCE grave; Lesión axonal difusa; Tetraparesia espástica (predominio del lado izquierdo)
F	22	59.6	1.58	Malformación cerebral; Hemiparesia izquierda; Diplopía

Del grupo con alteraciones de la marcha (n=26), 15 presentaban diagnóstico de Enfermedad de Parkinson (60%), 2 con secuelas de traumatismo craneoencefálico, 1 con accidente cerebrovascular, y 3 con patologías musculoesqueléticas.

4.2. Instrumentación y Protocolo experimental

4.2.1 Instrumentación

Los participantes utilizaron una unidad de medición inercial (IMU), la cual integra un acelerómetro, un giroscopio y un magnetómetro en los tres ejes, para capturar datos de movimiento y orientación. Este dispositivo emplea un procesador interno que combina los datos inerciales y magnéticos mediante un filtro de Kalman extendido, proporcionando la orientación en formato de cuaterniones, lo que elimina problemas como las singularidades presentes en otras representaciones angulares. La orientación se registró con una precisión de un grado y los datos se almacenaron a una frecuencia de 100 Hz. El sistema opera con un microcontrolador eficiente de 32 bits basado en la arquitectura ARM Cortex-M0+, y transmite los datos a través de Bluetooth 3.0, asegurando un alcance de hasta 20 metros sin interrupciones. Además, está alimentado por una batería recargable de 500 mAh, que ofrece una autonomía de 10 horas [49]. Las características técnicas del dispositivo se presentan en la Tabla III.

Tabla III Características Técnicas de la IMU.

Sensor	Rango	Ancho de banda	Resolución	Output Rate
Acelerómetro	±16 G	62.5 Hz	14 bits	100 Hz
Giroscópio	±2000 dps	32 Hz	16 bits	100 Hz
Magnetómetro	±1300 [uT]	10 Hz	13 bits	20 Hz

La IMU se posicionó en la zona lumbar, específicamente en la región L5-S1, debido a que presenta varias ventajas sobre los métodos tradicionales de evaluación. Esta región es clave para la estabilidad postural y el control del equilibrio, lo que la convierte en un punto ideal para capturar datos relevantes sobre el movimiento [44]. Estudios han demostrado que las IMU en la espalda baja permiten monitorear de manera continua la estabilidad del tronco en distintos contextos de movimiento, como tareas de equilibrio y marcha, proporcionando información detallada crucial para ajustar intervenciones y monitorear la recuperación del paciente [73], [74].

Adicionalmente, se empleó la configuración *Conventional Lower (16)* del sistema OptiTrack®, que utiliza 16 marcadores pasivos, como se observa en la Fig. 4-2. Estos marcadores se ubicaron en ambos lados del cuerpo en regiones específicas, incluyendo los maléolos lateral y medial, la espina ilíaca anterior superior, el talón, la rodilla lateral y medial, la espina ilíaca posterior superior,

la cara anterior del muslo, la cara anterior de la tibia y el dedo del pie. Esta disposición permite capturar con precisión el movimiento de las extremidades inferiores, facilitando el análisis de dinámicas articulares y patrones de movimiento [27].




Fig. 4-2 Instrumentación durante la prueba. (a) Unidad de Medición Inercial localizada en región L5-S1 y orientación sensor; (b) Identificación de marcador de sistema Optitrack.

4.2.2 Procedimiento de Adquisición de Datos

Las pruebas del test Timed Up and Go (TUG) se realizaron en el laboratorio de Ingeniería Biomédica de la Universidad de Concepción. Durante estas sesiones, una kinesióloga de la Facultad de Medicina de la misma universidad fue la encargada de proporcionar las instrucciones necesarias para garantizar la correcta ejecución del test. Cada participante llevó a cabo tres intentos del TUG, siguiendo el procedimiento estándar de la prueba, que consistió en: levantarse de una silla, caminar tres metros, girar en la dirección de su preferencia pasando por detrás de un cono, regresar caminando tres metros hacia la silla, girar y sentarse nuevamente. En la Fig. Fig. 4-3 se presenta una secuencia representativa de la ejecución de esta prueba.




Fig. 4-3 Secuencia del test Timed Up and Go: (a) Etapa inicial Pararse; (b) Etapa Caminata ida; (c) Inicio Primer Giro; (d) Inicio etapa Caminata Vuelta; (e) Etapa Segundo Giro; (f) Etapa Sentarse.

4.3. Procesamiento de Señales y Generación Ground Truth

Para entrenar el modelo de segmentación automática, se procesó un conjunto de 315 ensayos individuales de la prueba iTUG y se generó manualmente su correspondiente ground truth. A continuación, se detalla el pipeline de preprocesamiento aplicado a las señales antes del etiquetado.

4.3.1 Preprocesamiento de señales

El objetivo de esta etapa fue transformar los datos crudos del sensor IMU en series de tiempo limpias y representativas del movimiento, listas para ser etiquetadas. El procedimiento consistió en los siguientes pasos:

1. Extracción de Datos Crudos:

Los datos iniciales se registraron en formato JSON, conteniendo las señales del acelerómetro (ax , ay , az), giroscopio (gx , gy , gz) y los cuaterniones de orientación (qx , qy , qz , qw) para los tres intentos consecutivos de cada participante.

2. Conversión a Ángulos de Euler:

Para obtener una representación biomecánicamente interpretable de la orientación del tronco, los datos de orientación en formato de cuaternión se convirtieron a ángulos de Euler: roll (balanceo lateral), pitch (inclinación anteroposterior) y yaw (giro eje vertical).

3. Limpieza y Normalización de Señales:

- Recorte inicial: Se eliminaron las primeras 200 muestras (equivalentes a 2 segundos) de todas las señales para excluir el período estático inicial en que suena el sonido de preparación e inicio.
- Corrección de discontinuidades: Se aplicó a la señal de yaw el algoritmo de corrección de discontinuidades descrito en [75], el cual detecta y corrige saltos angulares superiores a 180° para garantizar una representación continua del giro.
- Valor absoluto: A las señales de pitch y yaw se les calculó su valor absoluto para enfocar el análisis en la magnitud del movimiento.
- Eliminación de offset: Finalmente, se removió el offset de ambas señales restando el valor de la primera muestra a toda la serie.

4. Selección de señales:

Del conjunto de señales disponibles, se seleccionaron únicamente las señales de pitch y yaw como entradas para el modelo de segmentación. Esta decisión busca un balance óptimo entre la riqueza informativa y la eficiencia computacional, dado que estas dos señales capturan eficazmente la dinámica del tronco en los planos de movimiento dominantes durante la prueba.

Desde un punto de vista biomecánico, el movimiento del tronco durante el test TUG se concentra principalmente en los planos sagital y transversal. El pitch refleja los cambios de inclinación anterior–posterior asociados a las transiciones Sit–to–Stand, Stand–to–Sit y las fases de inicio y terminación de la marcha, mientras que el yaw captura la rotación axial del tronco, componente clave para identificar de manera precisa las fases de giro (turning) y la modulación direccional durante la marcha. Ambos ángulos, por tanto, representan de forma directa los patrones dinámicos más distintivos que separan cada sub-tarea del TUG [70], [76].

Una vez completado este preprocesamiento, las 315 series temporales de pitch y yaw fueron importadas a la herramienta de anotación Label Studio®, donde se procedió al etiquetado manual de cada fase para construir el ground truth final.

4.3.2 Protocolo de Etiquetado en Label Studio

El etiquetado manual de las pruebas se realizó en la plataforma Label Studio [77], utilizando un protocolo desarrollado específicamente para este estudio, basado en criterios biomecánicos del movimiento del tronco y en la observación sistemática de las señales de pitch y yaw preprocesadas, con el fin de identificar los límites de las seis etapas del test Timed Up and Go (TUG). La coherencia de este protocolo fue posteriormente evaluada a través de la validación clínica del algoritmo de segmentación:

- Pararse (Sit-to-Stand): Comienza con el inicio del aumento sostenido de la señal de pitch y termina en la estabilización del primer peak principal de dicha señal, que marca el fin de la extensión completa.
- Caminata de Ida (First Walk): Se extiende desde la estabilización del primer peak de pitch hasta el punto donde la señal de yaw inicia su primer ascenso sostenido.
- Primer Giro (First Turn): Comienza con el ascenso sostenido de la señal de yaw y finaliza cuando dicha señal alcanza aproximadamente los 180°.
- Caminata de Vuelta (Return Walk): Abarca desde que el yaw alcanza los ~180° y se mantiene en este valor. Esta subetapa termina en el punto donde la señal de yaw inicia su segundo ascenso sostenido, marcando el inicio del segundo giro.
- Segundo Giro (Second Turn): Identificado por el segundo ascenso sostenido en la señal de yaw (desde ~180° de vuelta hacia ~360°). Esta fase se solapa frecuentemente con la subetapa Stand-to-Sit.
- Sentarse (Stand-to-Sit): Comienza con el inicio del aumento sostenido que precede al segundo peak prominente en la señal de pitch, correspondiente a la flexión del tronco para iniciar el movimiento de sentarse. La fase culmina con la estabilización de la señal tras dicho pico, marcando el final de la prueba. Esta subetapa frecuentemente se solapa con la fase del Segundo Giro.

Este proceso resultó en 315 pruebas etiquetadas, listas para ser utilizadas en el entrenamiento del modelo de Deep Learning. El outline de estos pasos se presenta en la Fig. 4-4.

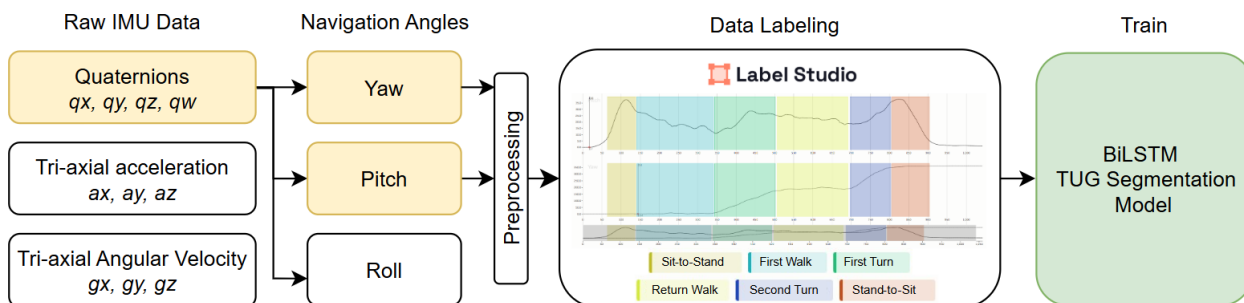


Fig. 4-4 Obtención y etiquetado de datos para entrenamiento del modelo.

4.3.3 Ground Truth Clínico Basado en Video (Para Validación)

La validación del modelo se realizó utilizando datos obtenidos del sistema óptico de captura de movimiento OptiTrack®, considerado estándar de referencia en este trabajo, para la medición precisa y análisis del movimiento humano [32].

Los datos capturados fueron analizados mediante el software Mokka®, donde 2 observadores clínicos (ciegos entre sí), segmentaron manualmente las seis subetapas de cada prueba TUG, lo cual se utilizó como ground truth para la validación. Los criterios para segmentar manualmente cada subetapa del test TUG mediante el software Mokka® se presentan en la Tabla IV, los cuales fueron utilizados para validar el algoritmo propuesto en [75]. Cabe destacar que el evento *Caminata Ida* puede identificarse en dos escenarios clínicamente relevantes:

Caso 1: Pararse seguido del primer paso.

En este caso, la persona no realiza un ajuste significativo del tronco tras levantarse, lo que sugiere un control postural eficiente y una transición directa hacia la fase de marcha. Este patrón es común en individuos con buena estabilidad [78].

Caso 2: Pararse, mantenerse en bípedo y realizar el primer contacto.

Tras levantarse, la persona realiza un ajuste del tronco antes de dar el primer paso, lo cual refleja la necesidad de estabilizarse en posición bípedo antes de iniciar la marcha. Este patrón puede observarse en personas con alteraciones en el equilibrio o debilidad muscular [79].

En la subetapa *Sentarse*, se han identificado dos escenarios clínicamente relevantes:

Caso 1: Giro al sentado.

En este caso, la persona realiza directamente el giro y la transición al apoyo completo de los glúteos, sin detenerse en posición bípedo [80]. En base a la identificación de eventos mediante las señales

inerciales de rotación e inclinación del tronco, se aprecia que ambas fases de ‘Segundo giro’ y ‘Sentarse’ son simultaneas.

Caso 2: Giro, pausa en posición bípedo y sentado.

Aquí, la persona realiza el giro, mantiene brevemente la posición bípeda para estabilizarse, y luego procede a sentarse.

Tabla IV. Criterios biomecánicos utilizada por los observadores clínicos para la identificación de Subetapas del test TUG [75].

Subetapas TUG	Inicio
Pararse	Desde flexión anterior de la pelvis y despegue de los glúteos.
Caminata Ida	Estabilización del tronco inferior y pelvis o primer contacto inicial talón en la fase de apoyo de la marcha.
Primer Giro	Inclinación de la pelvis e inicio de la rotación del tronco.
Caminata Vuelta	Finaliza rotación de tronco y contacto inicial del talón.
Segundo Giro	Inicio de la rotación e inclinación de la pelvis. Finaliza con el inicio de la flexión del tronco
Sentarse	Inicia flexión de tronco, pelvis, flexión de rodilla, cadera y tobillo. Finaliza con el apoyo total de los glúteos.

4.4. Desarrollo de un Modelo de Segmentación Automática

Para abordar el desafío de la segmentación temporal del test Timed Up and Go (TUG), se diseñó e implementó un modelo basado en una arquitectura BiLSTM (Red Neuronal Recurrente Bidireccional de Memoria a Corto y Largo Plazo). La elección de este enfoque se fundamenta en su capacidad para procesar secuencias temporales y capturar dependencias contextuales tanto pasadas como futuras, lo que es crucial para identificar transiciones entre las subtareas del TUG con mayor robustez frente a la variabilidad inter-sujeto y condiciones patológicas. La metodología general de segmentación automática del test TUG se ilustra en la Fig. 4-5.

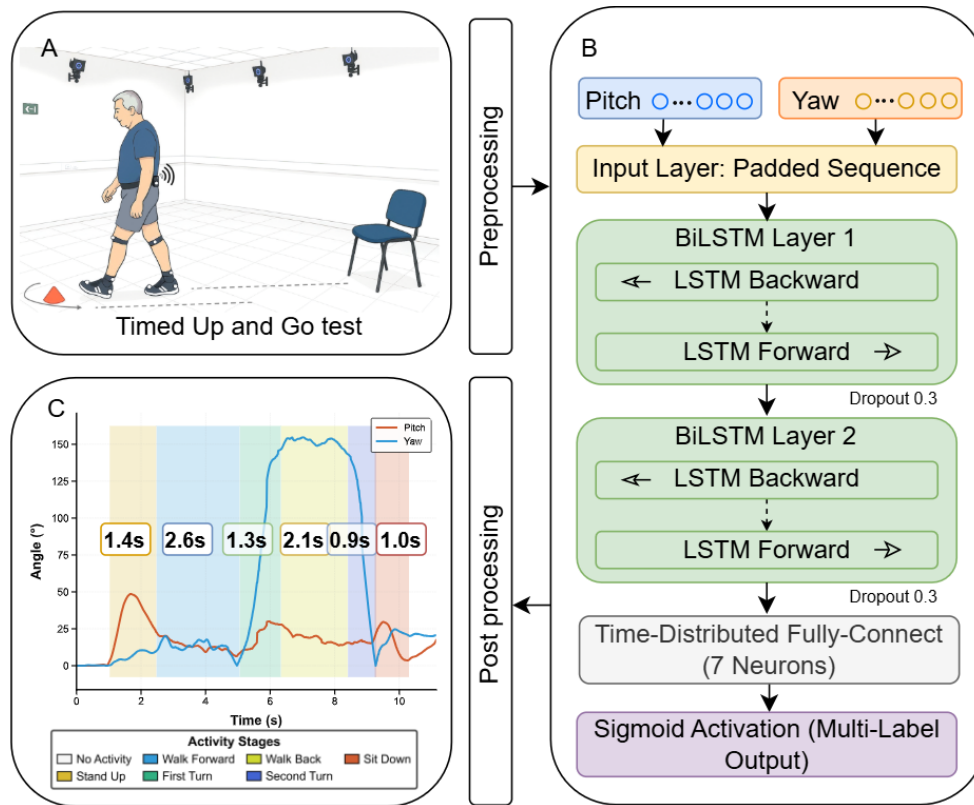


Fig. 4-5. Metodología general para la segmentación del test TUG: (a) Setup de adquisición de datos; (b) Arquitectura del modelo propuesto; (c) Salida de segmentación que muestra la duración de cada subtarea del TUG.

