



Facultad de Ingeniería
Universidad de Concepción

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELECTRICA**

**EVALUACIÓN CRÍTICA DE ALGORITMOS DE SEGMENTACIÓN DEL
TEST TIMED UP AND GO (TUG) BASADOS EN IMU**

POR

Loreto Valentina Rojas Sandoval

Informe Final de Memoria de Titulo

Profesor Guía
Pablo Aqueveque Navarro

Comisión
Paulina Ortega Bastidas
Pedro Pinacho Davidson

Junio
Concepción
(Chile)

© 2025 Loreto Valentina Rojas Sandoval

© 2025 Loreto Valentina Rojas Sandoval

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

Resumen

El Timed Up and Go (TUG) es una prueba funcional ampliamente utilizada para evaluar movilidad y riesgo de caídas, especialmente en adultos mayores y personas con patologías neurológicas. Sin embargo, su enfoque tradicional basado únicamente en el tiempo total presenta limitaciones al no considerar aspectos cualitativos del movimiento. La integración de sensores inerciales (IMU) y algoritmos ha permitido segmentar el TUG en subetapas, mejorando la detección de deficiencias motoras.

Este trabajo valida y desarrolla un algoritmo automático de segmentación del TUG, utilizando datos inerciales en personas de distintos rangos etarios. Se revisaron algoritmos existentes, se evaluó un modelo basado en reglas y se propuso una optimización mediante votación de jurados, comparando resultados con el sistema OptiTrack, estándar de referencia para este trabajo. El algoritmo se evaluó por precisión, sensibilidad, error promedio y correlación con segmentación manual. Se espera aportar herramientas más precisas para la evaluación clínica, facilitando la integración del TUG automatizado en entornos de salud.

En la validación con 75 participantes de diversos rangos etarios, el algoritmo alcanzó sensibilidad y precisión de hasta 0.97, con MAE menor a un segundo en la mayoría de las subetapas. Se observó alta correlación ($r > 0.90$) con la segmentación manual en la duración total y fases estables, confirmando su robustez. Además, el análisis por grupo etario mostró un aumento progresivo en los tiempos de ejecución del TUG, subrayando el potencial de la herramienta para identificar variaciones funcionales asociadas a la edad. Estos resultados demuestran que la segmentación automática con IMU complementa y potencia la evaluación clínica, proporcionando métricas objetivas para el monitoreo y prevención del riesgo de caídas.

Abstract

The Timed Up and Go (TUG) test is widely used to assess mobility and fall risk, especially in older adults and individuals with neurological conditions. However, its traditional approach, based solely on total completion time, has significant limitations, as it fails to capture qualitative aspects of movement such as stability during turns and coordination when standing up. The integration of inertial measurement units (IMU) and algorithms has enabled the segmentation of the TUG into specific subtasks, improving the detection of motor deficiencies.

This thesis aims to validate and develop an automatic segmentation algorithm for the TUG using IMU data from individuals of different age ranges. The methodology involved a critical review of existing algorithms, evaluation of a rule-based model, and the development of an optimized approach through jury-based voting techniques, with validation against the OptiTrack system, the gold standard for motion capture. The algorithm was evaluated in terms of accuracy, sensitivity, mean absolute error, and correlation with manual segmentation. The goal is to contribute more precise and accessible tools for clinical assessment, enhancing the objectivity of TUG analysis and facilitating its integration into healthcare settings.

In the validation conducted with 75 participants across different age groups, the proposed algorithm achieved sensitivity and precision of up to 0.97, with a mean absolute error below one second in most subtasks. High correlation ($r > 0.90$) was observed with manual segmentation for total test duration and stable phases, confirming the method's robustness. Age group analysis showed a progressive increase in TUG times, highlighting the tool's potential to identify age-related functional variations. These results demonstrate that automatic IMU-based segmentation can complement and enhance traditional clinical assessment, providing objective and detailed metrics for the monitoring and prevention of fall risk.

Tabla de Contenidos

CAPÍTULO 1. INTRODUCCIÓN	9
1.1. INTRODUCCIÓN GENERAL.....	9
1.2. OBJETIVOS.....	10
1.2.1 <i>Objetivo General</i>	10
1.2.2 <i>Objetivos Específicos</i>	10
1.3. ALCANCES	10
1.4. LIMITACIONES.....	11
CAPÍTULO 2. MARCO TEÓRICO	12
2.1. TIMED UP AND GO	12
2.2. UNIDAD DE MEDICIÓN INERCIAL	13
2.3. TIMED UP AND GO INSTRUMENTADO (iTUG)	15
2.4. SISTEMA ÓPTICO BASADOS EN MARCADORES	15
CAPÍTULO 3. ANÁLISIS CRÍTICO ALGORITMOS DE SEGMENTACIÓN	17
3.1. MÉTODOS TRADICIONALES DE SEGMENTACIÓN DEL TUG: ALGORITMOS BASADOS EN REGLAS	17
3.2. MÉTODOS DE APRENDIZAJE AUTOMÁTICO.....	20
3.3. EVALUACIÓN DE UN ALGORITMO DE SEGMENTACIÓN DEL TEST TUG.....	23
3.4. DISCUSIÓN	26
CAPÍTULO 4. MÉTODOS	28
4.1. PARTICIPANTES.....	28
4.1.1 <i>Comité de Ética</i>	28
4.2. INSTRUMENTACIÓN.....	29
4.3. PROCEDIMIENTO DE ADQUISICIÓN DE DATOS.....	30
4.4. DESARROLLO DE ALGORITMO DE SEGMENTACIÓN.....	31
4.5. VALIDACIÓN DE LA SEGMENTACIÓN AUTOMÁTICA.....	31
4.5.1 <i>Consideraciones para la Segmentación Manual de Subetapas</i>	32
4.6. MÉTRICAS DE EVALUACIÓN	33
1) <i>Diferencia de Tiempos ΔT</i>	33
2) <i>Absolute Mean Error (MAE)</i>	33
3) <i>Precisión (Accuracy)</i>	33
4) <i>Sensibilidad</i>	33
5) <i>Coefficiente de correlación de Pearson (r)</i>	34
CAPÍTULO 5. DESARROLLO ALGORITMO DE SEGMENTACIÓN	35
5.1. PREPROCESAMIENTO	36
5.1.1 <i>Corrección de discontinuidades señal Yaw</i>	36
5.2. DETECCIÓN ETAPA PARARSE.....	37
5.2.1 <i>Jurado 1 (velocidad angular X)</i>	37
5.2.2 <i>Jurado 2 (aceleración Z)</i>	37
5.2.3 <i>Jurado 3 (pitch)</i>	37
5.3. DETECCIÓN ETAPA CAMINATA IDA	38
5.3.1 <i>Jurado 1 (Velocidad angular X)</i>	38
5.3.2 <i>Jurado 2 (Aceleración Z)</i>	38
5.3.3 <i>Jurado 3 (Pitch)</i>	38
5.4. DETECCIÓN PRIMER GIRO	39
5.4.1 <i>Jurado 1 (Yaw)</i>	39
5.4.2 <i>Jurado 2 (Velocidad angular en el eje Y)</i>	39
5.5. DETECCIÓN CAMINATA VUELTA	40
5.5.1 <i>Jurado 1 (yaw)</i>	40
5.5.2 <i>Jurado 2 (velocidad angular Y)</i>	40

5.6.	DETECCIÓN SEGUNDO GIRO	41
5.6.1	<i>Detección del inicio del giro</i>	41
5.6.2	<i>Detección del fin del giro</i>	41
5.7.	DETECCIÓN SENTARSE	42
5.7.1	<i>Jurado 1 (Velocidad angular eje X)</i>	42
5.7.2	<i>Jurado 2 (Aceleración eje Y)</i>	42
5.7.3	<i>Jurado 3 (Pitch)</i>	42
5.7.4	<i>Fin de la Etapa Sitting</i>	43
5.8.	DETERMINACIÓN DEL CONSENSO PONDERADO PARA LA SEGMENTACIÓN DE EVENTOS.....	43
5.9.	INTEGER LINEAL PROGRAMMING (ILP)	44
CAPÍTULO 6. RESULTADOS		46
6.1.	DESEMPEÑO ALGORITMOS DE SEGMENTACIÓN ITUG	46
6.2.	DURACIÓN SUBETAPAS TUG.....	48
CAPÍTULO 7. DISCUSIONES Y CONCLUSIONES.....		50
7.1.	DISCUSIÓN	50
7.2.	CONCLUSIÓN.....	52
7.3.	TRABAJO FUTURO	53
CAPÍTULO 8. GLOSARIO		54
CAPÍTULO 9. REFERENCIAS.....		55

Lista de Tablas

Tabla 2-1 Tiempos TUG Riesgo de caídas en población chilena	13
Tabla 3-1 Criterio de Evaluación para cada prueba TUG.	25
Tabla 3-2 Cantidad de detecciones por subtarea del test TUG.	26
Tabla 3-3 Sensibilidad por subtarea del TUG.	26
Tabla 4-1 Rango etario por cada clase.	28
Tabla 4-2 Características Técnicas de la IMU	29
Tabla 4-3 Criterios biomecánicos para la identificación de Subetapas del test TUG.	32
Tabla 5-1 Jurados para algoritmo de detección de eventos en señales provenientes de los sensores inerciales.....	35
Tabla 5-2 Preprocesamiento señales inerciales para detección de eventos.	36
Tabla 5-3 Pesos asignados a jurados en las etapas del test TUG para consenso ponderado.....	44
Tabla 5-4 Jurado seleccionado por cada subetapa TUG.	45
Tabla 6-1 Error absoluto promedio en segundos por etapa TUG de segmentación automática.	46
Tabla 6-2 Sensibilidad y precisión por subetapa del test TUG, promediando los tres intentos por participante, para los algoritmos de consenso ponderado e ILP.	46
Tabla 6-3 Coeficientes de Pearson entre las predicciones del algoritmo (Consenso Ponderado e ILP) y el Ground Truth para las etapas del test TUG en tres intentos.....	47
Tabla 6-4 Duración promedio de cada subetapa TUG (s) según segmentación manual (Ground Truth).....	48
Tabla 6-5 Duración promedio de cada subetapa TUG (s) según algoritmo de consenso ponderado.	48