4.4.1 Arquitectura Propuesta: Modelo BiLSTM

La arquitectura del modelo fue diseñada específicamente para la tarea de segmentación temporal y consta de las siguientes tres capas principales:

- 1) **Input Layer:** La primera capa se encarga de gestionar las secuencias de longitud variable. Dado que las señales del TUG se agrupan en lotes (batches) para el entrenamiento, se aplica un relleno (padding) con un valor de -1 para igualar sus longitudes. Esta capa inicial asegura que dichos valores de relleno sean ignorados durante el proceso de entrenamiento, evitando que afecten el cálculo del gradiente y el aprendizaje del modelo.
- 2) **Capas BiLSTM Apiladas:** El núcleo del modelo consta de dos capas BiLSTM apiladas, cada una con 128 unidades ocultas. El uso de una arquitectura bidireccional es fundamental, ya que permite que el modelo no solo utilice información pasada, sino también futura, para contextualizar y realizar una clasificación más precisa de cada punto en el tiempo. La

naturaleza apilada de las capas le permite aprender jerarquías de características temporales cada vez más abstractas y complejas. Para mitigar el sobreajuste (overfitting), se aplicó una tasa de dropout de 0.3 entre las capas BiLSTM.

- 3) Capa de Salida Lineal (Fully Connected Layer): Finalmente, la salida de la última capa BiLSTM se proyecta a través de una capa lineal totalmente conectada. Esta capa final transforma el espacio de características aprendido en un vector de logits correspondiente a las siete clases de salida: las seis fases del TUG ("Pararse", "Caminar ida", "Primer giro", "Caminar vuelta", "Segundo giro", "Sentarse") más una clase nula para los segmentos de inactividad o no definidos.

4.4.2 Entrenamiento del Modelo

El modelo fue entrenado utilizando el conjunto de datos descrito en la Sección 4.3. Los 315 ensayos se dividieron de manera estratificada en un conjunto de entrenamiento (80%, n=255) y otro de prueba (20%, n=63), preservando la distribución de clases en ambos grupos. La configuración de entrenamiento fue la siguiente:

- Optimizador: Adam
- Tasa de aprendizaje: 0.0005
- Tamaño de lote (batch size): 16
- Épocas: 150
- Función de pérdida: Entropía Cruzada (Cross-Entropy Loss), seleccionada por su idoneidad para problemas de clasificación multiclase.

El output del modelo de segmentación se evidencia en la Fig. 4-6.



Fig. 4-6 Output del modelo: Segmentación de la prueba TUG en sus subetapas, a través de sus señales de entrada Pitch y Yaw.

4.5. Estrategia de Validación

Para evaluar de manera integral el modelo de segmentación automática, se diseñó una estrategia de validación doble. Primero, una validación técnica para cuantificar el rendimiento del clasificador a nivel de frame. Segundo, una validación clínica para determinar la concordancia del algoritmo con la segmentación de expertos, considerada como segmentación de referencia.

4.5.1 Validación Técnica

- 1) Precision: Mide la fiabilidad de las predicciones del modelo. Para una clase específica, representa la fracción de frames que realmente pertenecen a esa clase de entre todos los frames que el modelo predijo como tal.

$$Precision = \frac{VP}{VP + FP} \quad (4.1)$$

- 2) Recall (Sensibilidad): Mide la capacidad del modelo para identificar todos los frames relevantes de una clase. Representa la fracción de frames de una clase que el modelo fue capaz de identificar correctamente.

$$Recall = \frac{VP}{VP + FN} \quad (4.2)$$

- 3) F1-Score: Proporciona una métrica única y balanceada que penaliza los desequilibrios extremos entre ambas. Es particularmente útil para evaluar el rendimiento general del modelo en clases con diferente número de muestras (soporte).

$$F1-Score = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4.3)$$

4.5.2 Validación Clínica

Con el fin de cuantificar el desempeño de la detección y segmentación automática del algoritmo, frente a la segmentación manual hecha por observadores clínicos, se obtuvieron las siguientes métricas:

1) Diferencia de Tiempos (ΔT)

Comparación entre los tiempos de segmentación manual y el tiempo de segmentación entregado por el algoritmo:

$$\Delta T = T_m - T_a \quad (4.4)$$

donde,

T_m : Duración promedio en segundos de la segmentación manual de la prueba, y

T_a : Duración en segundos de subetapa entregada por el algoritmo.

2) Mean Absolute Error (MAE)

Evalúa el promedio de las diferencias absolutas entre los tiempos de inicio y fin de cada subetapa detectados por el algoritmo y la segmentación manual:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\Delta T_i| \quad (4.5)$$

3) Coeficiente de correlación de Pearson (r)

Evalúa la relación lineal entre los tiempos de segmentación manual (T_m) y los tiempos entregados por el algoritmo (T_a):

$$r = \frac{\sum(T_m - \bar{T}_m)(T_a - \bar{T}_a)}{\sqrt{\sum(T_m - \bar{T}_m)^2 \cdot \sum(T_a - \bar{T}_a)^2}} \quad (4.6)$$

4) Coeficiente de Correlación Intraclase (ICC)

Para establecer la consistencia de la segmentación manual de referencia, se evaluó la fiabilidad Inter-observador calculando el Coeficiente de Correlación Intraclase (ICC) entre las duraciones de cada subetapa registradas por los dos evaluadores clínicos. Este análisis cuantifica el grado de acuerdo entre los expertos, considerando la fiabilidad como pobre para valores de ICC inferiores a 0.5, moderada entre 0.5 y 0.75, buena entre 0.75 y 0.9, y excelente para valores superiores a 0.9.

4.6. Caracterización de Biomarcadores Cinemáticos

A través de la segmentación por subetapas del test Timed Up and Go, se analizaron parámetros cinemáticos clave, como aceleración y velocidad angular, con el objetivo de identificar patrones de movimiento en individuos sanos y en personas con disfunciones motoras, establecer rangos de normalidad y detectar desviaciones o señales que se alejen de dichos rangos. La Fig. 4-7 muestra los planos anatómicos y su correspondencia con los ejes XYZ del sistema de referencia de la IMU, lo que permite interpretar la dirección y sentido de los movimientos registrados.




Fig. 4-7 Planos anatómicos y ejes XYZ del sistema de referencia de la IMU.

4.6.1 Definición de características a partir de la segmentación

De cada una de las seis etapas del TUG, se extrajeron cinco características estadísticas (valor máximo, medio, RMS, desviación estándar y rango) a partir de nueve señales de entrada (véase Fig. 4-8). De este modo, cada ejecución del test TUG fue representada por un vector total de 270 características (6 subetapas \times 9 señales \times 5 características) para su posterior análisis.




Fig. 4-8 Señales inerciales y ángulos de navegación: segmentadas por etapas para un intento del test TUG.

4.6.2 Análisis de la duración de subetapas por grupo

Adicionalmente, se realizaron análisis estadísticos para comparar las duraciones de las seis subetapas del TUG entre los cuatro grupos de participantes: Adultos Jóvenes, Adultos de Mediana Edad, Adultos Mayores y Grupo Clínico. Para cada fase del TUG, se evaluaron los supuestos de normalidad de las distribuciones de duración en cada grupo mediante la prueba de Shapiro-Wilk ($\alpha = 0.05$). La homogeneidad de varianzas se evaluó mediante la prueba de Levene. Basándose en estos tests diagnósticos, se seleccionaron métodos no paramétricos para todas las comparaciones debido al no cumplimiento de los supuestos de normalidad en uno o más grupos. Las diferencias entre grupos se evaluaron mediante la prueba H de Kruskal-Wallis, alternativa no paramétrica al ANOVA unidireccional. Cuando esta prueba omnibus indicaba diferencias significativas entre grupos ($p < 0.05$), se realizaron comparaciones post-hoc por pares utilizando la prueba de Dunn con corrección de Bonferroni para controlar comparaciones múltiples (6 comparaciones por pares por fase). Las estadísticas descriptivas para cada grupo se reportaron como mediana y rango intercuartílico (IQR), medidas apropiadas para datos no normales.

Todos los análisis estadísticos se realizaron utilizando Python (v3.8) con scipy (v1.7.3) para tests estadísticos, scikit-posthocs (v0.7.0) para comparaciones post-hoc, y pandas (v1.3.5) para manipulación de datos. La significancia estadística se estableció en $\alpha = 0.05$ para todos los tests.

4.6.3 Selección de Biomarcadores mediante Recursive Feature Elimination (RFE)

Para reducir el número de características y llegar a las más significativas por cada etapa, se implementó un algoritmo de selección de biomarcadores basado en Recursive Feature Elimination (RFE), técnica ampliamente utilizada en aprendizaje automático para identificar las características más relevantes en problemas de clasificación.



Fig. 4-9 Flujo general de la extracción de biomarcadores mediante RFE.

El objetivo del modelo fue identificar los biomarcadores cinemáticos que mejor discriminan entre los cuatro grupos de estudio (Jóvenes, Adultos, Adultos Mayores y Patológicos) durante las distintas fases del test Timed Up and Go (TUG).

El método RFE opera mediante un proceso iterativo que evalúa la importancia relativa de cada característica. Se empleó un clasificador Random Forest como estimador base, cuya función objetivo es la minimización de la impureza (índice de Gini) en los nodos de los árboles de decisión. Se ejecutó el siguiente procedimiento:

1. Extracción de Características

- Procesamiento de datos crudos del sensor inercial desde archivos JSON
- Cálculo de ángulos de navegación (yaw, pitch, roll) mediante transformación de cuaterniones
- Extracción de 5 características estadísticas para cada una de las 9 señales registradas
- Análisis independiente para las 6 etapas del TUG

2. Selección de Biomarcadores mediante RFE

- Aplicación de Recursive Feature Elimination con clasificador Random Forest

- Selección de las 10 características más discriminativas por etapa del TUG
- Objetivo: Maximizar la capacidad de clasificación entre los cuatro grupos

Flujo de ejecución:

- Preprocesamiento: Estandarización de datos mediante StandardScaler
- Selección iterativa: Procesamiento de todos los participantes y sus 3 intentos
- Configuración de RFE para selección de 10 características
- Eliminación recursiva de la característica menos importante en cada iteración
- Criterio: menor contribución a la reducción de impureza

El resultado de este análisis corresponde a un conjunto optimizado de 10 biomarcadores por etapa del TUG que maximiza la separabilidad entre grupos. La metodología de selección RFE se evidencia en la Fig. 4-10.




Fig. 4-10 Proceso de selección de biomarcadores mediante RFE.

4.6.4 Validez de la Selección de Características

Para garantizar la robustez y validez del proceso de selección realizado mediante RFE, se llevaron a cabo análisis estadísticos enfocados en dos dimensiones: la estabilidad algorítmica de los biomarcadores seleccionados y su capacidad discriminativa entre grupos. El objetivo fue verificar diferencias significativas en las propiedades estadísticas entre las características seleccionadas y no seleccionadas.

1. Análisis de Estabilidad del Algoritmo RFE: Con el objetivo de evaluar la consistencia de la selección ante variaciones en la inicialización del algoritmo, se ejecutó el siguiente análisis:
 - Ejecuciones Múltiples: 30 iteraciones de RFE con semillas aleatorias diferentes
 - Cálculo de Estabilidad: Frecuencia de selección por característica
 - Clasificación por Confianza:
 - i. Alta confianza: >80% estabilidad

- ii. Media confianza: 60-80% estabilidad
- iii. Baja confianza: <60% estabilidad

2. Análisis de Capacidad Discriminativa (AUC): El poder discriminativo entre pares de grupos específicos se evaluó mediante el área bajo la curva ROC (AUC). Se entrenaron modelos de regresión logística para cuatro comparaciones de interés clínico:

- i. Jóvenes vs Adultos Mayores
- ii. Adultos vs Adultos Mayores
- iii. Adultos Mayores vs Patológico
- iv. Adultos Jóvenes vs Patológico.

Un valor $AUC \geq 0.75$ se consideró indicativo de buena capacidad discriminativa, mientras que $AUC \geq 0.85$ se interpretó como excelente.

4.6.5 Definición de patrones de normalidad en función de la edad

Se aplicó el test de Shapiro Wilk ($\alpha = 0.05$) para evaluar la normalidad de las distribuciones de cada biomarcador según grupo etario. Para cada biomarcador y subetapa del TUG seleccionada mediante RFE, se calcularon los percentiles 2.5 y 97.5 como un método robusto que no asume normalidad en las distribuciones, capturando así el 95 % central de la población.

Adicionalmente, se estimaron medidas de tendencia central (media y mediana) y de dispersión (desviación estándar y rango intercuartílico, P25–P75).

Finalmente, con el objetivo de explorar la influencia del envejecimiento en los parámetros cinemáticos, se analizó la relación entre la edad y los valores de los biomarcadores. Para ello, se calcularon coeficientes de correlación y modelos de regresión lineal para cada biomarcador, identificando aquellos que mostraban tendencias de cambio estadísticamente significativas con la edad.

Capítulo 5. Resultados

5.1. Rendimiento del modelo

5.1.1 Validación Técnica del Modelo BiLSTM

Con el fin de evaluar el rendimiento del modelo de segmentación entrenado, se calcularon las métricas de Precisión, Sensibilidad y F1-score para cada subetapa de la prueba TUG, cuyos resultados se presentan en la Tabla IV. Para un análisis detallado en la clasificación de subetapas, la Fig 5-1. presenta la matriz de confusión correspondiente.

Tabla V Métricas de rendimiento del modelo de segmentación.

Subetapa	Precisión	Sensibilidad	F1-score	support
Pararse	0.92	0.93	0.93	7844
Caminar ida	0.97	0.95	0.96	19999
Primer giro	0.93	0.94	0.94	13630
Caminar vuelta	0.95	0.96	0.96	14178
Segundo giro	0.95	0.90	0.92	10773
Sentarse	0.91	0.91	0.91	7583
Sin Actividad	0.92	0.95	0.94	19075




Fig. 5-1 Matriz de confusión del modelo de segmentación para las subetapas de la prueba TUG, evaluada a nivel de muestras temporales. Los valores representan el número de puntos clasificados por subetapa.

5.1.2 Confiabilidad Inter-evaluador

Para establecer la robustez del ground truth de referencia, se evaluó la concordancia entre las segmentaciones realizadas por dos evaluadores clínicos independientes. La Tabla VI presenta el análisis entre ambos observadores.

Tabla VI. Análisis Confiabilidad Inter-evaluador

Subetapa	MAE (s)	Pearson (r)	ICC
Pararse	0.315	0.912	0.902
Caminar ida	0.288	0.929	0.929
Primer giro	0.375	0.814	0.812
Caminar vuelta	0.372	0.817	0.817
Segundo giro	0.275	0.873	0.873
sentarse	0.333	0.864	0.782
Tiempo total	0.389	0.993	0.995




Fig. 5-2 Gráficos de ICC y Diferencia de tiempo promedio (Evaluador 1 vs Evaluador 2).




Fig. 5-3 Bland-Altman: Concordancia Inter-evaluador (Tiempo Total TUG)

5.1.3 Validación Clínica

El desempeño del algoritmo de segmentación automática se evaluó frente a las segmentaciones de los dos evaluadores clínicos. La Figura 5-4 ilustra el Error Promedio Absoluto (MAE) del algoritmo comparado con cada evaluador. A su vez, La Tabla VII presenta las métricas de concordancia entre el algoritmo de segmentación automática y cada evaluador clínico.

Tabla VII Métricas de concordancia entre algoritmo de segmentación automática y cada evaluador clínico.

Subetapa	MAE Ev1 (s)	MAE Ev2 (s)	r Ev1	r Ev2	ICC Ev1	ICC Ev2
Pararse	0.30	0.36	0.77	0.76	0.75	0.78
Caminar Ida	0.35	0.39	0.92	0.90	0.92	0.90
Primer Giro	0.28	0.38	0.80	0.82	0.80	0.80
Caminar Vuelta	0.33	0.33	0.92	0.82	0.92	0.81
Segundo Giro	0.32	0.40	0.91	0.82	0.91	0.79
Sentarse	0.45	0.40	0.75	0.85	0.73	0.69
Tiempo Total	0.86	0.79	0.88	0.88	0.86	0.88

Ev1: Evaluador 1; Ev2: Evaluador 2; MAE: Error Absoluto Medio; r: Coeficiente de correlación de Pearson; ICC: Coeficiente de Correlación Intraclase.

La Fig. 5-5 muestra la duración media de cada subetapa obtenida por el algoritmo comparada con el promedio de ambos evaluadores clínicos.




Fig. 5-4 Error promedio absoluto de segmentación automática vs evaluadores.




Fig. 5-5 Duración media por subetapa: Modelo vs evaluadores.

5.2. Caracterización de Biomarcadores

5.2.1 Biomarcadores Cinemáticos más discriminativos según RFE

El algoritmo de Eliminación Recursiva de Características (RFE) identificó un total de 60 biomarcadores cinemáticos (10 por etapa) a partir de un espacio inicial de 270 características. La tabla VIII presenta los 10 biomarcadores más relevantes por etapa del TUG en base a su frecuencia de selección.