Lista de Figuras

Fig. 2.1 Representación del uso de Unidad de Medición Inercial durante la marcha y los ejes de movimiento.....	14
Fig. 3.1 Detección de eventos utilizando algoritmo propuesto por [45]. Participante a003_1.	24
Fig. 3.2 Detección de eventos deficiente utilizando algoritmo propuesto por [45]. Participante a009_1.	25
Fig. 4.1 Diagrama de flujo metodología.....	28
Fig. 4.2 Instrumentación durante la prueba.....	30
Fig. 4.3 Secuencia del test Timed Up and Go	31
Fig. 5.1 Planos anatómicos y ejes XYZ del sistema de referencia de la IMU.	35
Fig. 5.2 Corrección de discontinuidades en señal yaw.....	37
Fig. 5.3 Detección de eventos Pararse y Caminata ida mediante distintos jurados y su consenso. ...	38
Fig. 5.4 Detección Primer Giro a través de señal Yaw y Velocidad Angular Y.....	40
Fig. 5.5 Detección de Caminata Ida mediante velocidad angular en eje Y.....	41
Fig. 5.6 Segmentación Segundo giro mediante señal Yaw.	42
Fig. 5.7 Detección inicio y fin de subetapa sentarse.	43
Fig. 5.8 Segmentación automática del test TUG por algoritmo de consenso ponderado.....	44
Fig. 6.1 Gráficos de dispersión de la duración por subetapa estimada entre el algoritmo de consenso ponderado y la duración real en los intentos promediados del test TUG.....	47
Fig. 6.2 Gráficos de dispersión de la duración por subetapa estimada por el algoritmo versus la duración real en los intentos promediados del test TUG.....	47
Fig. 6.3 Duración promedio por subetapa según grupo etario (Segmentación Manual).	49
Fig. 6.4 Duración promedio por subetapa según grupo etario a partir de señales inerciales (Segmentación Algoritmo Consenso).	49
Fig. 6.5 Comparación de los tiempos totales del test Timed Up and Go (TUG) según grupo etario, obtenidos mediante segmentación manual (Ground Truth) y el algoritmo de consenso.	49

Capítulo 1. 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 subtarefas 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. Sin embargo, aún no existe un método universalmente aceptado para la segmentación del TUG [10]. Esto plantea la necesidad de investigar y evaluar rigurosamente dichos algoritmos para asegurar su precisión y utilidad en la identificación de subtarefas del TUG, ante distintas condiciones, mejorando así la capacidad de los profesionales de salud para objetivar la evaluación clínica e integrándose como herramienta clave junto a unidades de medición inercial en la evaluación del riesgo de caídas [11].

1.2. Objetivos

1.2.1 Objetivo General

Validar un algoritmo de segmentación automática del test Timed Up and Go (TUG) utilizando sensores inerciales (IMU) en personas de distintos rangos etarios, incluyendo adultos mayores, para optimizar la detección de subtareas y apoyar la evaluación clínica del riesgo de caídas.

1.2.2 Objetivos Específicos

- Analizar las metodologías existentes de segmentación de la prueba Timed Up and Go basados en datos de sensores inerciales.
- Evaluar críticamente la precisión y fiabilidad de un algoritmo actual de segmentación del TUG mediante su aplicación en datos reales.
- Desarrollar y evaluar el desempeño de un nuevo algoritmo de segmentación del TUG utilizando datos obtenidos en personas de distintos rangos etarios, incluyendo adultos mayores.

1.3. Alcances

- i. El análisis de algoritmos abarcará tanto los enfoques tradicionales basados en reglas como los métodos más avanzados de aprendizaje automático, enfocándose en la segmentación de fases específicas del TUG como levantarse, caminar, girar y sentarse.
- ii. El desarrollo del proyecto permitirá obtener un nuevo algoritmo optimizado, que será validado en entornos controlados y evaluado utilizando datos reales de sujetos, tanto jóvenes como mayores.
- iii. El algoritmo propuesto 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 variabilidad entre los sujetos. Patrones de marcha atípicos podrían presentar dificultades para una correcta segmentación en algunos casos, resultando en alguna segmentación incorrecta en fases del test.

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 2-1 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 pico, 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].

Los algoritmos de segmentación aplicados al test Timed Up and Go (TUG) mediante unidades de medición inercial (IMU) han evolucionado desde enfoques simples basados en reglas hasta métodos más sofisticados de aprendizaje automático. A continuación, se describen los diferentes enfoques utilizados en los estudios relevantes para mejorar la precisión y la utilidad clínica de la segmentación automática.

3.1. Métodos Tradicionales de Segmentación del TUG: Algoritmos Basados en Reglas

Zhang et al. (2013), en su estudio titulado *"Three Dimensional Gait Analysis Using Wearable Acceleration and Gyro Sensors Based on Quaternion Calculations"*, introduce un algoritmo basado en cálculos de cuaterniones para la estimación tridimensional de la orientación de los segmentos corporales durante la marcha. Este estudio utilizó sensores inerciales colocados en las extremidades inferiores para analizar los ángulos de flexión de cadera, rodilla y tobillo. Aunque no se centra específicamente en el test TUG, este enfoque destaca la capacidad de los sensores IMU para reconstruir movimientos complejos en un entorno no controlado, lo cual es clave para la segmentación del TUG en aplicaciones clínicas. El uso de cuaterniones minimiza el error acumulado por la integración de señales, conocido como "drift", lo que mejora la precisión en la estimación de la orientación de los segmentos corporales [35]. Sin embargo, una limitación importante es que el algoritmo depende en gran medida de la calibración precisa de los sensores y de las suposiciones relacionadas con la orientación inicial.

Por otro lado, el artículo "Transition between the Timed Up and Go turn to sit subtasks: Is timing everything?" por Weiss et. al. (2016) se centra específicamente en la segmentación de subtareas dentro del TUG, abordando la transición entre el giro y el sentado, que representa un momento crítico para identificar el riesgo de caídas en personas mayores. El estudio distingue dos estrategias utilizadas por los participantes: una transición distintiva, donde el individuo completa el giro antes de sentarse, y una transición superpuesta, donde el sentado comienza antes de finalizar el giro. Mediante el uso de sensores inerciales colocados en la parte baja de la espalda y algoritmos de regresión lineal, los investigadores lograron medir las duraciones de estas transiciones, encontrando correlaciones significativas entre la duración de las mismas y el deterioro motor y cognitivo. Este estudio revela que

las personas que optan por una transición más lenta y distinta suelen tener un peor rendimiento en cuanto a la velocidad de la marcha y mayor bradicinesia, lo que sugiere una relación entre el deterioro del control motor y la capacidad para realizar movimientos complejos [36]. A pesar de su capacidad para identificar estrategias motoras distintas, este enfoque aún enfrenta desafíos en cuanto a su aplicabilidad clínica, ya que no todos los pacientes siguen un patrón predecible.

En línea con estos avances, la validación de la precisión de los IMU frente a sistemas de captura de movimiento más avanzados fue abordada por Beyea et al. (2017), quienes compararon la capacidad de los IMU para medir subtareas del TUG con un sistema de captura de movimiento. Utilizando un sistema IMU colocado en el torso de los participantes, este estudio logró identificar seis fases principales del TUG, incluyendo la transición de sentado a de pie, caminar, giros, y la vuelta a la posición de sentado. Si bien el análisis mostró una alta concordancia en las fases de caminar y la duración total del TUG (con valores de correlación superiores a 0.9), se observaron discrepancias significativas en las mediciones relacionadas con las actividades de la silla y los giros, donde los valores de correlación fueron considerablemente menores (por debajo de 0.4). Este hallazgo resalta las limitaciones actuales de los sensores inerciales en la medición precisa de transiciones más complejas, como los giros, que son cruciales para evaluar el riesgo de caídas [9]. A pesar de estas limitaciones, la detección ante cambios mínimos sigue siendo un desafío para distintas condiciones y patologías en la aplicación del test Timed Up and Go.

Yang et al. (2019), proponen un enfoque innovador que adapta el entorno del TUG mediante el uso de un sistema llamado SITUG. Este sistema utiliza plantillas inteligentes con sensores inerciales para capturar datos detallados sobre los movimientos de los participantes durante la prueba. Uno de los aspectos más novedosos de este estudio es la capacidad del sistema para adaptarse a diferentes entornos, lo que permite evaluar la capacidad de una persona para realizar el TUG en condiciones ambientales más desafiantes, como la presencia de obstáculos o inclinaciones [37]. Este avance es importante porque las pruebas tradicionales del TUG suelen realizarse en entornos controlados, limitando la comprensión de cómo las personas se comportan en situaciones más realistas. SITUG logró una precisión media del 92.23% en la segmentación de cinco fases principales del TUG: levantarse, caminar hacia adelante, girar, caminar de regreso y sentarse. Este sistema representa un avance significativo al superar las limitaciones de los métodos tradicionales, que se centran solo en el tiempo total de la prueba y no en las características cinemáticas detalladas que proporcionan una visión

más profunda de la movilidad. Sin embargo, a pesar de sus ventajas, el sistema enfrenta desafíos en la detección precisa de algunas fases, como la fase de giro, donde la variabilidad entre sujetos puede afectar los resultados.