Tabla VIII Biomarcadores seleccionados por etapa TUG mediante algoritmo RFE.

Nº Biomarcador	Pararse	Caminata ida	Primer Giro	Caminata vuelta	Segundo Giro	Sentarse
BM1	Vx rms	Vx mean	Vx max	Vy max	Vy max	Vx p-p
BM2	Vx std	Yaw max	Vy rms	Ax std	Vy rms	Yaw max
BM3	Ay std	Pitch std	Vx mean	Vx mean	Ax std	Vx std
BM4	Ay max	Az std	Ax std	Vy mean	Ax rms	Vz std
BM5	Yaw rms	Vx p-p	Ay std	Vy std	Yaw p-p	Yaw mean
BM6	Ay p-p	Ay mean	Ax rms	Ay rms	Yaw std	Ax p-p
BM7	Yaw mean	Yaw mean	Ay rms	Vy p-p	Vy mean	Vz max
BM8	Vx max	Ay std	Az std	Ay std	Yaw mean	Pitch max
BM9	Ay mean	Pitch p-p	Vz rms	Yaw mean	Vx mean	Yaw std
BM10	Vy std	Ax std	Ax p-p	Az std	Vy p-p	Yaw p-p

5.2.2 Análisis de Estabilidad del Algoritmo RFE

Se presenta el análisis de estabilidad de los biomarcadores seleccionados en el Heatmap de la Fig. 5-6, donde se obtuvo una puntuación global de estabilidad del 79%.

A partir de este análisis, se evaluó el número de biomarcadores seleccionados en diferentes rangos de confianza (Alta confianza: >80%, Media Confianza: 60-80% y Baja Confianza: <60%), lo que permitió determinar el nivel de consistencia de cada característica frente a las variaciones del conjunto de entrenamiento. La Fig. 5-7(a) muestra la distribución del número de biomarcadores en cada nivel de confianza, mientras que la Fig. 5-7 (b) presenta la proporción de selección de estos según el tipo de señal.




Fig. 5-6 Heatmap de la Estabilidad de selección de biomarcadores por RFE según etapa TUG.

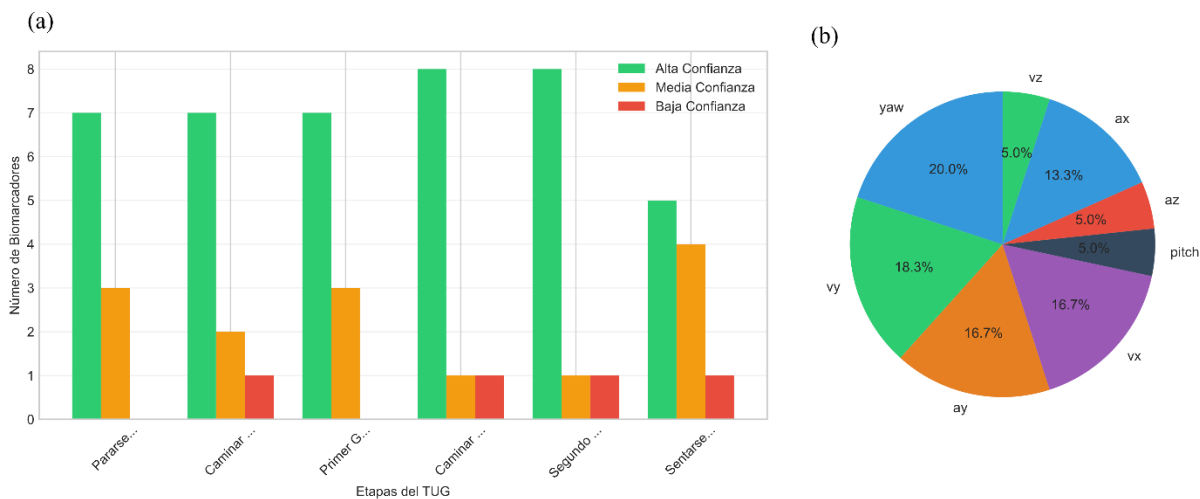


Fig. 5-7 Biomarcadores según nivel de confianza por subetapa: (a) Clasificación por nivel de confianza. (b) Distribución de BM por tipo de señal.

5.2.3 Poder Discriminativo

El análisis de discriminación por grupos a partir de estos biomarcadores (Fig. 5-8 mostró valores de AUC superiores a 0.75 en el 100% de las cuatro comparaciones evaluadas. El mayor valor de AUC se observó en la comparación Jóvenes vs. Patológico durante la etapa de Segundo Giro (AUC

= 0.98), mientras que el menor valor correspondió a la comparación Jóvenes vs. Adultos en Pararse (AUC = 0.78). En promedio, los biomarcadores presentaron un AUC de 0.95 en las comparaciones que incluyeron grupos patológicos.

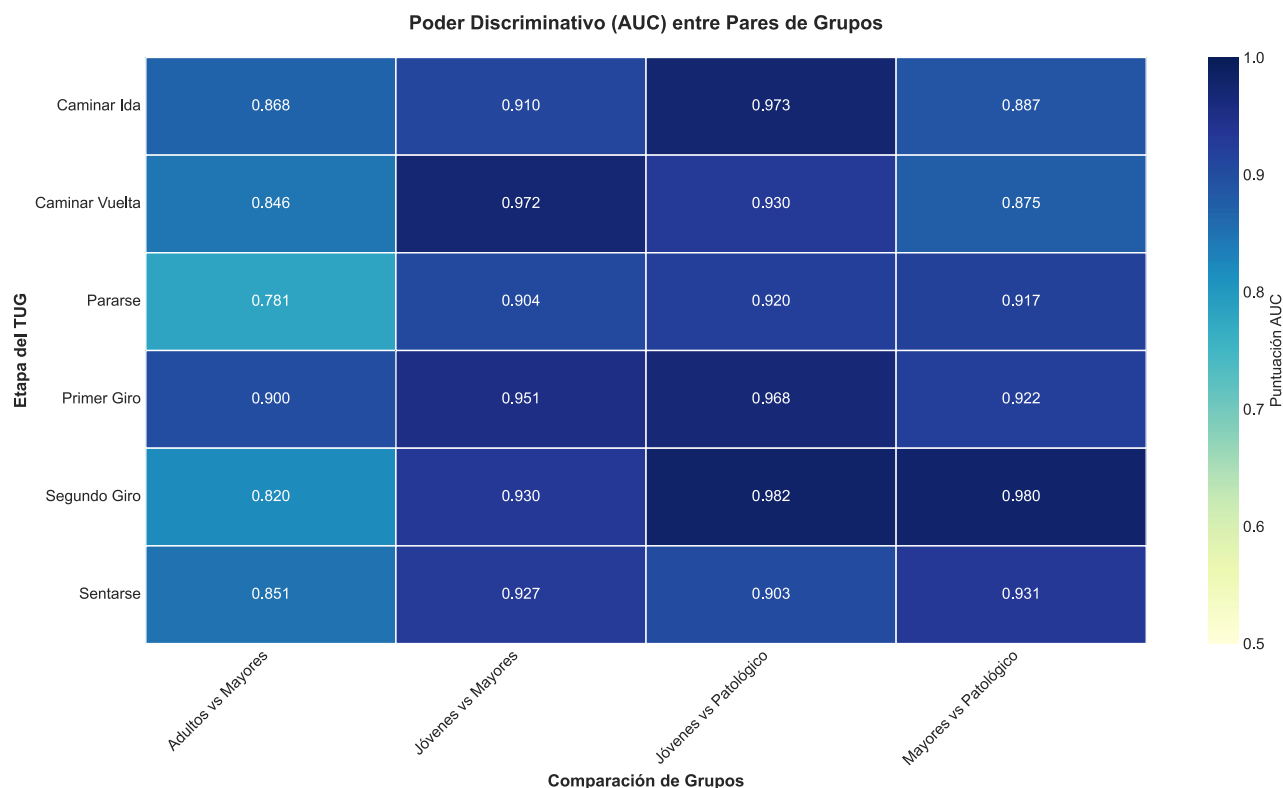


Fig. 5-8 Heatmap del poder discriminativo (AUC) entre grupos a partir de biomarcadores de cada etapa TUG.

5.3. Patrones de normalidad de Biomarcadores en función de la edad

5.3.1 Caracterización de la población de referencia

Se establecieron rangos de normalidad específicos por grupo etario utilizando exclusivamente la población de controles sanos, distribuidos en 3 grupos presentes en la Tabla IX. Se establecieron un total de 180 rangos de normalidad correspondientes a los 60 biomarcadores distribuidos en las 6 etapas del TUG para cada uno de los grupos de control.

Tabla IX Características demográficas y antropométricas de los participantes.

	Jóvenes (n=25)	Adultos (n=30)	Adulto Mayor (n=24)	Grupo Clínico (n=26)
Edad (años)	26.2 ± 3.9	52.7 ± 6.6	70.2 ± 3.7	63.9 ± 16.6
Masa Corporal (kg)	72.6 ± 13.0	81.9 ± 15.1	73.4 ± 11.8	69.8 ± 13.1
Estatura (m)	1.68 ± 0.09	1.63 ± 0.10	1.62 ± 0.08	1.57 ± 0.14
IMC (kg/m ²)	25.8 ± 3.7	31.0 ± 5.2	27.9 ± 4.4	28.5 ± 5.2
Sexo (F, n (%))	13 (52%)	19 (63%)	15 (62%)	17 (65%)

5.3.2 Duración de las subetapas del TUG por grupo etario

En cuanto a las duraciones por subetapa TUG, se observaron diferencias significativas entre grupos (prueba de Kruskal-Wallis, $p < 0.001$ para todas las fases; Tabla VII). Las estadísticas descriptivas revelaron que el grupo clínico exhibió consistentemente duraciones más largas en comparación con las cohortes sanas en todas las fases de movimiento. Las comparaciones post-hoc por pares mediante la prueba de Dunn con corrección de Bonferroni confirmaron estas diferencias y revelaron patrones adicionales relacionados con la edad (Fig. 5-9).

La fase de Pararse mostró diferencias significativas entre el grupo clínico y todos los grupos sanos (YA vs. CG, $p < 0.001$; MA vs. CG, $p < 0.001$; OA vs. CG, $p = 0.001$). No se encontraron diferencias significativas entre los grupos sanos (todos $p > 0.05$; Fig. 7A), consistente con los rangos intercuartílicos superpuestos entre las cohortes sanas.

La fase de stand-to-sit demostró diferencias generales significativas (Kruskal-Wallis $p = 0.0005$), con el análisis post-hoc revelando duraciones significativamente más largas en el grupo clínico comparado con adultos jóvenes ($p < 0.001$) y adultos de mediana edad ($p = 0.004$). La comparación entre adultos mayores y el grupo clínico mostró una tendencia que no alcanzó significancia estadística después de la corrección de Bonferroni. No se observaron diferencias significativas entre las cohortes sanas (todos $p > 0.05$; Fig. 5-9(F)).

La duración de la primera marcha (First Walk) reveló una progresión clara de aumento de duración entre grupos. Los adultos jóvenes demostraron duraciones significativamente más cortas comparadas con adultos mayores ($p < 0.001$) y el grupo clínico ($p < 0.001$). Los adultos de mediana

edad difirieron significativamente del grupo clínico ($p < 0.001$), mientras que la diferencia entre jóvenes y adultos de mediana edad fue marginal ($p = 0.019$). Adultos de mediana edad y adultos mayores no difirieron significativamente entre sí ($p = 0.107$; Fig. 5-9 (B))

Tabla X. Resultados de la prueba de Kruskal-Wallis para las duraciones en los distintos grupos de participantes.

Etapa TUG	H-statistic	p-value	Mediana Jóvenes (IQR)	Mediana Adultos (IQR)	Mediana Adulto Mayor (IQR)	Mediana Grupo Clínico (IQR)
Pararse	100.14	6.92E-23	1.89 (1.71-2.23)	2.17 (1.85-2.50)	2.42 (1.94-2.99)	3.57 (2.90-4.49)
Caminar Ida	161.91	4.41E-35	1.49 (1.35-1.69)	1.79 (1.54-1.95)	2.18 (1.94-2.50)	3.01 (2.48-4.08)
Primer Giro	100.86	1.80E-22	1.51 (1.33-1.67)	1.56 (1.34-1.78)	1.64 (1.42-1.85)	2.58 (1.94-3.62)
Caminar Vuelta	117.07	4.43E-27	1.01 (0.88-1.15)	1.14 (1.00-1.33)	1.29 (1.13-1.50)	2.02 (1.60-3.07)
Segundo Giro	35.95	1.17E-07	1.00 (0.92-1.06)	1.00 (0.92-1.07)	1.03 (0.95-1.19)	1.19 (1.02-1.56)
Sentarse	12.06	0.0005	0.92 (0.68-1.09)	0.92 (0.79-1.04)	0.93 (0.78-1.15)	1.03 (0.87-1.44)

Duración media (rango intercuartílico) en segundos para cada fase del TUG en los distintos grupos de participantes. Diferencias significativas ($p < 0,001$).

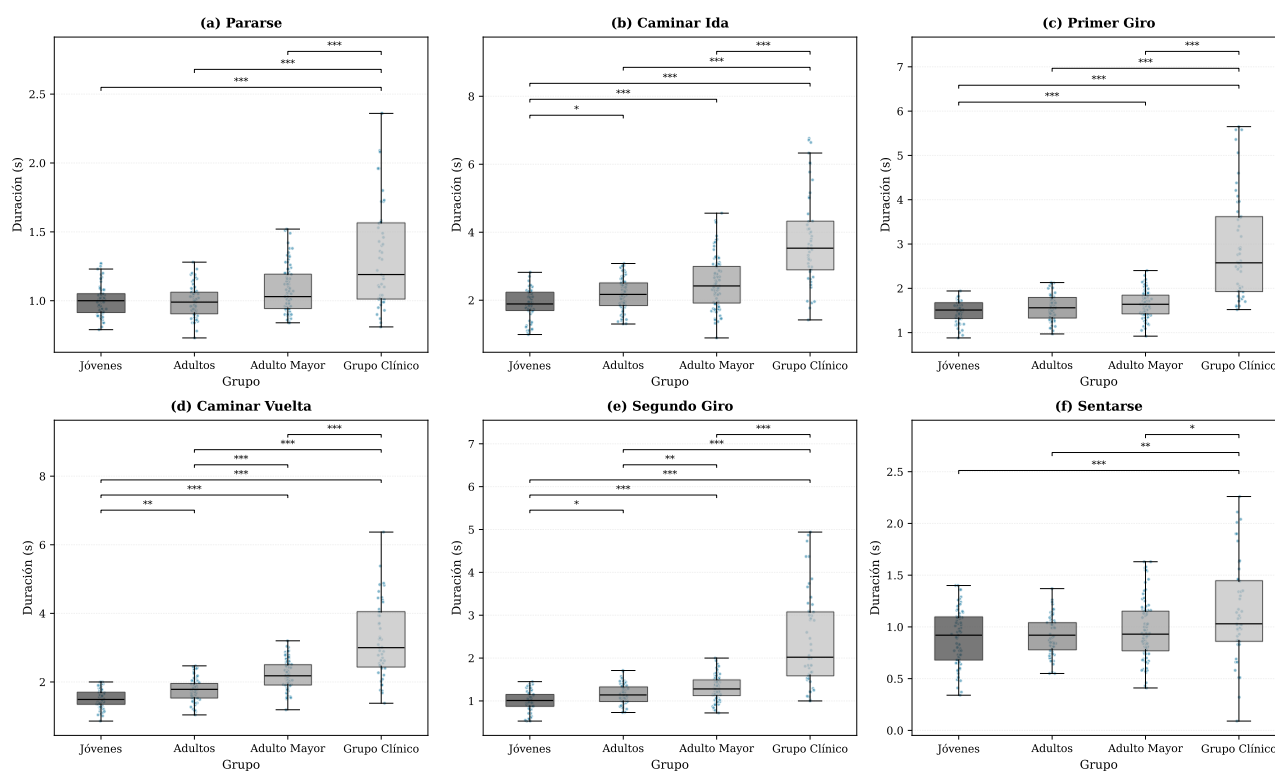


Fig. 5-9 Comparaciones de la duración de las subtarecas TUG entre los grupos de participantes: (A) Pararse, (B) Caminata ida, (C) Primer giro, (D) Caminata vuelta, (E) Segundo giro, (F) Sentarse. Se muestran los valores medianos con rangos intercuartílicos (IQR); Niveles de significación: * $p < 0.05$, ** $p < 0.01$, * $p < 0.001$ (prueba de Dunn con corrección de Bonferroni).**

5.3.3 Distribución de normalidad de los biomarcadores

El análisis de normalidad mediante Shapiro-Wilk reveló que solo el 53.9% ($n = 97/180$) de las distribuciones siguieron una distribución normal ($p > 0.05$), justificando el uso de métodos no paramétricos para el establecimiento de rangos de normalidad por grupo etario.