Esta dificultad para segmentar con precisión fases críticas, como el giro, ha sido una constante en la investigación sobre el Timed Up and Go, como lo destaca Ansai et al. (2019) en su estudio sobre la fragilidad en adultos mayores. Al evaluar la movilidad de personas no frágiles, prefrágiles y frágiles, encontraron que la fase de giro era un diferenciador clave entre los grupos, especialmente en los frágiles, quienes mostraban tiempos más largos y velocidades más lentas. Estos hallazgos refuerzan la importancia de segmentar con precisión las subtarefas del TUG, ya que transiciones como el giro son esenciales para evaluar el riesgo de caídas [38]. Sin embargo, al igual que en el estudio de Yang et al., la variabilidad entre sujetos y la dificultad para distinguir entre individuos prefrágiles y no frágiles limita la capacidad de identificar con precisión etapas tempranas de deterioro. Esto indica la necesidad de mejorar las medidas de sensibilidad en la segmentación para detectar cambios más sutiles en las poblaciones prefrágiles.

En la tesis de B. Gómez (2021), describe la implementación de un algoritmo de segmentación aplicado al test Timed Up and Go (TUG) utilizando una unidad de medición inercial, con un enfoque basado en características. Este algoritmo emplea principalmente las señales de inclinación (Pitch) y rotación (Yaw) para identificar los eventos clave durante el TUG, como las fases de levantarse, caminar, girar y sentarse. A través de un filtro de media móvil y la normalización de las señales, el algoritmo detecta picos de manera secuencial, en las inclinaciones del tronco que corresponden a eventos críticos de la prueba, como el inicio y el final de los movimientos. El algoritmo también identifica los giros de 180 grados durante el test utilizando la señal de rotación (Yaw). Mediante un procesamiento similar con un filtro de media móvil, se detectan los máximos de la señal de Yaw para determinar el inicio y el fin de los giros, lo cual es fundamental en la evaluación del TUG. Este sistema permite extraer características temporales precisas, que son esenciales para la evaluación de la movilidad y el riesgo de caídas en diferentes fases del TUG [39]. Además, el algoritmo se valida a través de estudios en sujetos jóvenes y mayores, obteniendo resultados que muestran una correlación alta con la observación visual, con errores mínimos en la segmentación. Sin embargo, el algoritmo presenta varias limitaciones, entre las cuales destaca la detección secuencial de eventos. Si el algoritmo identifica erróneamente una subetapa, los eventos posteriores también serán etiquetados

incorrectamente. Esto ocurre porque, aunque detecta correctamente el pico de la señal, el evento en sí puede estar mal clasificado. Por ejemplo, podría señalar que la persona ha realizado la etapa del segundo giro, cuando en realidad se trata del primer giro.

Otra limitación importante del algoritmo es el umbral fijo que utiliza para discriminar cada una de las seis etapas de la prueba. Este enfoque puede fallar en señales de personas con patologías o que presentan una marcha atípica en comparación con los patrones clínicos normales. El algoritmo es una buena estrategia para la detección secuencial de eventos, sin embargo, para efectos de este, sería interesante explorar un enfoque donde la detección de etapas se realice de manera independiente, empleando umbrales adaptativos para cada una de las subetapas del test TUG, lo que permitiría una mayor flexibilidad y precisión en la segmentación.

Los desafíos en la detección de giros no son exclusivos de los algoritmos basados en IMU. Romijnders et al. (2021) examina la validación de la detección de eventos de marcha utilizando sensores inerciales (IMU) montados en la pierna. La precisión en la detección de eventos como el contacto inicial y final del pie (IC y FC) es crucial para una evaluación clínica precisa de la marcha, especialmente en poblaciones con trastornos neurológicos como el Parkinson. El estudio demostró que los IMU son altamente precisos en la detección de estos eventos durante la marcha en línea recta, alcanzando una precisión del 100% en condiciones de tarea única y dual, lo que subraya su aplicabilidad en la evaluación de la marcha en escenarios simples [40]. Sin embargo, los resultados mostraron una disminución significativa en la precisión durante los giros, con una caída en la sensibilidad a un 85% para el contacto inicial y a un 84% para el contacto final, lo que indica que los giros siguen siendo un desafío importante para los algoritmos de segmentación basados en IMU. La naturaleza compleja de los giros, donde los movimientos no son tan predecibles como en la marcha recta, dificulta la identificación precisa de los eventos clave, generando falsos positivos y negativos. Este estudio subraya la necesidad de mejorar los algoritmos actuales para integrar de manera más eficaz las variaciones en las trayectorias de giro y otras condiciones de marcha complejas.

3.2. Métodos de Aprendizaje Automático

El reconocimiento de las limitaciones de los IMU ha impulsado la exploración de modelos más avanzados para mejorar la segmentación del TUG. Haji et al. (2018) presenta una comparación

entre diferentes métodos de segmentación de la marcha utilizando sensores inerciales en pacientes con Parkinson, lo que es altamente relevante para la evaluación de la marcha en poblaciones con riesgos de caídas elevados. Se probaron cuatro métodos principales: detección de picos, dos variaciones de la técnica Dynamic Time Warping (DTW), y modelos ocultos de Markov jerárquicos (hHMM). En situaciones simples, como caminatas rectas, todos los métodos mostraron un rendimiento similar, con una precisión cercana al 100%. Sin embargo, en tareas más complejas que incluían giros y transiciones entre pasos, como en el TUG, el modelo hHMM superó significativamente a los otros métodos, alcanzando un 96% de precisión. Este enfoque probabilístico permitió una mejor diferenciación entre los movimientos de marcha y otros movimientos, lo que es crucial para una segmentación precisa en pacientes con patrones de marcha patológicos [15]. Aunque este método mostró una mayor robustez, su implementación es más compleja y requiere un mayor poder computacional. A pesar de estos avances, el desafío de segmentar adecuadamente fases complejas también se observa en el ámbito postoperatorio, como señala Hsieh et al. (2020) en su estudio sobre pacientes con artroplastia total de rodilla (TKA). Utilizando un sistema de clasificación de múltiples etapas que combina técnicas de aprendizaje automático y procesamiento basado en el conocimiento, Lee et al. lograron mejorar la precisión en la segmentación del TUG en un 92%, destacando su efectividad en la identificación de fases específicas del TUG, como caminar, girar y sentarse. Uno de los principales desafíos abordados en este trabajo es la variabilidad en las características del movimiento, especialmente en pacientes en diferentes etapas de recuperación postoperatoria. Además, se propone un esquema de ventana deslizante para mejorar la precisión en la identificación de eventos clave, como los giros, los cuales suelen presentar mayor dificultad debido a la superposición de patrones de movimiento [18]. Sin embargo, el estudio también revela limitaciones relacionadas con la ambigüedad en algunas transiciones, lo que resalta la necesidad de metodologías adicionales para mejorar la segmentación en escenarios complejos.

Choi et al. (2022) presenta un enfoque completamente distinto al utilizar cámaras RGB-D y aprendizaje profundo para la segmentación automática de las subtarefas del TUG. En lugar de sensores inerciales, se empleó una red de convolución temporal dilatada (TCN) para segmentar las diferentes fases del TUG a partir de datos de cámaras RGB-D. Este método demostró una notable precisión en tres grupos de sujetos: adultos jóvenes sanos (95.46%), adultos mayores (94.53%) y pacientes con accidente cerebrovascular (93.58%). Una de las innovaciones clave de este estudio fue la utilización de solo una característica, el punto del pelvis, lo que no solo mejoró la precisión, sino que también

redujo significativamente el tiempo de procesamiento, permitiendo la inferencia en tiempo real en dispositivos portátiles. Esta investigación también muestra cómo los modelos basados en aprendizaje profundo pueden superar las limitaciones de los métodos basados en reglas tradicionales y mejorar la segmentación de tareas complejas, como los giros y las transiciones de sentado a de pie [41]. A pesar de su alta precisión, una de las limitaciones del estudio es la necesidad de grandes cantidades de datos etiquetados para entrenar los modelos, lo que puede ser una barrera en entornos clínicos donde los datos etiquetados de alta calidad no siempre están disponibles.

La búsqueda de herramientas accesibles para la segmentación de las subtarefas del TUG también ha llevado a la exploración de métodos basados en video convencional. Kamnardsiri et al. (2023) desarrollaron un sistema de video para medir la velocidad de movimiento en las subtarefas del TUG y compararon su eficacia con un sistema de captura de movimiento tridimensional, considerado el estándar de oro. Los resultados mostraron una alta correlación entre ambos sistemas, demostrando que el uso de video convencional puede ser una alternativa viable y de bajo costo para la segmentación del TUG. No obstante, este enfoque también presenta limitaciones, como la dependencia de la correcta calibración del sistema y la influencia de factores ambientales, que podrían comprometer la precisión en la detección de transiciones complejas como los giros, reiterando la necesidad de optimizar estas tecnologías para escenarios más dinámicos [42].