5.3.4 Rangos de normalidad por etapa

La Tabla XII presenta los rangos de normalidad de los 60 biomarcadores seleccionados por el algoritmo RFE (Véase Anexo A: Rangos de referencia de Biomarcadores del iTUG). A modo de ejemplo, para el biomarcador $a_{x_{rms}}$ durante el Primer Giro evidenciado en Fig. 5-10, para el grupo Jóvenes, el rango de normalidad establecido fue $[0.13 - 0.31]$, con media de 0.21 ± 0.05 . En contraste, el grupo Adultos mostró un rango de $[0.13 - 0.26]$ con media de 1.44 ± 0.21 , mientras que para adulto mayor fue de $[0.11 - 0.24]$ con media 0.16 ± 0.03 .

En los Boxplots de la Fig. 5-10 se detallan gráficamente los rangos percentílicos 2.5-97.5 para biomarcadores de la etapa Primer Giro, mostrando las diferencias intergrupales en la distribución de valores. Los Boxplots correspondientes al resto de las etapas del test se adjuntan en el Anexo B: Boxplots de distribución de valores biomarcadores en las etapas iTUG.

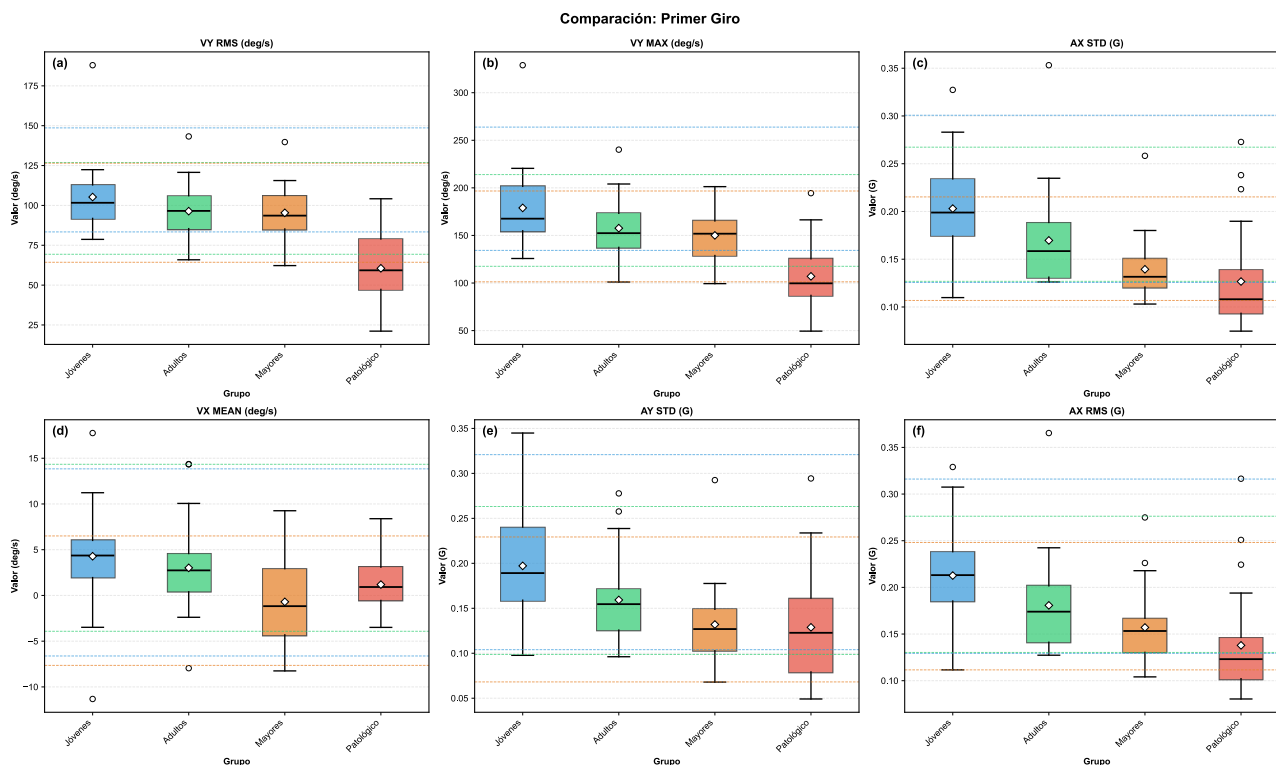


Fig. 5-10 Boxplots de Rangos percentílicos (2.5–97.5) de biomarcadores correspondientes a la etapa Primer Giro del test iTUG: (a) V_y^{rms} ; (b) V_y^{max} ; (c) a_x^{std} ; (d) V_x^{mean} ; (e) a_y^{std} ; (f) a_x^{rms} .

5.3.5 Tendencias de cambio con la edad

De los 60 biomarcadores, se identificaron 31 con correlaciones significativas ($p < 0.05$). Las tendencias más marcadas se observaron en la etapa de Caminar Vuelta, donde el coeficiente de determinación R^2 alcanzó 0.28 para el biomarcador vy_{rms} Caminar Vuelta, indicando que aproximadamente 28.0% de la variabilidad en este parámetro puede explicarse por cambios relacionados con la edad. La Figura Fig. 5-11 muestra las regresiones lineales entre la edad y los valores de los biomarcadores para la etapa de Caminar Vuelta en específico, mientras que la Fig. 5-12 muestra las Tendencias lineales entre la edad y los seis biomarcadores con mayor coeficiente de determinación (R^2) en el test Timed Up and Go (TUG) completo.

Las figuras correspondientes a las tendencias observadas en las etapas restantes del iTUG se presentan en el Anexo C: Tendencias Lineales con la edad y biomarcadores en etapas del iTUG.

Tabla XI Métricas de correlación entre la edad y valor de biomarcador: 10 más significativos.

Etapa	Biomarcador	R	R ²	Valor-p
Primer Giro	ax_std	-0.55656	0.309756	1.785E-07
Caminar Vuelta	vy_rms	-0.50653	0.256574	3.032E-06
Caminar Vuelta	vy_max	-0.48044	0.230827	1.694E-05
Primer Giro	az_std	-0.47338	0.224093	1.792E-05
Primer Giro	ay_std	-0.46721	0.218288	2.381E-05
Primer Giro	ax_range	-0.43146	0.186159	9.970E-05
Caminar Vuelta	ax_std	-0.42117	0.17738	0.000168
Caminar Vuelta	az_std	-0.42079	0.177066	0.000154
Segundo Giro	yaw_std	0.41073	0.168696	0.000307
Primer Giro	vx_mean	-0.40689	0.165561	0.000390

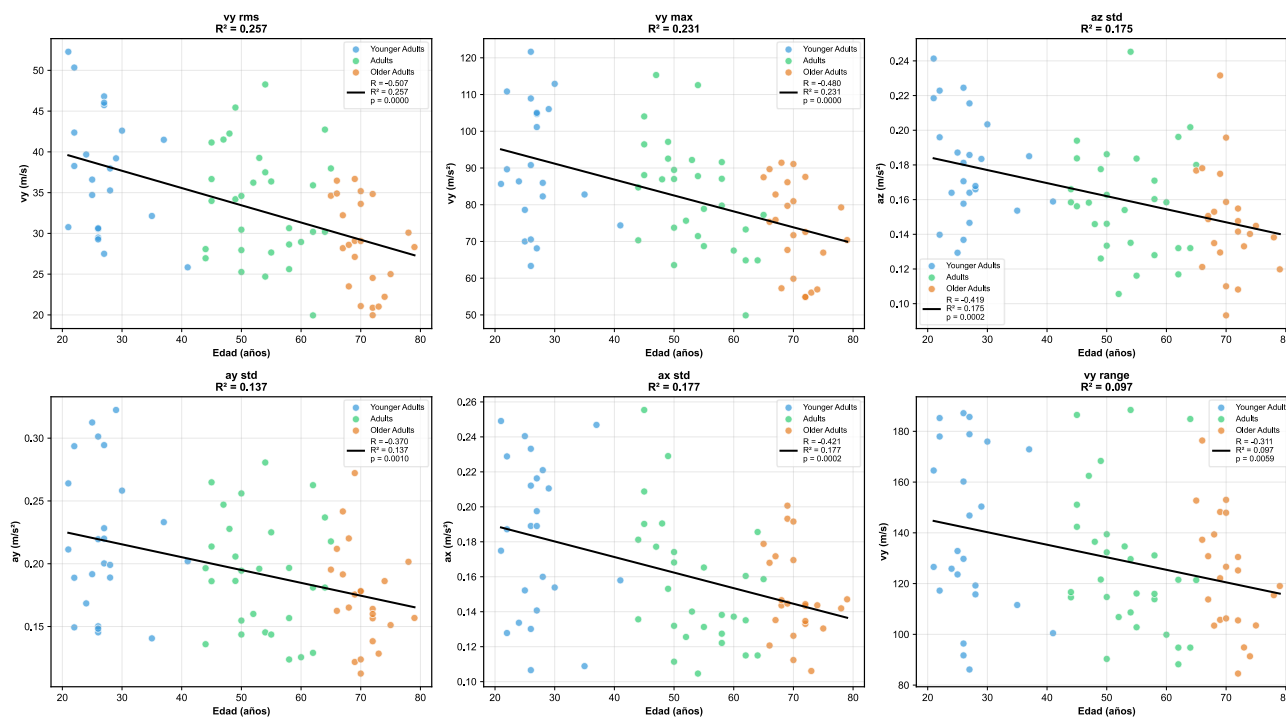


Fig. 5-11 Tendencias Lineales entre biomarcadores y la edad en etapa Caminata Vuelta.

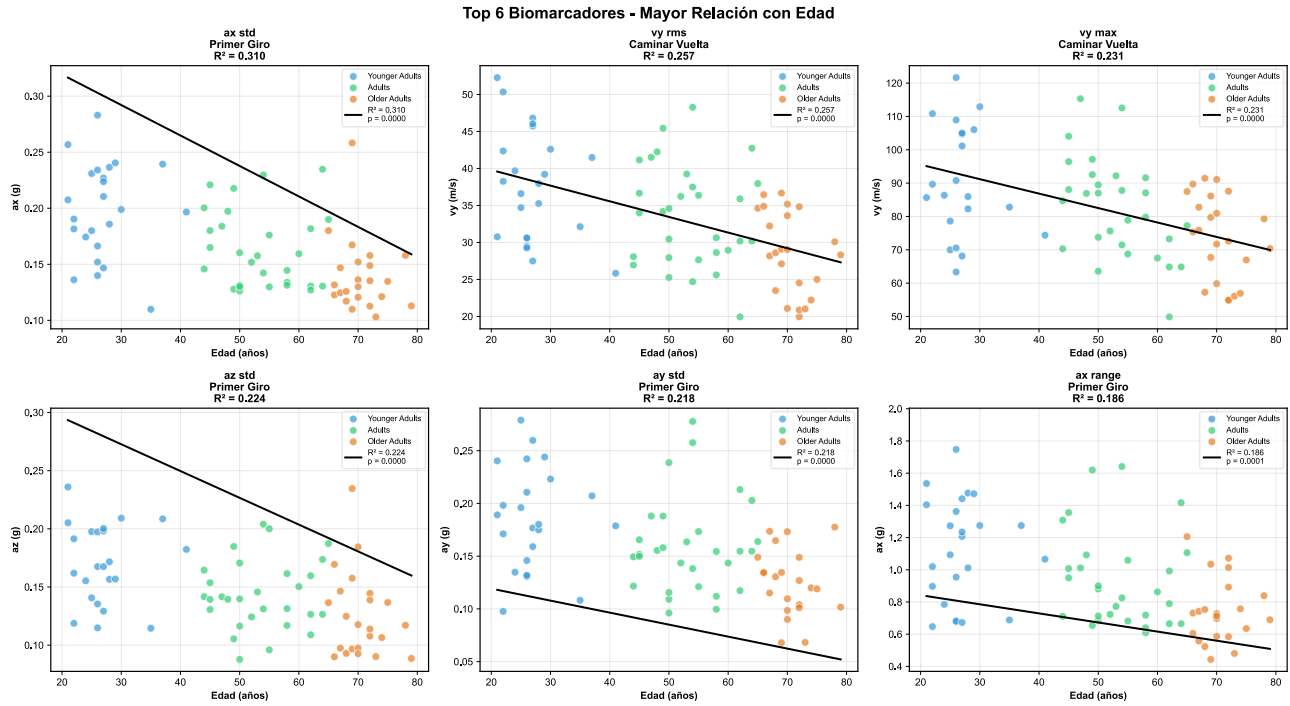


Fig. 5-12 Los seis biomarcadores con mayor relación con la edad en el análisis global del TUG. Cada gráfico presenta la regresión lineal entre la edad y un parámetro cinemático (biomarcador) específico, ordenados por fuerza de correlación (R² descendente).

Capítulo 6. Discusiones y Conclusiones

6.1. Discusión

El presente estudio tuvo como objetivo desarrollar y validar un modelo de segmentación automática del test Timed Up and Go (TUG) basado en un modelo BiLSTM y una única unidad de medición inercial (IMU) lumbar, y posteriormente emplear la segmentación obtenida para la caracterización de biomarcadores cinemáticos y su análisis discriminativo entre grupos sanos y patológicos. Los resultados obtenidos permiten discutir el rendimiento técnico del modelo, su validez clínica frente a evaluadores humanos, así como la relevancia funcional de los biomarcadores derivados en relación con el envejecimiento y la disfunción motora.

6.1.1 Desempeño técnico del modelo de segmentación

El modelo BiLSTM propuesto demostró un rendimiento robusto al clasificar las siete clases de salida (seis subetapas del TUG más la clase “sin actividad”), alcanzando métricas altas en precisión, sensibilidad y F1-score en todas las categorías. Por ejemplo, el modelo obtuvo un F1-score de 0.96 en Caminata Ida, 0.96 en Caminata Vuelta, y 0.94 en Primer Giro, lo cual confirma su capacidad para distinguir de manera efectiva las fases de marcha y giro. Estos resultados se alinean con los hallazgos de estudios previos que utilizan modelos de Deep Learning para la segmentación de actividades, los cuales reportan consistentemente un alto desempeño en la clasificación de fases [38], [54]. Las clases más complejas presentaron valores ligeramente menores, como Segundo Giro (F1 = 0.92) y Sentarse (F1 = 0.91), coherentes con la elevada variabilidad motora y el solapamiento biomecánico entre estas subetapas.

La matriz de confusión mostró patrones esperables: las fases de marcha presentaron una clasificación altamente consistente, mientras que los errores se concentraron mayormente en las transiciones entre Segundo Giro y Sentarse. Por ejemplo, en la clase Segundo Giro se observó confusión con la clase Sentarse, donde 379 muestras fueron clasificadas erróneamente como Sentarse, evidenciando el solapamiento natural entre ambas fases.

Además, los resultados basados en el MAE temporal confirmaron niveles de error clínicamente aceptables: el modelo presentó errores promedio entre 0.28 y 0.40 segundos, dependiendo de la subetapa. Sentarse fue la fase de mayor MAE (0.40 s), mientras que Primer Giro fue una de las más precisas (0.28 s). Estos valores se sitúan dentro del rango reportado en la literatura para métodos basados en IMU [49], [81], [82]. Es importante considerar que parte de este error también se relaciona con el tiempo de reacción del evaluador y el uso de un pulsador manual de tiempo, lo cual introduce una variabilidad inherente al error humano [83].

6.1.2 Concordancia del ground truth: confiabilidad Inter-evaluador

En la comparación entre el Evaluador 1 y el Evaluador 2 se observó un sesgo promedio de 0.098 segundos (97.7 ms). Esto indica que el Evaluador 1 tiende a registrar duraciones ligeramente mayores que el Evaluador 2. No obstante, esta diferencia mínima demuestra que la segmentación manual es lo suficientemente consistente como para emplearse como referencia válida en la validación del modelo automático, un resultado alineado con lo reportado en otros estudios de análisis inter-evaluador [29]. La alta concordancia entre evaluadores respalda la confiabilidad del procedimiento, aunque las pequeñas variaciones observadas refuerzan la necesidad de objetivar las mediciones con el fin de establecer un criterio de referencia estandarizado y reproducible. En conjunto con ello, los valores de ICC obtenidos confirman que el ground truth clínico es sólido y fiable, incluso en etapas donde suele existir mayor variabilidad, como Sentarse, que aun así presentó un ICC de 0.782, mientras que la alta correlación de Pearson (por ejemplo, Caminar Vuelta $r = 0.817$ y Segundo Giro $r = 0.873$) complementa esta evidencia. Por lo tanto, la referencia clínica utilizada constituye un criterio válido y adecuado para evaluar el desempeño del modelo.