Maiores et al. (2024), en su estudio titulado "Older Adult Fall Risk Prediction with Deep Learning and Timed Up and Go Test Data", exploran la predicción del riesgo de caídas en adultos mayores utilizando redes neuronales profundas. Los datos fueron recolectados de un sensor inercial inalámbrico colocado en la espalda baja de 106 adultos mayores durante la realización del TUG. Utilizando modelos de aprendizaje profundo como redes neuronales convolucionales (CNN) y redes neuronales recurrentes de memoria a largo plazo (LSTM), los investigadores lograron predecir el riesgo de caídas con una precisión del 83% y un área bajo la curva (AUC) de 0.73, siendo la arquitectura LSTM bidireccional la que obtuvo los mejores resultados. Este enfoque demuestra el potencial de los modelos de aprendizaje profundo para procesar señales inerciales crudas y extraer características útiles para la predicción del riesgo de caídas [43]. No obstante, el estudio también subraya desafíos importantes, como el desequilibrio de clases entre personas que sufrieron caídas y aquellas que no, lo que afecta la sensibilidad del modelo. Además, la necesidad de grandes cantidades

de datos etiquetados para entrenar estos modelos plantea una barrera significativa para su implementación generalizada en entornos clínicos, donde estos recursos suelen ser limitados.

En un contexto diferente, McCreath et al. (2024) exploran la segmentación de subtareas en el L test, un test funcional similar al TUG, en su estudio titulado "L Test Subtask Segmentation for Lower-Limb Amputees Using a Random Forest Algorithm". Este trabajo se centró en personas con amputación de miembros inferiores y utilizó un sensor inercial colocado en la espalda baja para segmentar las fases del L test, como levantarse, girar y sentarse. A través del uso de un algoritmo de Random Forest, el estudio alcanzó una alta precisión (superior al 85%) y especificidad (superior al 95%) en la segmentación de estas subtareas. Sin embargo, enfrentaron desafíos en la sensibilidad, particularmente durante los giros y movimientos más lentos, donde el algoritmo mostró una menor capacidad para detectar eventos clave. Este estudio es relevante ya que demuestra cómo los enfoques basados en sensores y algoritmos de aprendizaje automático pueden ser aplicados eficazmente en poblaciones con patrones de movilidad alterados, como los amputados, proporcionando información valiosa para la toma de decisiones clínicas [44]. A pesar de los resultados prometedores, los desafíos en la segmentación precisa de los giros destacan la necesidad de mejorar los algoritmos para su uso en poblaciones con patrones de marcha atípicos.

3.3. Evaluación de un Algoritmo de Segmentación del test TUG

A continuación, se presenta la evaluación del algoritmo de segmentación desarrollado por B. Gómez (2021) [45], diseñado para el test Timed Up and Go (TUG) utilizando señales inerciales de rotación (Yaw) e inclinación (Pitch). Este análisis tiene como objetivo verificar la precisión del algoritmo en la segmentación de cada evento crítico del TUG y evaluar su desempeño en la identificación de transiciones clave, como levantarse, caminar, girar y sentarse. Con el fin de reconocer las fortalezas del enfoque empleado, proponiendo mejoras para aumentar su adaptabilidad y precisión en poblaciones con patrones de movilidad variables.

En este algoritmo, los eventos de levantarse y sentarse se identifican mediante el análisis de la señal de inclinación (Pitch), que refleja las inclinaciones del tronco durante estas actividades. La señal es acondicionada a través de un filtro de media móvil, seguida de su normalización por el valor máximo absoluto. Posteriormente, se detectan los máximos locales correspondientes a las

inclinaciones máximas durante estos eventos, y se calculan los puntos de inicio y final utilizando derivadas secuenciales de la señal normalizada.

Para los eventos de giro, se utiliza la señal de rotación (Yaw), que representa los cambios de orientación del sensor durante los giros de 180 grados realizados en el TUG. La señal es suavizada y normalizada de manera similar a la señal Pitch. Mediante derivadas, se identifican los puntos de inicio y fin de cada giro. Cabe destacar que estas identificaciones no están etiquetadas individualmente; sin embargo, se asume secuencialmente que las detecciones corresponden a las subetapas en el siguiente orden: pararse, fin de pararse, caminata de ida, primer giro, caminata de retorno, segundo giro, sentarse y fin de sentarse. La detección de eventos con este método se muestra en la Fig. 3.1.




Fig. 3.1 Detección de eventos utilizando algoritmo propuesto por [45]. Participante a003_1.

En esta oportunidad, se detalla el análisis realizado en una muestra total de 16 participantes y con los resultados obtenidos con la instrumentalización de la prueba Timed up and Go. Cada participante realizó 3 pruebas Timed Up and Go, obteniendo un total de 38 pruebas para el análisis, descartando pruebas que tuviesen error en su adquisición.

Para obtener la detección de eventos en cada una de estas señales, se utilizó MATLAB R2024a, empleando la observación de etiquetas correspondientes a cada evento. Si el evento detectado por el

algoritmo se encontraba fuera del rango de 0.5 segundos respecto al momento real de ocurrencia, según el criterio de detección definido, este se clasificó como "no detección". Si la prueba no presenta errores en la detección de eventos, esta será clasificada como "Buena". Si la prueba tiene sólo 1 "No Detección", esta será considerada como aceptable, mientras que, si la prueba presenta 1 o más de una No detección, la detección de la prueba será considerada como deficiente. En la Fig 3.2 se evidencia una detección deficiente en los eventos de la prueba TUG, donde no se segmentan eventos al inicio de la prueba, como levantarse de la silla y caminar.




Fig. 3.2 Detección de eventos deficiente utilizando algoritmo propuesto por [45]. Participante a009_1.

La Tabla 3-1 presenta la categorización global para cada una de las pruebas. Posteriormente, se obtiene una evaluación de manera independiente para cada subtarea de la prueba Timed Up and Go, como se evidencia en la tabla 3-2. Finalmente, se calculó la métrica de sensibilidad. La Tabla 3-3 presenta los valores para cada una de las subetapas.

Tabla 3-1 Criterio de Evaluación para cada prueba TUG.

Detección	Nº Pruebas
Buena	17
Aceptable	3
Deficiente	18

Tabla 3-2 Cantidad de detecciones por subtarea del test TUG.

Evento	N° Detecciones	No detecciones
Pararse	27	11
Caminata Ida	26	12
Primer Giro	26	12
Caminata vuelta	27	11
Segundo Giro	38	0
Sentarse	38	0

Tabla 3-3 Sensibilidad por subtarea del TUG.

Evento	Sensibilidad (%)
Pararse	71.05
Caminata Ida	68.42
Primer Giro	68.42
Caminata vuelta	71.05
Segundo Giro	100.00
Sentarse	100.00

3.4. Discusión

Los resultados de la evaluación del algoritmo de Gómez (2021) muestran una alta sensibilidad en los eventos “Segundo giro” y “Sentarse” (100 %), pero una disminución notable en fases intermedias como “Primer giro” y “Caminata ida” (68 %). Este patrón refleja la misma dificultad que describen Beyea et al. en [9] al comparar sensores IMU con sistemas de captura óptica: altas correlaciones en marcha pero pobres resultados en giros y transiciones de silla, y coincide con la caída de sensibilidad durante giros reportada por Romijnders et al. (2021) (85 % IC, 84 % FC) [40]. Además, Ansai et al. (2019) destaca que la variabilidad intersujeto en la fase de giro limita la detección temprana de deterioro funcional [38].

Estas limitaciones se originan principalmente en la estructura secuencial del algoritmo y el uso de umbrales estáticos: un fallo en la identificación temprana de “Pararse” o “Caminata ida” desplaza todos los eventos posteriores, generando falsas etiquetas. La literatura sugiere varias rutas para mejorar este desempeño. En el ámbito de aprendizaje automático, Haji et al. (2018) lograron 96 % y 92% de precisión, respectivamente, usando modelos probabilísticos y esquemas de ventana deslizante,

pero a costa de mayor complejidad computacional y dependencia de datos etiquetados [46], por lo que una alternativa suficiente sería aplicar estos modelos, pero en procesamiento de señales, lo cual requiere de un bajo costo computacional.

Con base en estos hallazgos, se propone un enfoque adaptativo y modular basado en:

1. Segmentación independiente por subtarea, de modo que cada evento se valide con criterios propios (p. ej., umbrales dinámicos de Yaw y Velocidad Angular para giros).
2. Umbrales adaptativos en base a métricas de la señal total, para acomodar variabilidad clínica.
3. Integración de múltiples señales: corroborar cada evento combinando diferentes canales (p.ej. Pitch, Velocidad Angular y aceleración longitudinal para detectar evento de Pararse).
4. Evaluar el desempeño del algoritmo en cohortes de adultos de mediana y tercera edad, analizando su sensibilidad y precisión en cada grupo funcional.

Capítulo 4. Métodos

Para cumplir con los objetivos propuestos en esta memoria, se implementará la siguiente metodología:

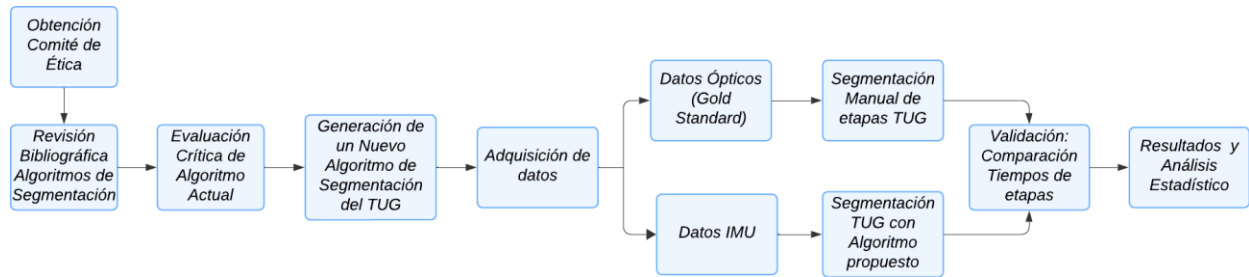


Fig. 4.1 Diagrama de flujo metodología

4.1. Participantes

El estudio consideró una muestra heterogénea de 75 personas voluntarias, organizadas en 3 grupos etarios con el objetivo de garantizar una representación equilibrada de edades y capacidades motoras.

Tabla 4-1 Rango etario por cada clase.

Rango Etario	Nº Participantes
45 – 59	25
60 – 69	25
70+	25
Total	75

Como criterios de exclusión, se descartaron personas incapaces de seguir órdenes simples, aquellas con intolerancia al esfuerzo físico, o individuos con diagnósticos médicos descompensados que representarían un riesgo durante la ejecución de la prueba. También se excluyeron participantes con antecedentes de intervenciones quirúrgicas en miembros inferiores o tronco en los dos años previos a la evaluación, así como aquellos que presentarían dolor osteomuscular en los miembros inferiores superior a cinco puntos en la Escala Numérica Análoga (ENA).

4.1.1 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 CEBB 687-2020.

4.2. 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 [47]. Las características técnicas del dispositivo se presentan en la Tabla 4-2.

Tabla 4-2 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 [48], [49].

Adicionalmente, se empleó la configuración *Conventional Lower (16)* del sistema OptiTrack®, que utiliza 16 marcadores pasivos, como se observa en la Figura 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.

4.3. 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. 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.

4.4. Desarrollo de Algoritmo de Segmentación

Se desarrolló un nuevo algoritmo con el objetivo de optimizar la segmentación del test Timed Up and Go (TUG), empleando técnicas avanzadas de procesamiento de señales inerciales. En particular, se implementó un enfoque que integra las decisiones de múltiples heurísticas o subalgoritmos especializados en la detección de eventos clave. Este enfoque permite alcanzar un consenso robusto, reduciendo la sensibilidad a errores individuales y mejorando la precisión en la identificación de transiciones durante el test. El desarrollo detallado del algoritmo se presenta en el Capítulo 5.

4.5. Validación de la Segmentación Automática

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

Los datos capturados fueron analizados mediante el software Mokka®, donde un observador clínico segmentó manualmente las seis subetapas de cada prueba TUG, el cual se utilizó como *ground truth* para la validación.

4.5.1 Consideraciones para la Segmentación Manual de Subetapas

Los criterios para segmentar manualmente cada subetapa del test TUG mediante el software Mokka® se presentan en la Tabla 4-3. 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 [50].

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 [51].

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 [52]. 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 simultáneas.

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 4-3 Criterios biomecánicos para la identificación de Subetapas del test TUG.

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.
-----------------	---

4.6. Métricas de Evaluación

Con el fin de cuantificar el desempeño de la detección y segmentación automática del algoritmo, 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:

$$\Delta T = T_m - T_a \quad (4.1)$$

donde,

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

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

2) *Absolute Mean 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:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\Delta T_i| \quad (4.2)$$

3) *Precisión (Accuracy)*

Indica el porcentaje de detecciones correctas (coincidencia de subetapas detectadas por el algoritmo frente al Gold Standard).

$$Precisión = \frac{VP}{VP + FP} \quad (4.3)$$

4) *Sensibilidad*

Evalúa la capacidad del algoritmo para detectar correctamente los eventos presentes según la segmentación manual, considerando la tolerancia temporal. Se define como:

$$\text{Sensibilidad} = \frac{VP}{VP+FN} \quad (4.4)$$

donde,

VP (Verdaderos Positivos): Son los eventos correctamente detectados por el algoritmo, cuya duración se encuentra dentro del margen de tolerancia.

FP (Falsos Positivos): Son los eventos detectados por el algoritmo cuya duración se encuentra fuera del margen de tolerancia.

FN (Falsos Negativos): Eventos no detectados por algoritmo de segmentación.

5) *Coefficiente 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):

$$r = \frac{\Sigma(T_m - \bar{T}_m)(T_a - \bar{T}_a)}{\sqrt{\Sigma(T_m - \bar{T}_m)^2 \cdot \Sigma(T_a - \bar{T}_a)^2}} \quad (4.5)$$

Capítulo 5. Desarrollo Algoritmo de Segmentación

En este capítulo se presenta el desarrollo de un algoritmo de segmentación para la detección de eventos clave en el test *Timed Up and Go* (TUG). Este algoritmo, basado en un enfoque de reglas, utiliza señales obtenidas de sensores inerciales y técnicas avanzadas de procesamiento de señales para identificar de manera precisa las subetapas del test. Se emplea un enfoque de votación de jurados, que combina las decisiones de múltiples criterios.

En este contexto, el término jurado se refiere a un método o criterio independiente que procesa una señal específica (por ejemplo, la velocidad angular en el eje Y) para identificar uno o más eventos del TUG. Cada jurado utiliza técnicas de procesamiento de señales, como filtrado, derivación y umbralización, y permite detectar distintos patrones característicos asociados a movimientos en los diferentes ejes, en cada subetapa del test. La correspondencia entre las orientaciones de la IMU y los ejes anatómicos se ilustra en la Fig. 5.1.

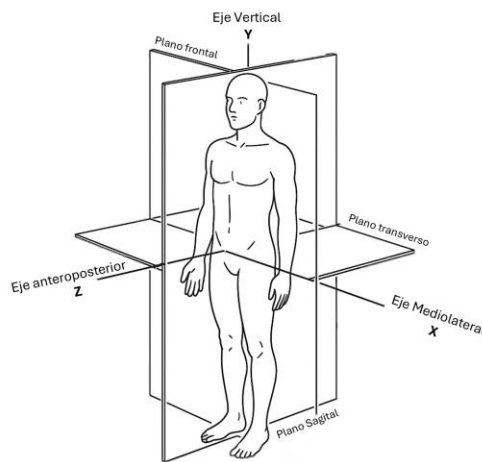


Fig. 5.1 Planos anatómicos y ejes XYZ del sistema de referencia de la IMU.

La Tabla 5-1 detalla las señales empleadas y los métodos específicos utilizados para la detección de cada evento.

Tabla 5-1 Jurados para algoritmo de detección de eventos en señales provenientes de los sensores inerciales.

Etapas TUG	Jurado 1	Jurado 2	Jurado 3
Pararse	Pitch	Velocidad Angular X	Aceleración Z
Caminata Ida	Pitch	Velocidad Angular X	Aceleración Z
Primer Giro	Yaw	Velocidad Angular Y	-

Caminata vuelta	Yaw	Velocidad Angular Y	-
Segundo Giro	Yaw	Velocidad Angular Y	-
Sentarse	Pitch	Velocidad Angular X	Aceleración Z

5.1. Preprocesamiento

La Tabla 5-2 muestra los pasos de preprocesamiento aplicados a cada señal inercial para optimizar la detección de eventos en el TUG.

Tabla 5-2 Preprocesamiento señales inerciales para detección de eventos.

Señal	Preprocesamiento
Aceleración eje Z	<ol style="list-style-type: none"> 1. Corrección de offset (respecto al valor inicial). 2. Suavizado con filtro de media móvil (ventana: 10 muestras).
Aceleración eje Y	<ol style="list-style-type: none"> 1. Corrección de offset (respecto al valor inicial). 2. Filtrado pasabanda Butterworth (4° orden, 0.1 Hz - 5 Hz). 3. Normalización z-score.
Vel. Angular eje Y	<ol style="list-style-type: none"> 1. Filtrado con filtro pasabanda Butterworth (4° orden, 0.1 Hz - 1 Hz). 2. Normalización z-score (centrado en cero y escalado por desviación estándar).
Vel. Angular eje X	Filtrado con filtro pasabanda Butterworth (4° orden, 0.1 Hz - 1 Hz).
Yaw	<ol style="list-style-type: none"> 1. Corrección de discontinuidades angulares ($\pm 180^\circ$ o $\pm 360^\circ$) 2. Centrado en cero y conversión a valor absoluto.
Pitch	<ol style="list-style-type: none"> 1. Corrección de offset (respecto al valor inicial). 2. Valor absoluto de la señal.

5.1.1 Corrección de discontinuidades señal Yaw

Para corregir las discontinuidades en la señal de *yaw*, primero se calcula la diferencia entre muestras sucesivas y se identifica cualquier salto mayor a 30° . Cada vez que se detecta un cambio brusco, se ajusta toda la sección subsiguiente de la serie: si el salto supera $\pm 180^\circ$, se asume que se trata de un desbordamiento de 360° y se corrige sumando o restando 360° ; en cambios intermedios, se resta el valor exacto del salto para mantener la continuidad. Este proceso se repite iterativamente hasta que no queden saltos mayores a 30° (o se alcance un máximo de diez iteraciones), y al final se centra la señal de modo que comience en cero y se toma su valor absoluto para quedarnos con la magnitud de rotación acumulada.