6.1.3 Validación clínica del modelo frente a evaluadores

La comparación del modelo con cada evaluador clínico demostró que el desempeño del algoritmo se aproxima considerablemente al nivel humano. El MAE entre el modelo y los evaluadores se mantuvo en rangos similares a los observados entre los mismos evaluadores, especialmente en las fases de marcha. Por ejemplo, en las etapas:

- Caminar Ida: MAE modelo–Ev1 = 0.35 s, Ev1–Ev2 = 0.288 s
- Caminar Vuelta: MAE modelo–Ev1 = 0.33 s, Ev1–Ev2 = 0.372 s

En otras palabras, el error entre el modelo y un evaluador clínico es comparable, e incluso menor en algunos casos, al error entre los propios evaluadores humanos. Lo cual constituye una evidencia fuerte de validez clínica.

Además, se observaron correlaciones altas entre el modelo y los evaluadores en todas las fases (por ejemplo, Caminar Ida $r = 0.92$ con Ev1 y 0.90 con Ev2). El ICC con evaluadores mostró un patrón similar: Primer Giro ICC = 0.80, Segundo Giro ICC = 0.91 (Ev1) y Sentarse ICC = 0.73.

6.1.4 Biomarcadores cinemáticos: selección, estabilidad y relevancia clínica

El modelo permitió generar segmentaciones suficientemente precisas para extraer biomarcadores cinemáticos de alta resolución. A partir de un espacio de 270 características iniciales, el algoritmo RFE seleccionó 60 biomarcadores relevantes (10 por subetapa). Los rangos de los biomarcadores entre los grupos sanos resultaron cercanos entre sí, por lo que se vuelve especialmente valioso examinar múltiples biomarcadores en conjunto. Se observó que muchos de estos parámetros coinciden con aquellos identificados como clínicamente relevantes en estudios previos sobre la marcha y el equilibrio [46], [48], [84]. Aunque en todos los biomarcadores existe cierto grado de intersección entre los grupos, se observa que, a medida que aumenta la edad, los rangos se estrechan, particularmente en adultos mayores. Esto indica una menor variabilidad del movimiento [85], lo que permite caracterizar de manera más específica cada rango etario, favoreciendo la diferenciación entre grupos etarios para la comprensión del deterioro motor y la interpretación biomecánica del desempeño funcional.

En cuanto al análisis de estabilidad, los resultados mostraron que las seis primeras características seleccionadas presentaron una alta consistencia (>80% de estabilidad), mientras que las cuatro restantes exhibieron una estabilidad moderada (60–80%). Este patrón evidencia la presencia de un grupo de biomarcadores altamente discriminativos, complementado por un conjunto de

características secundarias que, si bien aportan información relevante para la clasificación y el análisis clínico, presentan una variabilidad ligeramente mayor.

Entre los más frecuentes se encontraron magnitudes asociadas a:

- velocidad angular (p. ej., V_y max, V_x p-p)
- aceleraciones (p. ej., A_x rms, A_y std, A_z std)
- ángulos de navegación (p. ej., Yaw std, Pitch max, Pitch p-p)

Se observó que las etapas de giro (Primer Giro y Segundo Giro) concentraron la mayor proporción de biomarcadores de alta confianza (>80%), lo que coincide con su sensibilidad funcional para detectar alteraciones motoras [86], [87]

En cuanto al poder discriminativo, los biomarcadores alcanzaron valores de AUC superiores a 0.75 en el 100% de las comparaciones entre grupos. Destaca un AUC de 0.98 en la etapa de Segundo Giro al comparar adultos jóvenes con el grupo patológico, resultado que evidencia la fuerte capacidad de estos parámetros para identificar disfunción motora [86]. En contraste, la menor discriminación se observó en Pararse al comparar jóvenes y adultos (AUC = 0.78), consistente con la literatura que describe esta fase como menos sensible al deterioro leve [88].

6.1.5 Diferencias en la duración de las subetapas entre grupos

El análisis no paramétrico mediante la prueba de Kruskal–Wallis reveló diferencias significativas entre los grupos etarios y clínicos en todas las fases del TUG ($p < 0.001$). Las medianas muestran una progresión funcional coherente, evidenciando un aumento sistemático en la duración de cada subetapa desde los participantes jóvenes hasta el grupo clínico. Por ejemplo, en la fase Pararse, las medianas fueron de 1.89 s en jóvenes, 2.17 s en adultos, 2.42 s en adultos mayores y 3.57 s en el grupo clínico.

Un patrón similar se observa en Caminar Ida (1.49 s en jóvenes, 1.79 s en adultos, 2.18 s en adultos mayores y 3.01 s en clínicos), en Primer Giro (1.51 s, 1.56 s, 1.64 s y 2.58 s, respectivamente) y en Caminar Vuelta (1.01 s, 1.14 s, 1.29 s y 2.02 s, respectivamente). Estas diferencias reflejan que

el TUG es altamente sensible para detectar alteraciones funcionales asociadas al envejecimiento y la patología, incluso utilizando una única IMU ubicada en la región lumbar.

El análisis post-hoc mostró que el grupo clínico difiere sistemáticamente de los grupos sanos ($p < 0.001$ en la mayoría de las comparaciones). Asimismo, se observaron aumentos graduales con la edad, especialmente en Caminata Ida y Caminar Vuelta, lo que refleja la disminución progresiva del control motor [19], [79].

6.1.6 Establecimiento de rangos de normalidad

Se generaron un total de 180 rangos percentiles (2.5–97.5) correspondientes a los 60 biomarcadores calculados para los tres grupos etarios. Un ejemplo representativo es el biomarcador a_x rms durante la fase de Primer Giro, donde los jóvenes presentan un rango de [0.13 – 0.31] con una media de 0.21 ± 0.05 , los adultos muestran un rango de [0.13 – 0.26], y los adultos mayores un rango de [0.11 – 0.24] con una media de 0.16 ± 0.03 . Estos rangos permiten contextualizar valores individuales en relación con la edad y resultan útiles para apoyar procesos de evaluación funcional y seguimiento rehabilitador. Además, solo el 53.9% de las distribuciones de biomarcadores presentó normalidad según la prueba de Shapiro–Wilk, lo que respalda la elección de métodos no paramétricos para los análisis estadísticos realizados.

6.1.7 Tendencias de los biomarcadores con la edad

El análisis reveló que el 51.7% de los biomarcadores cinemáticos (31 de 60) presentaron correlaciones significativas con la edad, demostrando una influencia del envejecimiento en la ejecución del test TUG. Lo cual respalda que los cambios en la movilidad asociados a la edad pueden cuantificarse objetivamente mediante parámetros cinemáticos [54], [64].

La etapa de Caminar Vuelta emergió como la más sensible a los cambios etarios, con el biomarcador vy_{rms} explicando el 28.0% de su variabilidad mediante la relación con la edad ($R^2 = 0.280$). Esta predominancia sugiere que el retorno durante el TUG representa un desafío motor

particularmente del envejecimiento, posiblemente debido a la combinación de fatiga acumulada y requerimientos de estabilidad dinámica [88], [89].

El análisis de los 10 biomarcadores más significativos en este aspecto (Tabla XI) revela el predominio de correlaciones negativas (9 de los 10 biomarcadores) muestran tendencias decrecientes con la edad, indicando una reducción generalizada en la amplitud y variabilidad del movimiento [53], [85].

La consistencia de estas tendencias entre distintas etapas del TUG respalda la utilidad del análisis cinemático completo para caracterizar el envejecimiento motor, superando las limitaciones de las medidas temporales tradicionales.

6.2. Limitaciones

A pesar de los resultados positivos, este estudio presenta limitaciones que deben considerarse al interpretar los hallazgos y proyectar futuras investigaciones.

En primer lugar, existe un solapamiento entre subetapas del TUG, especialmente entre el segundo giro y la fase de sentarse, donde los patrones biomecánicos presentan similitudes que generan ambigüedad tanto para el algoritmo como para los evaluadores humanos. Este solapamiento contribuye a los mayores niveles de error observados en estas fases.

Por otra parte, el conjunto de datos utilizado fue limitado y mostró una distribución heterogénea. Si bien incluyó participantes de diversas edades y condiciones, el número de sujetos con disfunción fue menor respecto del grupo sano, lo que podría afectar la capacidad de generalización del modelo hacia poblaciones con alteraciones motoras más marcadas. Asimismo, el grupo de participantes con patologías reunió condiciones neurológicas y musculoesqueléticas de naturaleza distinta, cada una con manifestaciones biomecánicas particulares. Esta heterogeneidad introduce una variabilidad funcional elevada, lo que restringe la extrapolación de los resultados y posiciona el análisis para este grupo como esencialmente exploratorio, orientado a evaluar el desempeño del modelo bajo patrones de marcha no normativos y no a establecer conclusiones específicas para cada diagnóstico.

A esto se suma que el etiquetado manual se realizó únicamente a partir de señales inerciales, sin referencia inicial a video; si bien la validación clínica mostró alta concordancia, contar con un ground truth multimodal más robusto podría mejorar el desempeño del modelo.

Finalmente, aunque el modelo BiLSTM obtuvo resultados adecuados, no se exploraron arquitecturas más avanzadas como Transformers temporales, modelos híbridos CNN-LSTM o enfoques autorregresivos, que podrían ofrecer mejoras adicionales en la segmentación.

6.3. Conclusión

Este trabajo desarrolló y validó un modelo de segmentación automática del test Timed Up and Go (TUG) basado en un modelo BiLSTM y señales provenientes de una única unidad de medición inercial (IMU) ubicada en la región lumbar. Los principales hallazgos permiten concluir que el enfoque propuesto constituye una herramienta robusta para la evaluación funcional del movimiento humano en contextos clínicos y de investigación.

En primer lugar, El modelo BiLSTM demostró un desempeño técnico excepcional, con métricas de precisión, sensibilidad y F1-score superiores al 90% para la mayoría de las subetapas, alcanzando valores de hasta 0.96 en fases de marcha. Fundamentalmente, los errores temporales (MAE entre 0.28 y 0.40 segundos) se sitúan dentro del margen de error de la evaluación humana manual (aproximadamente 0.2–0.3 s por tiempo de reacción) y fueron validados contra captura de movimiento OptiTrack, mostrando una confiabilidad inter-evaluador excelente (ICC: 0.78–0.99). La comparación directa con clínicos expertos reveló que la discrepancia algoritmo-evaluador (MAE: 0.33–0.39 s en fases de marcha) es comparable a la variabilidad inter-evaluador (0.288–0.372 s), respaldando su validez clínica y fiabilidad como herramienta objetiva.

En segundo lugar, la segmentación automática permitió la extracción confiable de 60 biomarcadores cinemáticos seleccionados mediante RFE, con una estabilidad del 79% y un alto poder discriminativo entre grupos etarios. Los biomarcadores mostraron valores de AUC superiores a 0.75 en todas las comparaciones, alcanzando un máximo de 0.98 en la etapa de Segundo Giro al diferenciar sujetos jóvenes de pacientes con disfunción.

Finalmente, el análisis de normalidad, rangos de referencia y correlaciones con la edad demostró que los biomarcadores derivados capturan diferencias asociadas a tendencias relacionadas con el envejecimiento. Esto posiciona al enfoque propuesto como una herramienta relevante para evaluación clínica, monitoreo longitudinal y detección temprana de deterioro funcional.

6.4. Trabajo Futuro

Un primer aspecto relevante para trabajo futuro es la incorporación de un número significativamente mayor de participantes que presenten condiciones clínicas o características funcionales específicas, recolectando grandes conjuntos de datos etiquetados por grupo. Por ejemplo, disponer de cohortes amplias y bien caracterizadas de personas con Traumatismo Encéfalo Craneano (TEC), Enfermedad de Parkinson, accidente cerebrovascular, neuropatías periféricas, artrosis de cadera o rodilla, esclerosis múltiple u otras alteraciones neuromusculares permitiría entrenar y evaluar el modelo de manera más robusta dentro de cada condición. Asimismo, incluir poblaciones que puedan presentar características funcionales particulares, como personas con síndrome de Down, individuos con obesidad, adultos con síndrome de fragilidad, ampliaría el espectro de patrones de marcha analizados y permitiría identificar biomarcadores sensibles a diferencias fenotípicas no estrictamente patológicas.

Otra dirección prometedora es la implementación de modelos avanzados basados en LLM y arquitecturas multimodales, capaces de combinar información temporal, biomecánica y contextual para interpretar de manera más profunda lo que ocurre durante cada etapa del TUG. Este tipo de modelos, que integran señales inerciales con descripciones generadas o inferencias de alto nivel, permitiría explicar en el momento de la evaluación, el significado funcional de los patrones detectados, identificar compensaciones motoras sutiles y traducirlo en texto para una interpretación clínica. Estas capacidades podrían transformar el sistema en una herramienta más interpretativa y explicativa, acercándolo a escenarios de apoyo experto en rehabilitación y evaluación funcional.

De igual manera, estudiar la evolución temporal de los biomarcadores mediante análisis longitudinales permitiría determinar si estos indicadores son capaces de detectar cambios progresivos

tempranos, lo cual sería valioso para la prevención de caídas o la evaluación de la eficacia de intervenciones de rehabilitación.

Finalmente, se vuelve fundamental avanzar hacia la validación del sistema en contextos clínicos reales. Su aplicación en hospitales, centros de rehabilitación, unidades de evaluación geriátrica e incluso en entornos domiciliarios permitiría obtener evidencia externa adicional sobre su validez ecológica y su utilidad práctica en escenarios cotidianos de atención en salud. Esta validación ampliada contribuiría a garantizar que el sistema funcione de manera robusta, confiable y consistente en las condiciones reales donde será utilizado.

Capítulo 7. Envío Artículo Científico

Los resultados de esta tesis fueron enviados a la revista indexada en Web of Science: IEEE Transactions on Neural Systems and Rehabilitation Engineering (TNSRE), bajo el artículo titulado “BiLSTM Segmentation of TUG Subtasks Across Healthy and Pathological Populations Using a Single IMU”.

Capítulo 8. Glosario

TUG	: Prueba de Levantarse y Andar, en inglés, Timed Up and Go.
iTUG	: Instrumented Timed Up and Go.
STS	: Transferencia sedente-bípedo, en inglés, Sit-to-Stand.
IMU	: Unidad de Medición Inercial, en inglés, Inertial Measurement Unit.
MOCAP	: Captura de Movimiento, en inglés, Motion Capture.
RNN	: Red Neuronal Recurrente, en inglés, Recurrent Neural Network.
LSTM	: Memoria bilateral a corto y largo plazo, en inglés, Long Short-Term Memory.
BiLSTM	: Memoria bilateral a corto y largo plazo, en inglés, Bilateral Long Short-Term Memory.
RMS	: Valor eficaz, en inglés, Root Mean Square Value.
SD	: Desviación estándar, en inglés, Standard Deviation.
BM	: Biomarcador, en inglés, Biomarker.