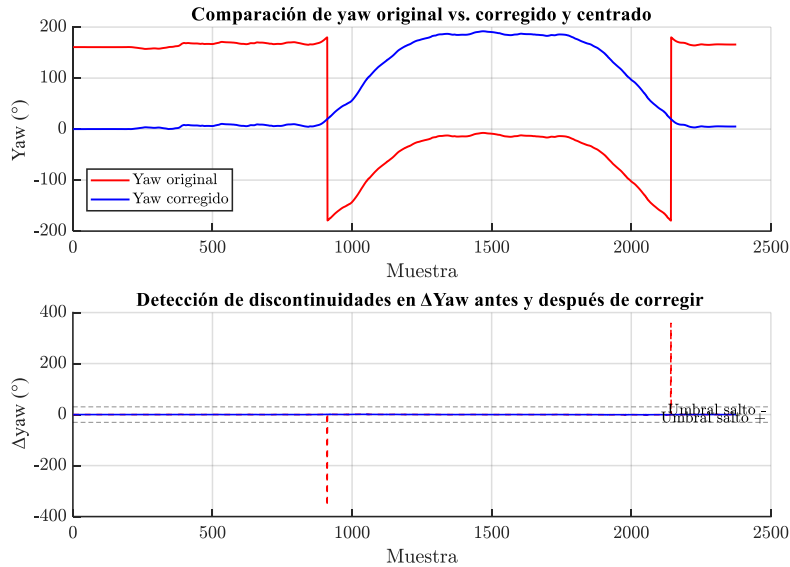


Fig. 5.2 Corrección de discontinuidades en señal yaw.

5.2. Detección Etapa Pararse

5.2.1 Jurado 1 (velocidad angular X)

Se identificó una caída abrupta en la derivada de la señal (ω_x), con un umbral de $-5^\circ/s^2$. El evento fue ajustado retrocediendo cinco muestras para capturar el término de la fase de impulso. El umbral de (ω_x) se basó en observaciones previas de patrones cinemáticos característicos del test Timed Up and Go (TUG), mostrando buena concordancia temporal con la ocurrencia del evento.

5.2.2 Jurado 2 (aceleración Z)

Se analizó la derivada de a_z en el primer tercio de la prueba. Se identificó una pendiente ascendente pronunciada (>1 o 2 m/s^3), como indicadora de la fase de impulso inicial, correspondiente al empuje de los pies contra el suelo para iniciar el alzamiento del tronco.

5.2.3 Jurado 3 (pitch)

Se buscó el primer valor de la inclinación del tronco dentro del rango $[10^\circ-70^\circ]$ durante el primer tercio de la prueba. Si no se encontraba, se seleccionó el valor más cercano al centro del rango. Este rango representa el ángulo típico de inclinación anterior del tronco que ocurre durante la fase inicial de impulso, antes de que el centro de masa se traslade verticalmente hacia la posición de

bipedestación. Se ha reportado que este patrón de flexión del tronco es un prerequisite mecánico para generar el momento necesario para levantarse [53].

5.3. Detección Etapa Caminata Ida

5.3.1 Jurado 1 (Velocidad angular X)

Se localizó el valor máximo de (ω_x) , en el primer tercio de la señal, y luego se identificó el primer valor en que la señal se estabilizaba entre 0.01 y $0.6^\circ/s$, indicando inicio de desplazamiento.

5.3.2 Jurado 2 (Aceleración Z)

Tras una espera mínima de 0.5 segundos desde *Standing*, se detectó una caída abrupta en la derivada de a_z , seguida por la identificación del valor mínimo en una ventana de 0.7 segundos. Este mínimo fue interpretado como el inicio de la marcha.

5.3.3 Jurado 3 (Pitch)

Se identificó el primer máximo de inclinación del tronco tras *Standing*, y luego se localizó una caída de al menos 15° , lo que indica el retroceso del tronco al iniciar el paso [54].

La detección de los eventos pararse y caminata ida a partir de los jurados descritos se ilustra en la Fig 5.3.




Fig. 5.3 Detección de eventos Pararse y Caminata ida mediante distintos jurados y su consenso.

5.4. Detección Primer Giro

5.4.1 Jurado 1 (Yaw)

El jurado 1 utilizó la señal de orientación yaw para identificar el momento en que se produce una rotación significativa del tronco en el plano transversal. Primero, se clasificó el patrón de la señal yaw según su forma global: Si la señal se acercaba a 180° y luego volvía a 0° , se etiquetó como *yaw_180*. Por el contrario, si progresaba de 0° a 180° y luego continuaba hacia 360° , se consideró *yaw_360*. Posteriormente, se analizó el primer 40 % de la señal yaw para calcular su media y su variabilidad. Si el valor medio de la señal superaba los 14 grados, se aplicó un umbral dinámico, el cual se estableció sumando 2.5 veces la desviación estándar de ese segmento a la media calculada. En casos con menor movilidad angular, se estableció un umbral fijo de 24° , consistente con valores reportados para rotaciones mínimas requeridas para ejecutar giros funcionales en adultos mayores [55]. A partir de ese valor umbral, se buscó el primer punto en que la señal yaw lo superara, dentro del rango temporal comprendido entre el inicio de la marcha y el 60 % de la duración de la señal. Si se detectó un cruce, se marcó el tiempo correspondiente como evento *Primer Giro*.

5.4.2 Jurado 2 (Velocidad angular en el eje Y)

El jurado 2 complementó la detección utilizando la señal de velocidad angular sobre el eje Y (ω_y), sensible a rotaciones axiales del tronco. Se aplicó un umbral dinámico correspondiente al 45 % del valor máximo de la señal filtrada. Se identificaron los picos que superaban este umbral y se seleccionó el primero como referencia.

A partir del primer peak, se definió una ventana retrospectiva de búsqueda de 1 segundo, dentro de la cual se localizó el mínimo local de la señal. Este punto fue interpretado como el inicio del giro, y registrado como el evento *Primer Giro*. La detección mediante ambos jurados se evidencia en la Fig. 5.4.

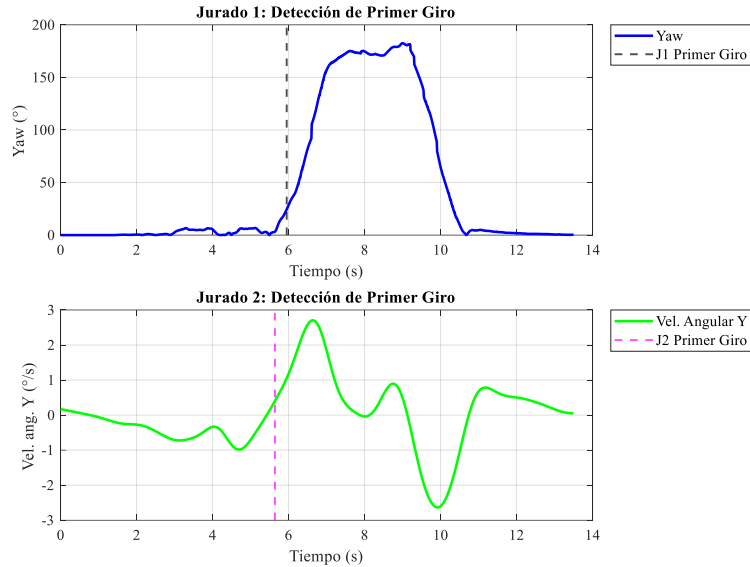


Fig. 5.4 Detección Primer Giro a través de señal Yaw y Velocidad Angular Y.

5.5. Detección Caminata Vuelta

5.5.1 Jurado 1 (yaw)

Se aplicó un umbral fijo de 145° para detectar el momento en que el tronco alcanza una orientación suficiente como para indicar el cambio de dirección. Para evitar falsos positivos, se inició la búsqueda 0.5 segundos después del evento *Primer Giro*. Si se detectaba un cruce de umbral, se analizaba una ventana de 0.5 segundos posteriores en busca del valor máximo de yaw. El evento *Return Walking* fue asignado al primer instante dentro de esa ventana en que se alcanzaba dicho máximo, confirmando el inicio de la marcha de regreso.

5.5.2 Jurado 2 (velocidad angular Y)

A partir del primer pico detectado en la etapa *Primer Giro*, se definió una ventana temporal entre 0.5 y 1 segundo. Dentro de ese intervalo, se examinó la señal de velocidad angular en Y en busca de un mínimo significativo, interpretado como la estabilización tras el giro. El tiempo correspondiente a ese mínimo se registró como el evento *Caminata Vuelta*, siempre que ocurriera dentro del rango permitido. La detección de este evento a través de este jurado se evidencia en la Fig. 5.4.

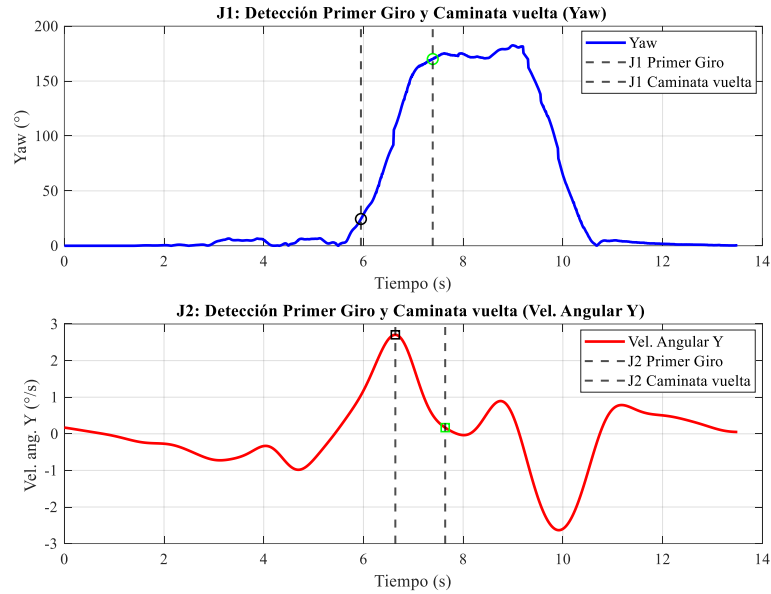


Fig. 5.5 Detección de Caminata Ida mediante velocidad angular en eje Y.

5.6. Detección Segundo Giro

5.6.1 Detección del inicio del giro

En el caso de señales tipo *yaw_180*, se identificó el valor máximo de yaw posterior al evento *Return Walking*. Desde ese punto en adelante, se buscó el primer cruce descendente por debajo de 170° , interpretado como el inicio del segundo giro. Para señales tipo *yaw_360*, se buscó directamente el primer cruce ascendente que superara los 200° , como indicativo del inicio de la rotación final.

5.6.2 Detección del fin del giro

Una vez detectado el inicio del giro, se procedió a localizar su término. Para *yaw_180*, se buscó el primer cruce por debajo de 10° tras el giro, seguido de una verificación de estabilidad: se exigió que la señal se mantuviera sin rebotes por debajo de 20° durante al menos 0.5 segundos. En el caso de *yaw_360*, se marcó como fin del giro el primer cruce por encima de 345° , sin aplicar ventana de estabilización. La segmentación del segundo giro se evidencia en la Fig. 5.6.

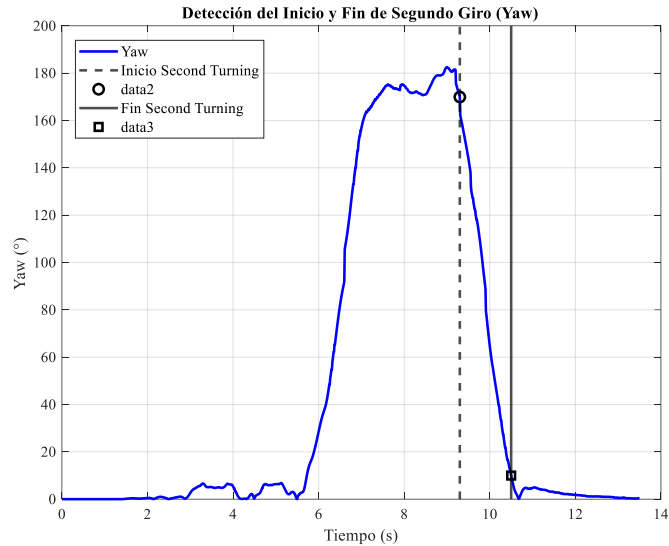


Fig. 5.6 Segmentación Segundo giro mediante señal Yaw.

5.7. Detección Sentarse

5.7.1 Jurado 1 (Velocidad angular eje X)

Se analizó el último tercio de la señal de velocidad angular para identificar una caída igual o superior a 1 rad/s respecto al valor inicial del segmento. Si dicha caída ocurría cerca del mínimo local de la señal (a menos de 0.2 segundos), se retrocedía medio segundo desde el punto detectado para ubicar el inicio del movimiento de descenso. El evento *Sentarse* fue marcado en ese instante ajustado.

5.7.2 Jurado 2 (Aceleración eje Y)

Se identificaron los peaks prominentes de la señal de aceleración vertical durante el último tercio de la prueba. Se seleccionó el de mayor magnitud, asociado al impacto o estabilización al sentarse. Luego, se retrocedieron 0.5 segundos desde dicho pico para estimar el inicio del movimiento descendente y marcar el evento *Sentarse*.

5.7.3 Jurado 3 (Pitch)

Se aplicó un enfoque adaptativo. Primero, se estimó una línea base en el tercio medio de la señal de pitch y se calculó un umbral dinámico sumando un valor fijo (7 a 8 grados) a dicha base. Desde el último tercio de la señal, se localizó el pico principal de inclinación del tronco y, hacia atrás, se buscó el primer tramo de al menos 0.3 segundos donde el pitch se mantuviera por debajo del umbral, indicando el inicio sostenido del descenso. Si no se encontraba este patrón, se ajustaba el umbral o se

usaba el punto de máxima pendiente como respaldo. El evento *Sitting* fue marcado en el punto mínimo refinado más próximo.

5.7.4 Fin de la Etapa *Sitting*

Para determinar el final de la prueba, se utilizó nuevamente la señal de pitch. Se buscó el primer cruce descendente por debajo de 10° , posterior al pico principal del descenso. El evento fue confirmado solo si la señal se mantenía por debajo de ese umbral durante al menos 0.3 segundos consecutivos, indicando que el participante había finalizado completamente la acción de sentarse.

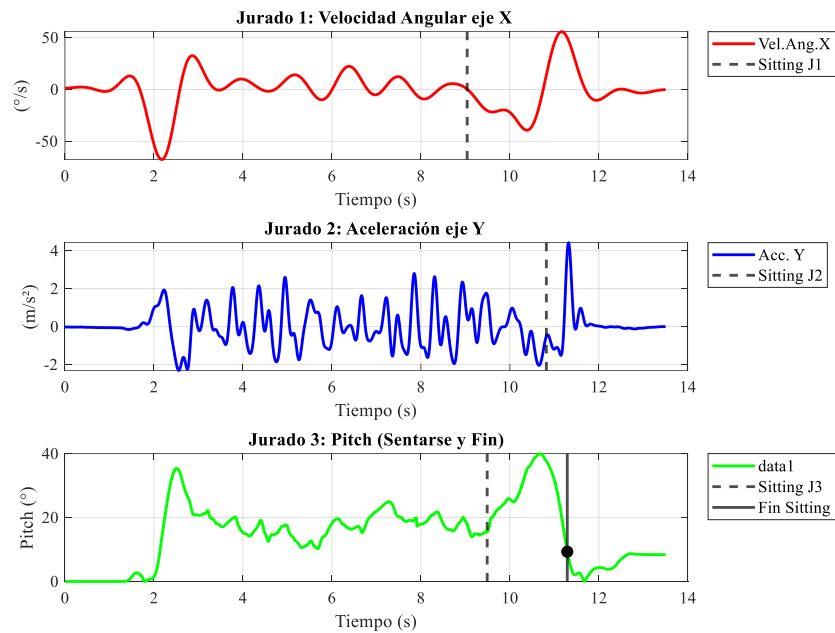


Fig. 5.7 Detección inicio y fin de subetapa sentarse.

5.8. Determinación del Consenso Ponderado para la Segmentación de Eventos

Con el fin de obtener una estimación robusta del tiempo de ocurrencia de cada evento dentro del test Timed Up and Go (TUG), se implementó un mecanismo de consenso ponderado basado en la detección realizada por tres jurados independientes (J1, J2 y J3). Este método considera un promedio ponderado de los tiempos identificados por cada jurado, donde los pesos asignados reflejan el grado de confianza de cada jurado con la segmentación manual, considerada Ground Truth. El resultado de esta operación define la duración de cada subetapa del test TUG.

La Tabla 5-3 presenta los pesos asignados a cada jurado para las distintas subetapas del TUG, los cuales fueron determinados con base en coeficientes de correlación obtenidos durante una etapa preliminar de validación.

Tabla 5-3 Pesos asignados a jurados en las etapas del test TUG para consenso ponderado.

Etapas TUG	Jurado 1	Jurado 2	Jurado 3
Pararse	0.06	0.52	0.42
Caminata Ida	0.06	0.52	0.42
Primer Giro	0.91	0.09	-
Caminata Vuelta	0.90	0.10	-
Segundo Giro	1.00	-	-
Sentarse	0.10	0.10	0.80

Un ejemplo representativo de la segmentación completa de un intento mediante este método puede observarse en la Fig 5.8.




Fig. 5.8 Segmentación automática del test TUG por algoritmo de consenso ponderado.

5.9. Integer Lineal Programming (ILP)

La Programación Lineal Entera (ILP) es una técnica de optimización matemática que extiende la programación lineal al imponer que algunas o todas las variables de decisión tomen valores enteros, permitiendo modelar problemas de selección y asignación discreta [56]. Con el objetivo de minimizar el error en la estimación de las duraciones de las subetapas del test TUG, se implementó un modelo de Programación Lineal Entera (ILP). Este modelo formaliza la selección de los tiempos de segmentación propuestos por los jurados (J1, J2 y J3), buscando minimizar el error absoluto respecto a los tiempos de referencia segmentados manualmente.

El modelo ILP introduce variables binarias que representan la selección exclusiva de un jurado para cada evento, asegurando que solo uno de los tiempos propuestos sea elegido. La función objetivo se orienta a minimizar la suma total de errores absolutos entre las segmentaciones seleccionadas y los tiempos de referencia.

Para construir este modelo, se calculó el error promedio absoluto de cada jurado por subetapa dado por la (4.2), y se formuló una matriz de decisión en la que el jurado con menor error en cada caso fue asignado como la opción óptima. De esta forma, el modelo ILP permite integrar decisiones discretas bajo restricciones de unicidad y consistencia, generando un esquema de segmentación basado en las fuentes más confiables para cada etapa del test. La Tabla 5-4 resume los jurados seleccionados para cada subetapa del TUG.

Tabla 5-4 Jurado seleccionado por cada subetapa TUG.

Etapas TUG	Decisión
Pararse	Aceleración Z
Caminata Ida	Velocidad Angular X
Primer Giro	Yaw
Caminata vuelta	Yaw
Segundo Giro	Yaw
Sentarse	Aceleración Z

Capítulo 6. Resultados

A continuación se presentan los resultados obtenidos a partir de la aplicación del algoritmo de segmentación automática al test Timed Up and Go (TUG), utilizando señales inerciales y validando frente a la segmentación manual obtenida a través de los datos ópticos.