Capítulo 9. Referencias

- [1] S. I. Sharif, A. B. Al-Harbi, A. M. Al-Shihabi, D. S. Al-Daour, y R. S. Sharif, «Falls in the elderly: assessment of prevalence and risk factors», *Pharm Pract (Granada)*, vol. 16, n.º 3, p. 1206, 2018, doi: 10.18549/PharmPract.2018.03.1206.
- [2] T. C. T. Mak, T. W. L. Wong, y S. S. M. Ng, «Visual-related training to improve balance and walking ability in older adults: A systematic review», *Exp Gerontol*, vol. 156, p. 111612, dic. 2021, doi: 10.1016/j.exger.2021.111612.
- [3] P. Ea y R. K, «Fall Prevention in Community-Dwelling Older Adults», *Annals of internal medicine*, vol. 169, n.º 11, abr. 2018, doi: 10.7326/AITC201812040.
- [4] A. F. Ambrose, G. Paul, y J. M. Hausdorff, «Risk factors for falls among older adults: a review of the literature», *Maturitas*, vol. 75, n.º 1, pp. 51-61, may 2013, doi: 10.1016/j.maturitas.2013.02.009.
- [5] S.-H. Park, «Tools for assessing fall risk in the elderly: a systematic review and meta-analysis», *Aging Clin Exp Res*, vol. 30, n.º 1, pp. 1-16, ene. 2018, doi: 10.1007/s40520-017-0749-0.
- [6] N. R. Marques, D. H. Spinoso, B. C. Cardoso, V. C. Moreno, M. H. Kuroda, y M. T. Navega, «Is it possible to predict falls in older adults using gait kinematics?», *Clin Biomech (Bristol, Avon)*, vol. 59, pp. 15-18, nov. 2018, doi: 10.1016/j.clinbiomech.2018.08.006.
- [7] E. Zasadzka, A. M. Borowicz, M. Roszak, y M. Pawlaczyk, «Assessment of the risk of falling with the use of timed up and go test in the elderly with lower extremity osteoarthritis», *Clin Interv Aging*, vol. 10, pp. 1289-1298, 2015, doi: 10.2147/CIA.S86001.
- [8] C. U. Persson, A. Danielsson, K. S. Sunnerhagen, A. Grimby-Ekman, y P.-O. Hansson, «Timed Up & Go as a measure for longitudinal change in mobility after stroke - Postural Stroke Study in Gothenburg (POSTGOT)», *J Neuroeng Rehabil*, vol. 11, p. 83, may 2014, doi: 10.1186/1743-0003-11-83.
- [9] J. Beyea, C. A. McGibbon, A. Sexton, J. Noble, y C. O'Connell, «Convergent Validity of a Wearable Sensor System for Measuring Sub-Task Performance during the Timed Up-and-Go Test», *Sensors (Basel)*, vol. 17, n.º 4, p. 934, abr. 2017, doi: 10.3390/s17040934.
- [10] H. Nguyen, K. Lebel, P. Boissy, S. Bogard, E. Goubault, y C. Duval, «Auto detection and segmentation of daily living activities during a Timed Up and Go task in people with Parkinson's disease using multiple inertial sensors», *J Neuroeng Rehabil*, vol. 14, p. 26, abr. 2017, doi: 10.1186/s12984-017-0241-2.
- [11] «Instrumented Timed Up and Go Test (iTUG)—More Than Assessing Time to Predict Falls: A Systematic Review». Accedido: 8 de octubre de 2024. [En línea]. Disponible en: <https://www.mdpi.com/1424-8220/23/7/3426>
- [12] S. Mathias, U. S. Nayak, y B. Isaacs, «Balance in elderly patients: the "get-up and go" test», *Arch Phys Med Rehabil*, vol. 67, n.º 6, pp. 387-389, jun. 1986.
- [13] D. Podsiadlo y S. Richardson, «The timed "Up & Go": a test of basic functional mobility for frail elderly persons», *J Am Geriatr Soc*, vol. 39, n.º 2, pp. 142-148, feb. 1991, doi: 10.1111/j.1532-5415.1991.tb01616.x.
- [14] E. Mancilla S, J. Valenzuela H, y M. Escobar C, «Rendimiento en las pruebas "Timed Up and Go" y "Estación Unipodal" en adultos mayores chilenos entre 60 y 89 años», *Revista médica de Chile*, vol. 143, n.º 1, pp. 39-46, ene. 2015, doi: 10.4067/S0034-98872015000100005.
- [15] E. E. Stone y M. Skubic, «Mapping Kinect-based in-home gait speed to TUG time: A methodology to facilitate clinical interpretation», en *2013 7th International Conference on Pervasive Computing Technologies for Healthcare and Workshops*, may 2013, pp. 57-64. doi: 10.4108/icst.pervasivehealth.2013.252097.

- [16] P. Ortega-Bastidas *et al.*, «Post-Stroke Balance Impairments Assessment: Clinical Scales and Current Technologies», en *Post-Stroke Rehabilitation*, IntechOpen, 2022. doi: 10.5772/intechopen.101984.
- [17] E. Rolenz y J. C. Reneker, «Validity of the 8-Foot Up and Go, Timed Up and Go, and Activities-Specific Balance Confidence Scale in older adults with and without cognitive impairment», *J Rehabil Res Dev*, vol. 53, n.º 4, pp. 511-518, 2016, doi: 10.1682/JRRD.2015.03.0042.
- [18] J. H. Ansai, L. P. de Andrade, T. H. Nakagawa, y J. R. Rebelatto, «Performances on the Timed Up and Go Test and subtasks between fallers and non-fallers in older adults with cognitive impairment», *Arq Neuropsiquiatr*, vol. 76, n.º 6, pp. 381-386, jun. 2018, doi: 10.1590/0004-282X20180055.
- [19] Q. Mao, J. Zhang, L. Yu, Y. Zhao, Y. Luximon, y H. Wang, «Effectiveness of sensor-based interventions in improving gait and balance performance in older adults: systematic review and meta-analysis of randomized controlled trials», *J Neuroeng Rehabil*, vol. 21, n.º 1, p. 85, may 2024, doi: 10.1186/s12984-024-01375-0.
- [20] M. Moreno-Verdú, M. D. R. Ferreira-Sánchez, P. Martín-Casas, y M. Á. Atín-Arratibel, «Imagined Timed Up and Go test (iTUG) in people with Parkinson's Disease: test-retest reliability and validity», *Disabil Rehabil*, pp. 1-11, mar. 2023, doi: 10.1080/09638288.2023.2185688.
- [21] M. Cosetti, L. Arie, J. Kelly, J. Ren, y A. V. Lubetzky, «Dual task iTUG to investigate increased fall risk among older adults with bilateral hearing loss», *Am J Otolaryngol*, vol. 46, n.º 1, p. 104536, dic. 2024, doi: 10.1016/j.amjoto.2024.104536.
- [22] A. M. Shkel y Y. Wang, «Inertial Sensors and Inertial Measurement Units», en *Pedestrian Inertial Navigation with Self-Contained Aiding*, IEEE, 2021, pp. 17-36. doi: 10.1002/9781119699910.ch2.
- [23] A. M. Shkel y Y. Wang, *Pedestrian Inertial Navigation with Self-Contained Aiding*, 1.^a ed. Wiley, 2021. doi: 10.1002/9781119699910.
- [24] W. Niswander y K. Kontson, «Evaluating the Impact of IMU Sensor Location and Walking Task on Accuracy of Gait Event Detection Algorithms», *Sensors*, vol. 21, n.º 12, Art. n.º 12, ene. 2021, doi: 10.3390/s21123989.
- [25] M. Kozlovsky, P. Bogdanov, K. Karóckai, G. Garaguly, y G. Kronreif, «IMU based human movement tracking», en *2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, may 2018, pp. 0240-0244. doi: 10.23919/MIPRO.2018.8400045.
- [26] R. Bergquist *et al.*, «Predicting Advanced Balance Ability and Mobility with an Instrumented Timed Up and Go Test», *Sensors*, vol. 20, n.º 17, Art. n.º 17, ene. 2020, doi: 10.3390/s20174987.
- [27] A. Leardini, F. Biagi, A. Merlo, C. Belvedere, y M. G. Benedetti, «Multi-segment trunk kinematics during locomotion and elementary exercises», *Clin Biomech (Bristol)*, vol. 26, n.º 6, pp. 562-571, jul. 2011, doi: 10.1016/j.clinbiomech.2011.01.015.
- [28] C. Amici, F. Ragni, M. Tiboni, J. Pollet, y R. Buraschi, «Quantitative Kinematic Assessment of the Sit-to-Stand Transition using an IMU Sensor», en *2021 24th International Conference on Mechatronics Technology (ICMT)*, dic. 2021, pp. 1-6. doi: 10.1109/ICMT53429.2021.9687250.
- [29] R. C. Van Lummel *et al.*, «Intra-Rater, Inter-Rater and Test-Retest Reliability of an Instrumented Timed Up and Go (iTUG) Test in Patients with Parkinson's Disease», *PLoS ONE*, vol. 11, n.º 3, p. e0151881, mar. 2016, doi: 10.1371/journal.pone.0151881.
- [30] A. Cappozzo, U. Della Croce, A. Leardini, y L. Chiari, «Human movement analysis using stereophotogrammetry. Part 1: theoretical background», *Gait Posture*, vol. 21, n.º 2, pp. 186-196, feb. 2005, doi: 10.1016/j.gaitpost.2004.01.010.

- [31] A. Dubois y J.-P. Bresciani, «Validation of an ambient system for the measurement of gait parameters», *J Biomech*, vol. 69, pp. 175-180, mar. 2018, doi: 10.1016/j.jbiomech.2018.01.024.
- [32] «Motion Capture Systems», OptiTrack. Accedido: 11 de octubre de 2024. [En línea]. Disponible en: <http://optitrack.com/index.html>
- [33] «Application of OptiTrack motion capture systems in human movement analysis A systematic literature review», ResearchGate. Accedido: 18 de noviembre de 2024. [En línea]. Disponible en: https://www.researchgate.net/publication/326168325_Application_of_OptiTrack_motion_capture_systems_in_human_movement_analysis_A_systematic_literature_review
- [34] «Motive - In Depth», OptiTrack. Accedido: 18 de noviembre de 2024. [En línea]. Disponible en: <http://www.optitrack.com/software/motive/index.html>
- [35] I. H. Sarker, «Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions», *SN COMPUT. SCI.*, vol. 2, n.º 6, p. 420, ago. 2021, doi: 10.1007/s42979-021-00815-1.
- [36] I. D. Mienye y T. G. Swart, «A Comprehensive Review of Deep Learning: Architectures, Recent Advances, and Applications», *Information*, vol. 15, n.º 12, p. 755, dic. 2024, doi: 10.3390/info15120755.
- [37] J. Maiora, C. Rezola-Pardo, G. García, B. Sanz, y M. Graña, «Older Adult Fall Risk Prediction with Deep Learning and Timed Up and Go (TUG) Test Data», *Bioengineering*, vol. 11, n.º 10, Art. n.º 10, oct. 2024, doi: 10.3390/bioengineering11101000.
- [38] Y. Choi, Y. Bae, B. Cha, y J. Ryu, «Deep Learning-Based Subtask Segmentation of Timed Up-and-Go Test Using RGB-D Cameras», *Sensors*, vol. 22, n.º 17, Art. n.º 17, ene. 2022, doi: 10.3390/s22176323.
- [39] I. D. Mienye, T. G. Swart, y G. Obaido, «Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications», *Information*, vol. 15, n.º 9, p. 517, sep. 2024, doi: 10.3390/info15090517.
- [40] X. Wu, B. Xiang, H. Lu, C. Li, X. Huang, y W. Huang, «Optimizing Recurrent Neural Networks: A Study on Gradient Normalization of Weights for Enhanced Training Efficiency», *Applied Sciences*, vol. 14, n.º 15, p. 6578, ene. 2024, doi: 10.3390/app14156578.
- [41] S.-H. Noh, «Analysis of Gradient Vanishing of RNNs and Performance Comparison», *Information*, vol. 12, n.º 11, p. 442, nov. 2021, doi: 10.3390/info12110442.
- [42] S. M. Al-Selwi *et al.*, «RNN-LSTM: From applications to modeling techniques and beyond—Systematic review», *Journal of King Saud University - Computer and Information Sciences*, vol. 36, n.º 5, p. 102068, jun. 2024, doi: 10.1016/j.jksuci.2024.102068.
- [43] Y. Fan, Q. Tang, Y. Guo, y Y. Wei, «BiLSTM-MLAM: A Multi-Scale Time Series Prediction Model for Sensor Data Based on Bi-LSTM and Local Attention Mechanisms», *Sensors*, vol. 24, n.º 12, p. 3962, ene. 2024, doi: 10.3390/s24123962.
- [44] «Bidirectional Long Short-Term Memory Network - an overview | ScienceDirect Topics». Accedido: 9 de octubre de 2025. [En línea]. Disponible en: <https://www.sciencedirect.com/topics/computer-science/bidirectional-long-short-term-memory-network>
- [45] S. Vasudevan, A. Saha, M. E. Tarver, y B. Patel, «Digital biomarkers: Convergence of digital health technologies and biomarkers», *npj Digit. Med.*, vol. 5, n.º 1, p. 36, mar. 2022, doi: 10.1038/s41746-022-00583-z.
- [46] C. Polvorinos-Fernández *et al.*, «Evaluating Motor Symptoms in Parkinson's Disease Through Wearable Sensors: A Systematic Review of Digital Biomarkers», *Applied Sciences*, vol. 14, n.º 22, p. 10189, ene. 2024, doi: 10.3390/app142210189.

- [47] A. Weiss *et al.*, «Transition between the Timed Up and Go turn to sit subtasks: Is timing everything?», *J Am Med Dir Assoc*, vol. 17, n.º 9, p. 864.e9-864.e15, sep. 2016, doi: 10.1016/j.jamda.2016.06.025.
- [48] D. Naito, K. Honda, Y. Sekiguchi, S.-I. Izumi, y S. Ebihara, «Characteristics of Trunk Acceleration and Angular Velocity in Turning Movement in Post-Stroke Patients with High Risk of Falling», *Sensors*, vol. 25, n.º 9, p. 2689, abr. 2025, doi: 10.3390/s25092689.
- [49] P. Ortega-Bastidas, P. Aqueveque, B. Gómez, F. Saavedra, y R. Cano-de-la-Cuerda, «Use of a Single Wireless IMU for the Segmentation and Automatic Analysis of Activities Performed in the 3-m Timed Up & Go Test», *Sensors (Basel)*, vol. 19, n.º 7, p. 1647, abr. 2019, doi: 10.3390/s19071647.
- [50] Z. Yang, C. Song, F. Lin, J. Langan, y W. Xu, «A Smart Environment-Adapting Timed-Up-and-Go System Powered by Sensor-Embedded Insoles», *IEEE Internet Things J.*, vol. 6, n.º 2, pp. 1298-1305, abr. 2019, doi: 10.1109/JIOT.2018.2844837.
- [51] B. A. Gómez Arias, «Desarrollo e implementación de una estrategia para la evaluación automática del riesgo de caídas en personas usando sensores inerciales.», 2021, Accedido: 9 de octubre de 2024. [En línea]. Disponible en: <https://repositorio.udec.cl/handle/11594/8893>
- [52] R. Romijnders, E. Warmerdam, C. Hansen, J. Welzel, G. Schmidt, y W. Maetzler, «Validation of IMU-based gait event detection during curved walking and turning in older adults and Parkinson's Disease patients», *Journal of NeuroEngineering and Rehabilitation*, vol. 18, n.º 1, p. 28, feb. 2021, doi: 10.1186/s12984-021-00828-0.
- [53] N. Haji Ghassemi *et al.*, «Segmentation of Gait Sequences in Sensor-Based Movement Analysis: A Comparison of Methods in Parkinson's Disease», *Sensors*, vol. 18, n.º 1, Art. n.º 1, ene. 2018, doi: 10.3390/s18010145.
- [54] C.-Y. Hsieh, H.-Y. Huang, K.-C. Liu, K.-H. Chen, S. J.-P. Hsu, y C.-T. Chan, «Subtask Segmentation of Timed Up and Go Test for Mobility Assessment of Perioperative Total Knee Arthroplasty», *Sensors*, vol. 20, n.º 21, Art. n.º 21, ene. 2020, doi: 10.3390/s20216302.
- [55] T. Kamnardsiri *et al.*, «Conventional video-based system for measuring the subtask speed of the Timed Up and Go Test in older adults: Validity and reliability study», *PLOS ONE*, vol. 18, n.º 6, p. e0286574, jun. 2023, doi: 10.1371/journal.pone.0286574.
- [56] A. L. McCreath Frangakis, E. D. Lemaire, H. Burger, y N. Baddour, «L Test Subtask Segmentation for Lower-Limb Amputees Using a Random Forest Algorithm», *Sensors*, vol. 24, n.º 15, Art. n.º 15, ene. 2024, doi: 10.3390/s24154953.
- [57] V. Cimolin *et al.*, «Do wearable sensors add meaningful information to the Timed Up and Go test? A study on obese women», *Journal of Electromyography and Kinesiology*, vol. 44, pp. 78-85, feb. 2019, doi: 10.1016/j.jelekin.2018.12.001.
- [58] A. Atrsaei *et al.*, «Postural transitions detection and characterization in healthy and patient populations using a single waist sensor», *Journal of NeuroEngineering and Rehabilitation*, vol. 17, n.º 1, p. 70, jun. 2020, doi: 10.1186/s12984-020-00692-4.
- [59] N. A. Zakaria, Y. Kuwae, T. Tamura, K. Minato, y S. Kanaya, «Quantitative analysis of fall risk using TUG test», *Computer Methods in Biomechanics and Biomedical Engineering*, vol. 18, n.º 4, pp. 426-437, mar. 2015, doi: 10.1080/10255842.2013.805211.
- [60] Barry. R. Greene, A. O'Donovan, R. Romero-Ortuno, L. Cogan, C. N. Scanaill, y R. A. Kenny, «Quantitative Falls Risk Assessment Using the Timed Up and Go Test», *IEEE Trans. Biomed. Eng.*, vol. 57, n.º 12, pp. 2918-2926, dic. 2010, doi: 10.1109/TBME.2010.2083659.
- [61] A. Weiss, T. Herman, M. Plotnik, M. Brozgol, N. Giladi, y J. M. Hausdorff, «An instrumented timed up and go: the added value of an accelerometer for identifying fall risk in idiopathic fallers», *Physiol. Meas.*, vol. 32, n.º 12, pp. 2003-2018, dic. 2011, doi: 10.1088/0967-3334/32/12/009.

- [62] M. Abdollahi, P. M. Kuber, M. Shiraishi, R. Soangra, y E. Rashedi, «Kinematic Analysis of 360° Turning in Stroke Survivors Using Wearable Motion Sensors», *Sensors*, vol. 22, n.º 1, p. 385, ene. 2022, doi: 10.3390/s22010385.
- [63] R. P. Matthew, S. Seko, y R. Bajcsy, «Fusing motion-capture and inertial measurements for improved joint state recovery: An application for sit-to-stand actions», en *2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Seogwipo: IEEE, jul. 2017, pp. 1893-1896. doi: 10.1109/EMBC.2017.8037217.
- [64] M. Bertoli, A. Cereatti, U. Della Croce, y M. Mancini, «An objective assessment to investigate the impact of turning angle on freezing of gait in Parkinson's disease», en *2017 IEEE Biomedical Circuits and Systems Conference (BioCAS)*, Torino: IEEE, oct. 2017, pp. 1-4. doi: 10.1109/BIOCAS.2017.8325122.
- [65] M. A. Newman *et al.*, «Use of an instrumented dual-task timed up and go test in children with traumatic brain injury», *Gait & Posture*, vol. 76, pp. 193-197, feb. 2020, doi: 10.1016/j.gaitpost.2019.12.001.
- [66] M. Kowal *et al.*, «Functional Mobility Studies in Younger Adults: Instrumented Timed Up and Go (iTUG) Test Using Inertial Devices», *JCM*, vol. 14, n.º 6, p. 1944, mar. 2025, doi: 10.3390/jcm14061944.
- [67] S. Stuart *et al.*, «Analysis of Free-Living Mobility in People with Mild Traumatic Brain Injury and Healthy Controls: Quality over Quantity», *Journal of Neurotrauma*, vol. 37, n.º 1, pp. 139-145, ene. 2020, doi: 10.1089/neu.2019.6450.
- [68] F. Özden, İ. Uysal, İ. Tümtürk, y M. Özkeskin, «Investigation of Motor Activity, Movement Kinematics and Forward-Backwards Gait in Children with Cerebral Palsy», *Percept Mot Skills*, vol. 130, n.º 5, pp. 2000-2014, oct. 2023, doi: 10.1177/00315125231191152.
- [69] L. Donisi, A. Coccia, F. Amitrano, L. Mercogliano, G. Cesarelli, y G. D'Addio, «Backpack Influence on Kinematic Parameters related to Timed Up and Go (TUG) Test in School Children», en *2020 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, Bari, Italy: IEEE, jun. 2020, pp. 1-5. doi: 10.1109/MeMeA49120.2020.9137198.
- [70] B. M. Cornish *et al.*, «Sagittal plane knee kinematics can be measured during activities of daily living following total knee arthroplasty with two IMU», *PLoS ONE*, vol. 19, n.º 2, p. e0297899, feb. 2024, doi: 10.1371/journal.pone.0297899.
- [71] K. J. Kim, Y. Gimmon, J. Millar, K. Brewer, J. Serrador, y M. C. Schubert, «The Instrumented Timed "Up & Go" Test Distinguishes Turning Characteristics in Vestibular Hypofunction», *Physical Therapy*, vol. 101, n.º 7, p. pzab103, jul. 2021, doi: 10.1093/ptj/pzab103.
- [72] D. Jiménez, M. Lavados, P. Rojas, C. Henríquez, F. Silva, y M. Guillón, «Evaluación del minimal abreviado de la evaluación funcional del adulto mayor (EFAM) como screening para la detección de demencia en la atención primaria», *Rev. méd. Chile*, vol. 145, n.º 7, pp. 862-868, jul. 2017, doi: 10.4067/s0034-98872017000700862.
- [73] E. P. Washabaugh, T. Kalyanaraman, P. G. Adamczyk, E. S. Claflin, y C. Krishnan, «Validity and repeatability of inertial measurement units for measuring gait parameters», *Gait Posture*, vol. 55, pp. 87-93, jun. 2017, doi: 10.1016/j.gaitpost.2017.04.013.
- [74] B. E. Sibson, J. J. Banks, A. Yawar, A. K. Yegian, D. E. Anderson, y D. E. Lieberman, «Using inertial measurement units to estimate spine joint kinematics and kinetics during walking and running», *Sci Rep*, vol. 14, n.º 1, p. 234, ene. 2024, doi: 10.1038/s41598-023-50652-w.
- [75] L. V. Rojas Sandoval, «Evaluación crítica de Algoritmos de segmentación del test Timed Up and Go (TUG) basados en IMU.», Universidad de Concepción, 2025. Accedido: 10 de octubre de 2025. [En línea]. Disponible en: <https://repositorio.udec.cl/handle/11594/12939>

- [76] S. A. A. N. Bolink *et al.*, «Validity of an inertial measurement unit to assess pelvic orientation angles during gait, sit–stand transfers and step-up transfers: Comparison with an optoelectronic motion capture system*», *Medical Engineering & Physics*, vol. 38, n.º 3, pp. 225-231, mar. 2016, doi: 10.1016/j.medengphy.2015.11.009.
- [77] «Open Source Data Labeling», Label Studio. Accedido: 23 de octubre de 2025. [En línea]. Disponible en: <https://labelstud.io/>
- [78] C. Bonnyaud, D. Pradon, D. Bensmail, y N. Roche, «Dynamic Stability and Risk of Tripping during the Timed Up and Go Test in Hemiparetic and Healthy Subjects», *PLoS One*, vol. 10, n.º 10, p. e0140317, 2015, doi: 10.1371/journal.pone.0140317.
- [79] T. Nishi *et al.*, «Effects of Peripheral Vestibular Dysfunction on Dynamic Postural Stability Measured by the Functional Reach Test and Timed Up and Go Test», *Ann Otol Rhinol Laryngol*, vol. 126, n.º 6, pp. 438-444, jun. 2017, doi: 10.1177/0003489417700439.
- [80] K. Nishizawa *et al.*, «Turning and sitting movements during timed up and go tests predict deterioration of physical function in middle-aged adults», *Gait Posture*, vol. 108, pp. 329-334, feb. 2024, doi: 10.1016/j.gaitpost.2023.12.020.
- [81] J. Choi, S. M. Parker, B. A. Knarr, Y. Gwon, y J.-H. Youn, «Wearable Sensor-Based Prediction Model of Timed up and Go Test in Older Adults», *Sensors*, vol. 21, n.º 20, p. 6831, ene. 2021, doi: 10.3390/s21206831.
- [82] R. Romijnders, E. Warmerdam, C. Hansen, J. Welzel, G. Schmidt, y W. Maetzler, «Validation of IMU-based gait event detection during curved walking and turning in older adults and Parkinson's Disease patients», *Journal of NeuroEngineering and Rehabilitation*, vol. 18, n.º 1, p. 28, feb. 2021, doi: 10.1186/s12984-021-00828-0.
- [83] D. A. Faux y J. Godolphin, «Manual timing in physics experiments: Error and uncertainty», *American Journal of Physics*, vol. 87, n.º 2, pp. 110-115, feb. 2019, doi: 10.1119/1.5085437.
- [84] S. Tadano, R. Takeda, y H. Miyagawa, «Three Dimensional Gait Analysis Using Wearable Acceleration and Gyro Sensors Based on Quaternion Calculations», *Sensors*, vol. 13, n.º 7, Art. n.º 7, jul. 2013, doi: 10.3390/s130709321.
- [85] B. M. Kear, T. P. Guck, y A. L. McGaha, «Timed Up and Go (TUG) Test: Normative Reference Values for Ages 20 to 59 Years and Relationships With Physical and Mental Health Risk Factors», *J Prim Care Community Health*, vol. 8, n.º 1, pp. 9-13, ene. 2017, doi: 10.1177/2150131916659282.
- [86] A. L. Miri, L. Laskovski, M. E. B. Bueno, D. C. Rodrigues, F. A. Moura, y S. M. Smaili, «A biomechanical analysis of turning during gait in individuals with different subtypes of Parkinson's disease», *Clinical Biomechanics*, vol. 112, p. 106166, feb. 2024, doi: 10.1016/j.clinbiomech.2023.106166.
- [87] D. Conradsson, C. Paquette, y E. Franzén, «Turning Stability in Individuals With Parkinson Disease», *J Neurol Phys Ther*, vol. 42, n.º 4, pp. 241-247, oct. 2018, doi: 10.1097/NPT.0000000000000242.
- [88] X. Wang *et al.*, «Identifying sensors-based parameters associated with fall risk in community-dwelling older adults: an investigation and interpretation of discriminatory parameters», *BMC Geriatrics*, vol. 24, n.º 1, p. 125, feb. 2024, doi: 10.1186/s12877-024-04723-w.
- [89] P. Ortega-Bastidas, B. Gómez, P. Aqueveque, S. Luarte-Martínez, y R. Cano-de-la-Cuerda, «Instrumented Timed Up and Go Test (iTUG)—More Than Assessing Time to Predict Falls: A Systematic Review», *Sensors*, vol. 23, n.º 7, Art. n.º 7, ene. 2023, doi: 10.3390/s23073426.

Capítulo 10. ANEXOS

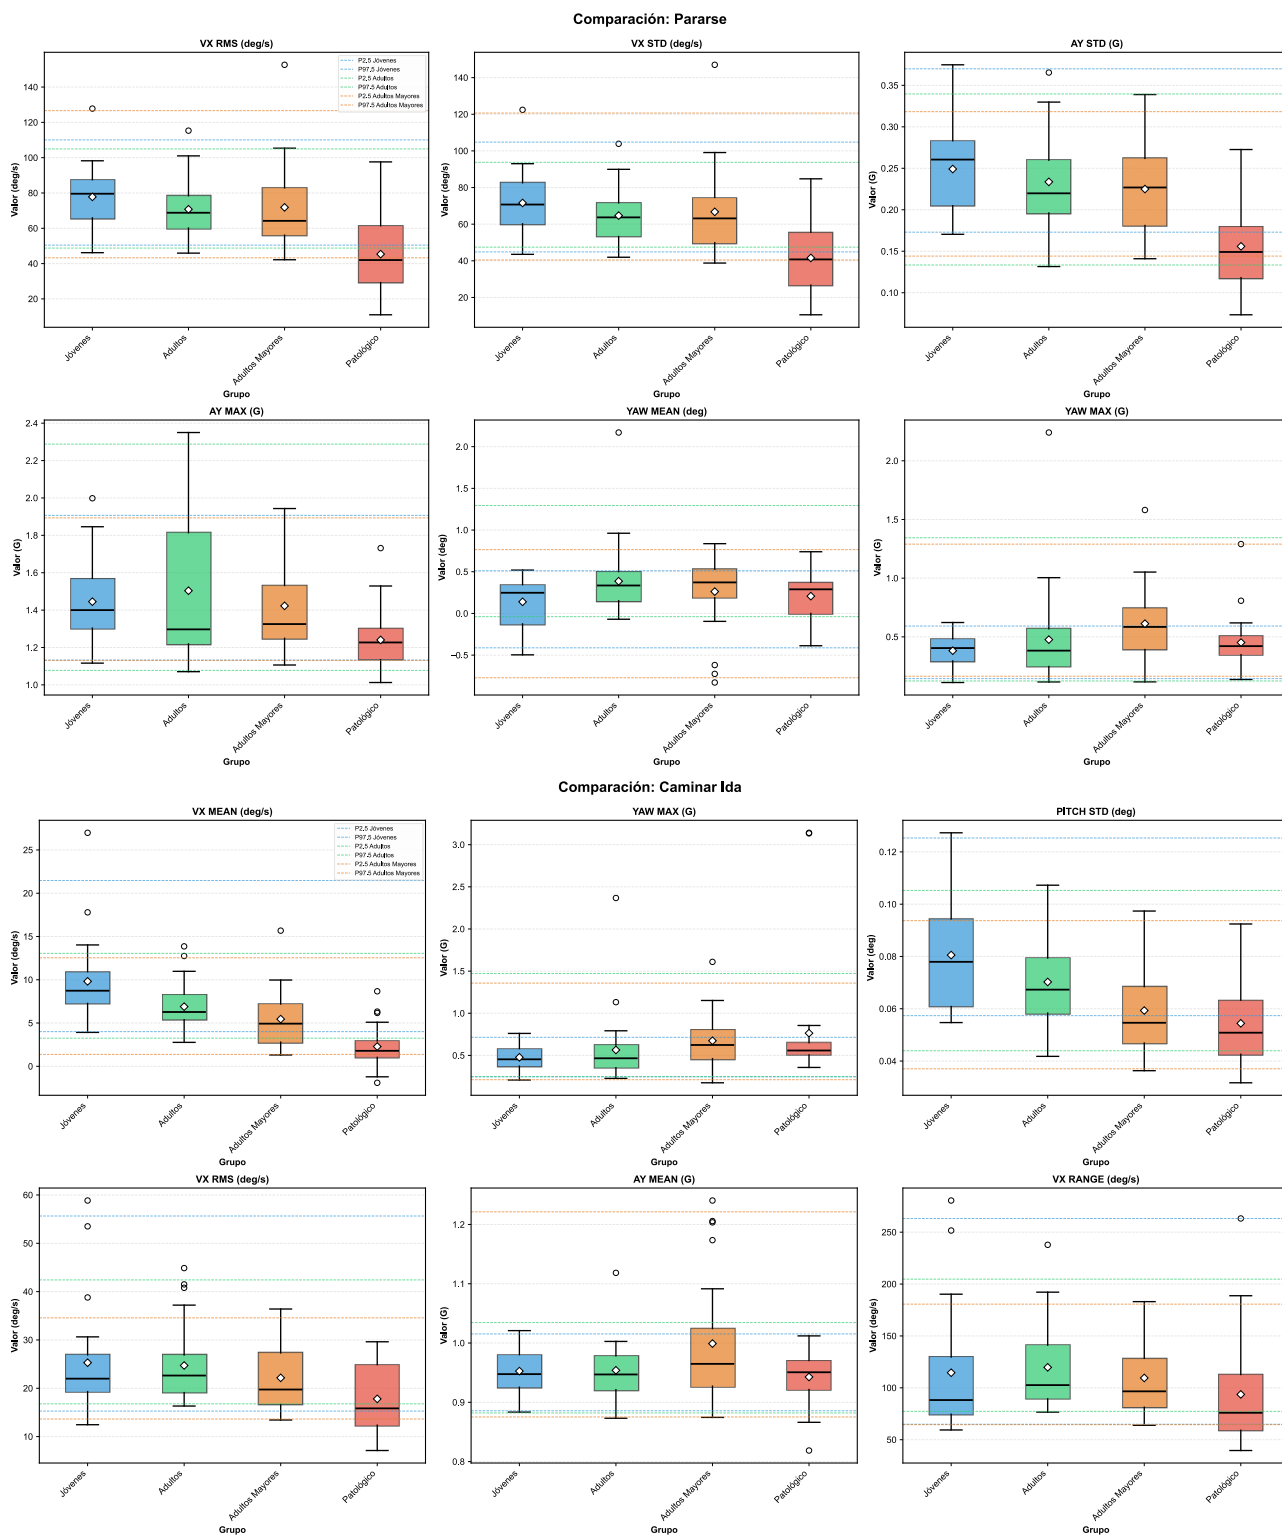
Anexo A: Rangos de referencia de Biomarcadores del iTUG

Tabla XII Rangos de referencia de Biomarcadores del iTUG según grupo etario

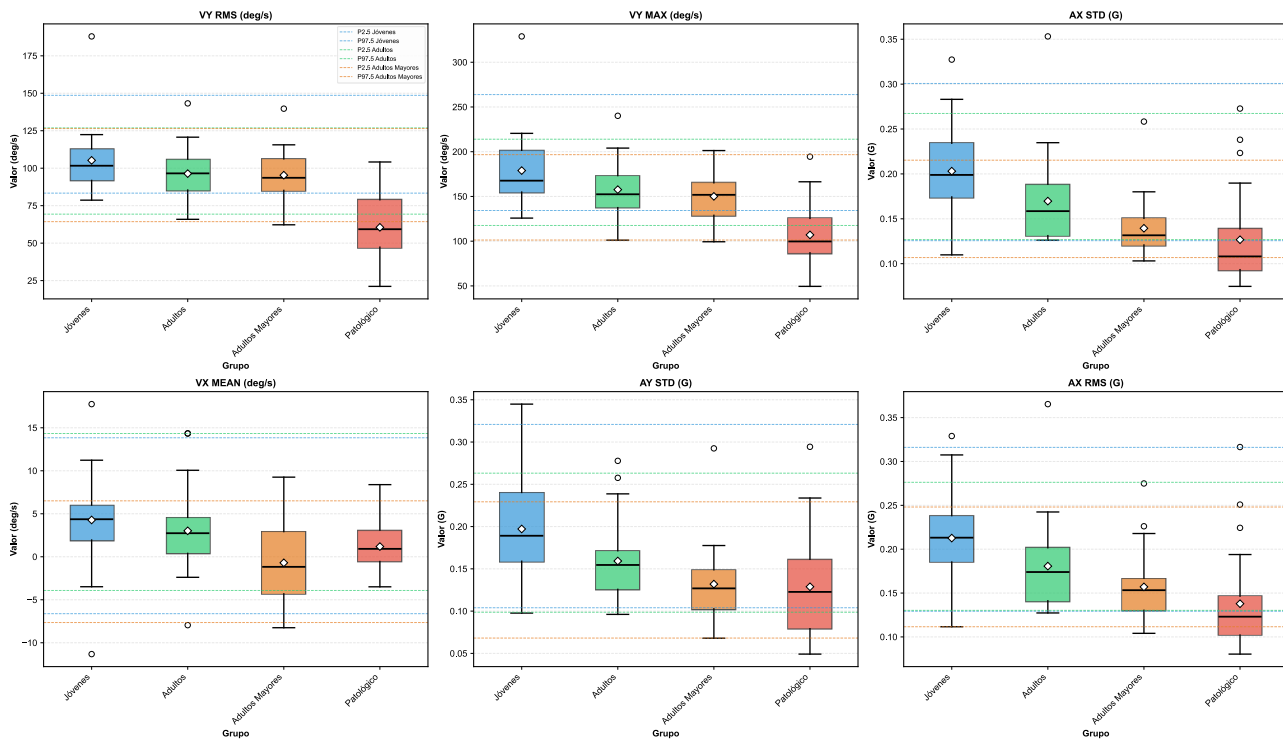
Biomarcador	Jóvenes		Adultos		Adulto Mayor	
	P_2.5	P_97.5	P_2.5	P_97.5	P_2.5	P_97.5
ax_range_Sentarse	0.242733	0.884533	0.209417	0.621467	0.162017	0.612133
ax_rms_Caminar Ida	0.114136	0.283233	0.098511	0.295103	0.115872	0.254459
ax_rms_Primer Giro	0.129261	0.316073	0.130273	0.276241	0.111596	0.248091
ax_rms_Segundo Giro	0.142896	0.340443	0.142152	0.28132	0.123201	0.251298
ax_std_Caminar Vuelta	0.107953	0.265149	0.109546	0.317343	0.109542	0.196541
ax_std_Primer Giro	0.12564	0.300758	0.126829	0.26733	0.106803	0.215262
ax_std_Segundo Giro	0.125147	0.338463	0.136237	0.275744	0.11719	0.248677
ay_max_Parse	1.132733	1.906933	1.077433	2.287892	1.1309	1.893283
ay_mean_Caminar Ida	0.885738	1.015328	0.882057	1.034507	0.875277	1.221333
ay_range_Caminar Ida	0.676067	1.861133	0.634983	1.870192	0.704617	1.34325
ay_range_Primer Giro	0.483267	1.7588	0.530633	1.472042	0.373583	1.219217
ay_rms_Caminar Vuelta	0.928831	1.042786	0.89524	1.057809	0.892565	1.2385
ay_rms_Primer Giro	0.941482	1.075145	0.902281	1.048331	0.882813	1.243529
ay_std_Caminar Vuelta	0.143452	0.338878	0.125061	0.309663	0.117635	0.255393
ay_std_Parse	0.172985	0.369934	0.133383	0.339603	0.144166	0.318274
ay_std_Primer Giro	0.103972	0.320828	0.098662	0.263168	0.068125	0.229291
az_std_Caminar Ida	0.144648	0.309739	0.112555	0.279338	0.112118	0.269774
az_std_Primer Giro	0.11474	0.319704	0.09373	0.219335	0.089405	0.207022
pitch_max_Sentarse	1.212508	1.599482	1.221891	1.654529	1.090007	1.727564
pitch_std_Caminar Ida	0.057358	0.125312	0.043933	0.105254	0.037033	0.093705
pitch_std_Primer Giro	0.030801	0.136853	0.02628	0.109956	0.028732	0.100264
roll_mean_Sentarse	-0.0436	0.087866	-0.08831	0.104727	-0.07445	0.075953
roll_std_Segundo Giro	0.020356	0.056623	0.020285	0.070531	0.018053	0.063576
vx_max_Parse	92.01667	374.05	87.95469	350.3729	90.84583	517.5969
vx_mean_Caminar Ida	4.004261	21.46805	3.247339	13.0517	1.374092	12.53645
vx_mean_Caminar Vuelta	0.022128	12.16	0.210833	7.314328	-0.19796	7.830984
vx_mean_Parse	-40.8125	-9.89717	-48.6216	-8.94659	-40.7778	-5.78827
vx_mean_Primer Giro	-6.61786	13.83823	-3.91894	14.33598	-7.64715	6.504624
vx_mean_Segundo Giro	-39.0348	-10.3327	-45.9312	-6.837	-37.1855	-3.58772
vx_range_Caminar Ida	64.89583	263.15	77.31406	204.7344	64.50313	180.6448
vx_range_Sentarse	109.35	234.6	105.8932	357.7526	74.98125	338.5188
vx_rms_Caminar Ida	15.27769	55.64839	16.78159	42.4249	13.63539	34.57525
vx_rms_Parse	50.45857	110.0579	48.78563	104.9504	43.27206	126.6374
vx_rms_Sentarse	42.69652	96.20859	41.6923	94.43009	29.02108	108.1573
vx_std_Parse	44.86178	104.7827	47.4727	93.76918	40.46111	120.6608
vx_std_Sentarse	32.58672	66.77119	27.05856	71.40929	21.53017	78.14072

vy_max_Caminar Vuelta	66.20833	161.0333	59.79844	119.4604	54.86771	91.24271
vy_max_Primer Giro	134.2958	263.8583	117.5526	213.9703	101.2792	196.6969
vy_max_Segundo Giro	150.1125	318.95	138.4167	294.0432	131.2573	242.8448
vy_mean_Caminar Ida	-4.76195	22.32861	-2.86107	16.95223	-2.16792	18.83852
vy_mean_Caminar Vuelta	-17.8581	32.57065	-13.3231	25.62504	-7.74292	19.3114
vy_range_Caminar Vuelta	89.48333	211.7125	89.73385	186.9969	88.28854	163.5188
vy_range_Segundo Giro	132.7792	264.8542	114.7255	258.5953	111.4375	222.8635
vy_rms_Caminar Vuelta	26.83455	59.77073	23.39319	46.21711	20.46616	36.55932
vy_rms_Primer Giro	83.37362	148.6303	69.34143	126.9099	64.32807	126.4559
vy_rms_Segundo Giro	99.84873	216.6844	88.97706	185.3778	80.42471	163.3958
vy_std_Caminar Vuelta	20.91065	54.95081	20.88972	42.58215	19.35872	35.52014
vy_std_Parse	8.848833	24.59467	7.06041	22.14317	6.965493	22.37597
vz_max_Sentarse	23.24583	84.975	23.91198	62.31927	23.3	79.77813
vz_std_Sentarse	6.514724	26.15332	7.711857	21.34782	8.825731	25.88857
yaw_max_Caminar Ida	0.246002	0.714573	0.24839	1.471653	0.211757	1.357853
yaw_max_Parse	0.14417	0.592153	0.124245	1.344387	0.164716	1.289868
yaw_max_Sentarse	0.125423	0.679649	0.150105	1.387519	0.177032	0.91965
yaw_mean_Caminar Vuelta	-2.77635	2.477397	-2.90665	0.183444	-2.8001	0.617555
yaw_mean_Parse	-0.41247	0.511779	-0.03873	1.293894	-0.77148	0.765192
yaw_mean_Segundo Giro	-1.5005	1.581242	-1.38802	1.657655	-1.3388	1.695104
yaw_mean_Sentarse	-0.24479	0.487402	0.102093	1.246967	-0.54584	0.574023
yaw_range_Segundo Giro	2.084064	5.52797	2.343666	4.621192	2.421315	6.269926
yaw_rms_Parse	0.065267	0.517273	0.081255	1.294388	0.119592	1.164776
yaw_std_Segundo Giro	0.692759	1.346911	0.736214	1.502816	0.789549	1.709467

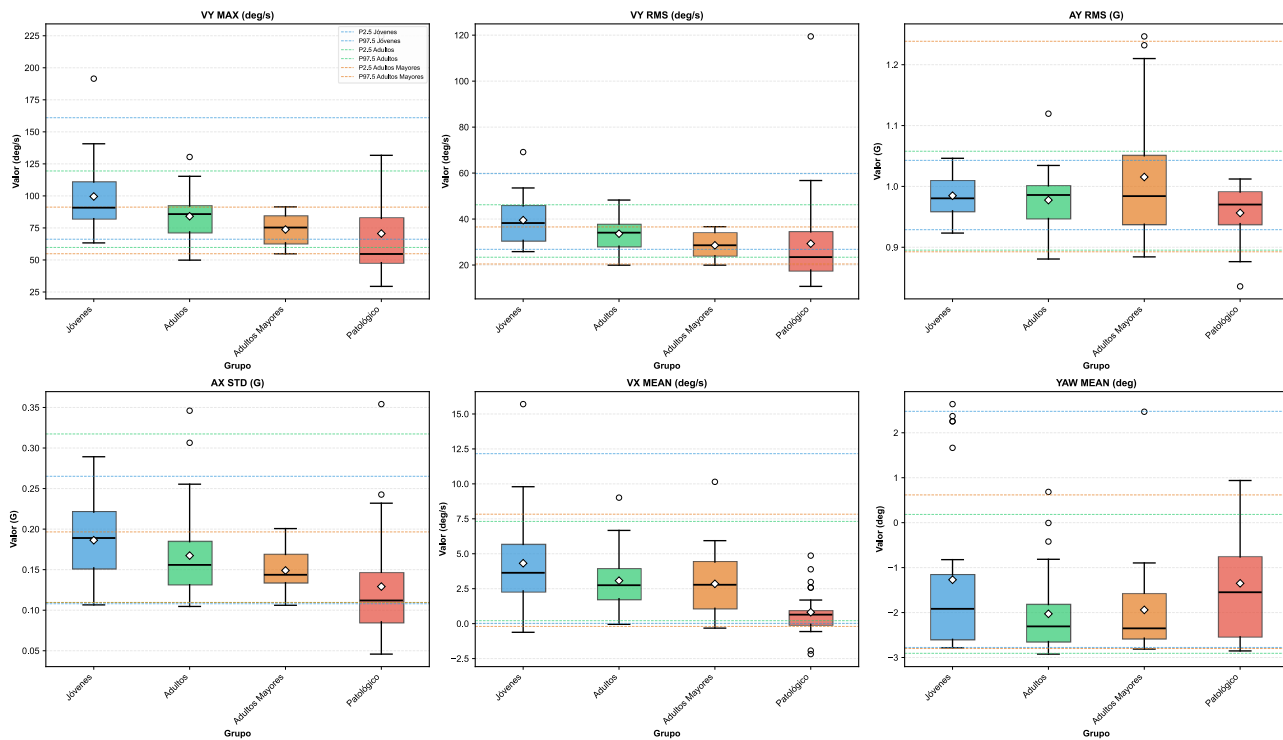
Anexo B: Boxplots de distribución de valores biomarcadores en las etapas iTUG



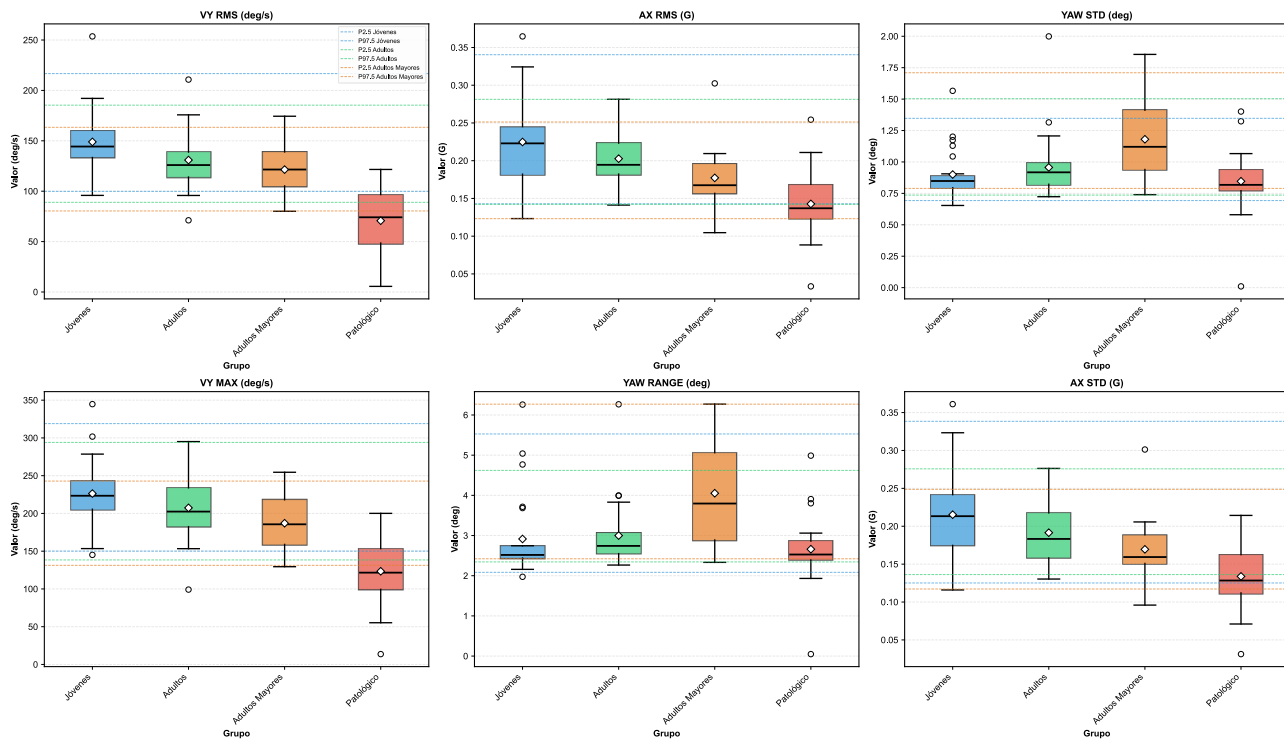
Comparación: Primer Giro



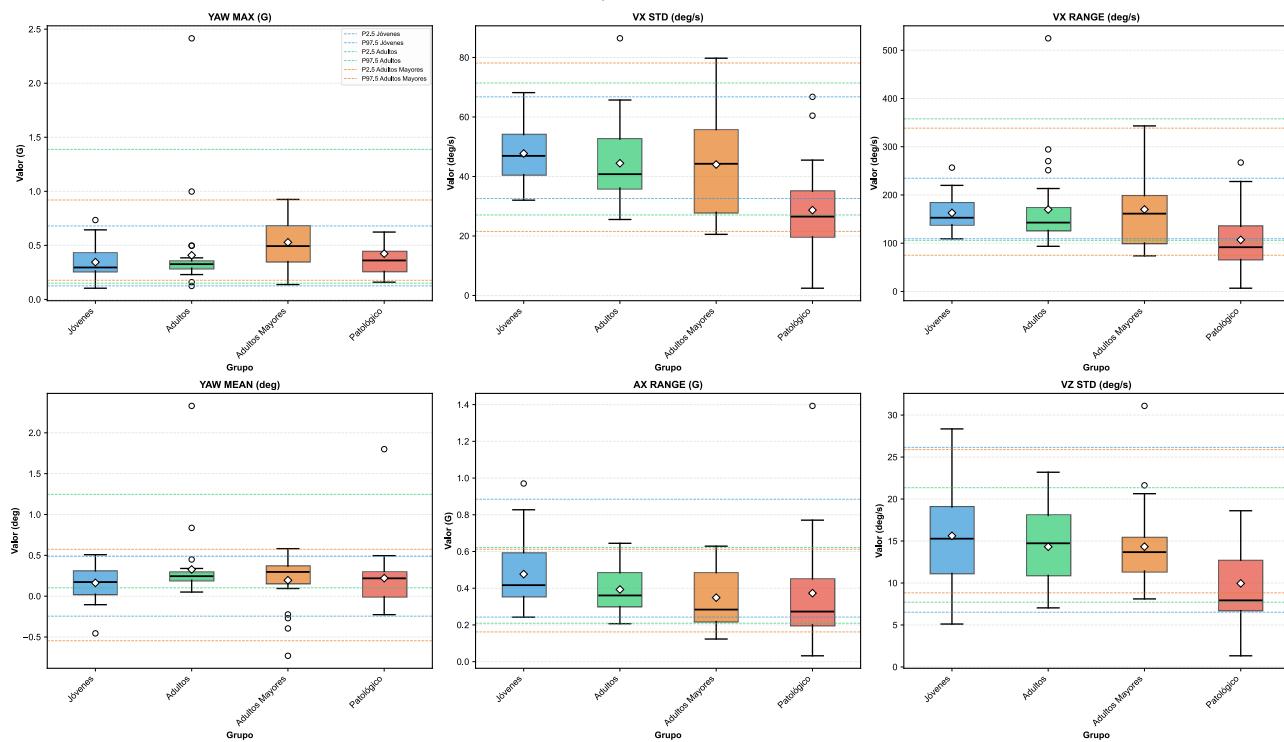
Comparación: Caminar Vuelta



Comparación: Segundo Giro



Comparación: Sentarse



Anexo C: Tendencias Lineales con la edad y biomarcadores en etapas del iTUG