6.1. Desempeño Algoritmos de Segmentación iTUG

Para evaluar los algoritmos de Consenso ponderado de jurados y modelo ILP, se calculó su error absoluto promedio (MAE, Tabla 6-1), precisión y sensibilidad (Tabla 6-2), utilizando un margen de tolerancia de 0.5 s. Este umbral se definió con base en el MAE promedio observado en todas las subetapas del TUG a través de las 225 pruebas analizadas. Finalmente, correlación lineal de Pearson, tanto a nivel global como por subetapa (Tabla 6-3). Esta relación se visualiza en los gráficos de dispersión de la Fig. 6.1, (duraciones por subetapa del Consenso ponderado vs. ground truth). Complementariamente, la Fig. 6.2 ilustra los diagramas de dispersión, para cada intento, en los que se comparan las duraciones obtenidas por el algoritmo de consenso ponderado con los tiempos de referencia.

Tabla 6-1 Error absoluto promedio en segundos por etapa TUG de segmentación automática.

MAE	Pararse	Caminata Ida	Primer Giro	Caminata Vuelta	Segundo Giro	Sentarse	Duración total
Consenso	0.30	0.44	0.40	0.56	0.56	0.81	1.02
ILP	0.28	0.47	0.37	0.56	0.55	0.67	1.11

Tabla 6-2 Sensibilidad y precisión por subetapa del test TUG, promediando los tres intentos por participante, para los algoritmos de consenso ponderado e ILP.

Evento	Consenso Ponderado		ILP	
	Sensibilidad	Precisión	Sensibilidad	Precisión
Pararse	0.97	0.97	0.85	0.92
Caminata Ida	0.91	0.91	0.82	0.89
Primer Giro	0.91	0.90	0.88	0.88
Caminata Vuelta	0.82	0.82	0.82	0.82
Segundo Giro	0.82	0.81	0.82	0.81
Sentarse	0.68	0.67	0.72	0.75

Tabla 6-3 Coeficientes de Pearson entre las predicciones del algoritmo (Consenso Ponderado e ILP) y el Ground Truth para las etapas del test TUG en tres intentos.

Etapas TUG	Consenso Ponderado			ILP		
	Intento 1	Intento 2	Intento 3	Intento 1	Intento 2	Intento 3
Pararse	0.53	0.45	0.36	0.06	0.11	0.06
Caminata Ida	0.82	0.88	0.75	0.89	0.90	0.84
Primer Giro	0.40	0.10	0.21	0.41	0.18	0.25
Caminata Vuelta	0.85	0.70	0.58	0.87	0.67	0.54
Segundo Giro	0.17	0.43	0.60	0.17	0.43	0.60
Sentarse	0.29	0.26	0.44	0.24	0.30	0.40
Duración total	0.93	0.96	0.92	0.81	0.95	0.91

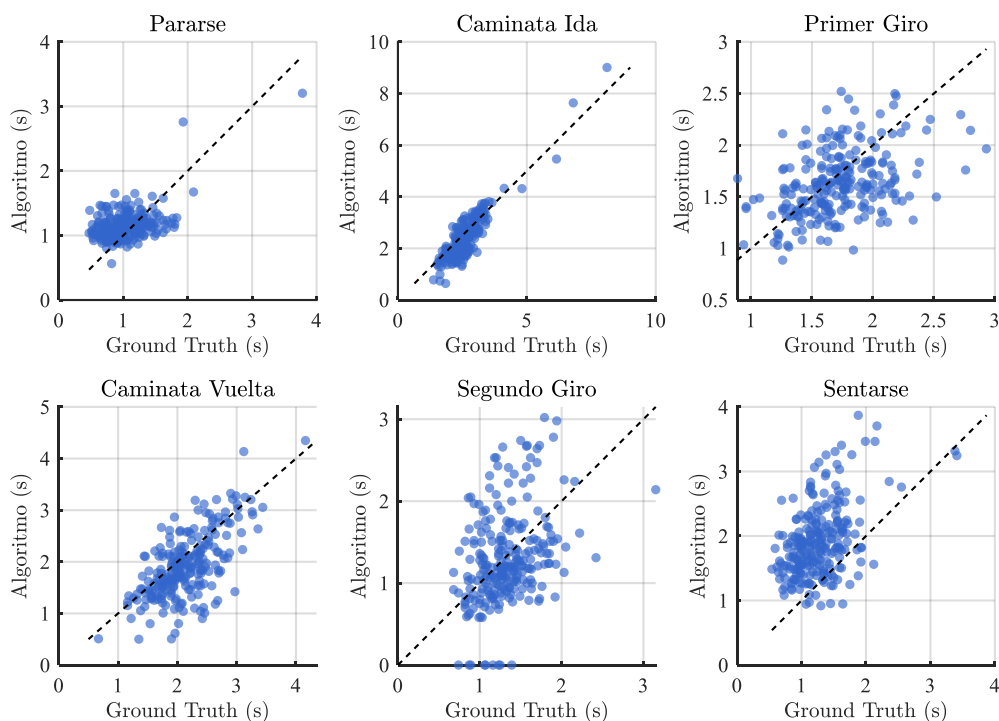


Fig. 6.1 Gráficos de dispersión de la duración por subetapa estimada entre el algoritmo de consenso ponderado y la duración real en los intentos promediados del test TUG.

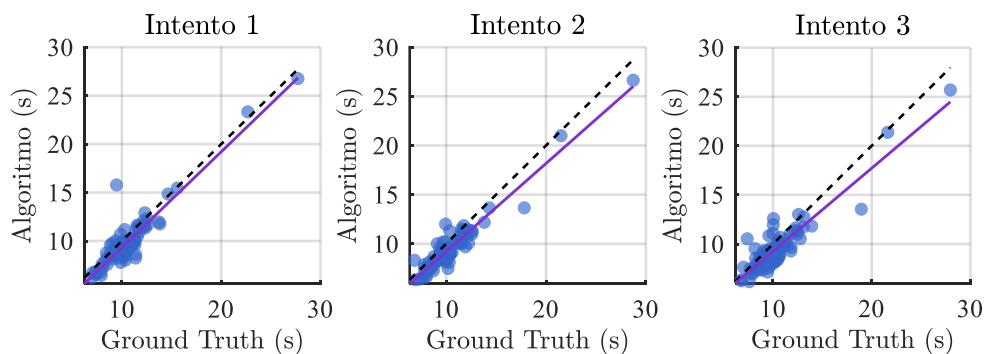


Fig. 6.2 Gráficos de dispersión de la duración por subetapa estimada por el algoritmo versus la duración real en los intentos promediados del test TUG.

6.2. Duración Subetapas TUG

Para analizar la variabilidad de la ejecución del TUG según la edad, se presentan en la Tabla 6-4 las duraciones promedio de cada subetapa obtenidas por segmentación manual, y en la Tabla 6-5 las obtenidas mediante el algoritmo automático. En las Fig. 6.3 y 6.4 se evidencian las tendencias temporales, por subetapa y tiempo total, para cada rango etario.

Tabla 6-4 Duración promedio de cada subetapa TUG (s) según segmentación manual (Ground Truth).

Edad	Pararse	Caminata Ida	Primer Giro	Caminata Vuelta	Segundo Giro	Sentarse	Tiempo Total
49-59	1.11	2.41	1.56	1.99	1.33	1.22	9.61
60-69	0.98	2.49	1.77	2.09	1.32	1.25	9.90
70+	1.20	3.26	2.04	2.92	1.54	1.41	12.37

Tabla 6-5 Duración promedio de cada subetapa TUG (s) según algoritmo de consenso ponderado.

Edad	Pararse	Caminata Ida	Primer Giro	Caminata Vuelta	Segundo Giro	Sentarse	Tiempo Total
49-59	1.16	2.11	1.62	1.65	1.24	1.89	8.69
60-69	1.14	2.23	1.68	1.87	1.32	1.89	9.14
70+	1.24	3.18	1.80	2.45	1.77	2.42	11.72




Fig. 6.3 Duración promedio por subetapa según grupo etario (Segmentación Manual).




Fig. 6.4 Duración promedio por subetapa según grupo etario a partir de señales inerciales (Segmentación Algoritmo Consenso).

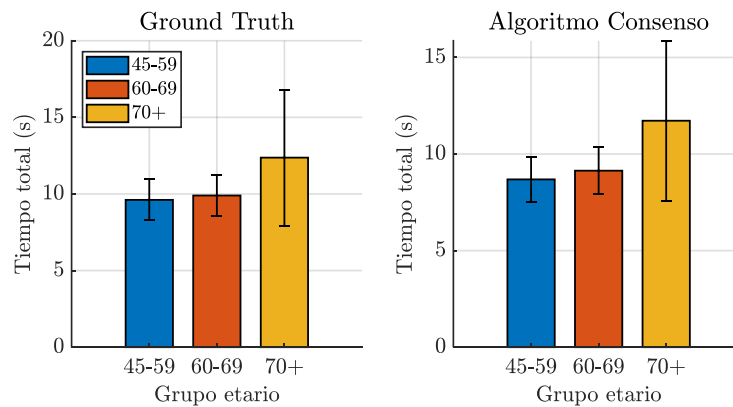


Fig. 6.5 Comparación de los tiempos totales del test Timed Up and Go (TUG) según grupo etario, obtenidos mediante segmentación manual (Ground Truth) y el algoritmo de consenso.

Capítulo 7. Discusiones y Conclusiones

7.1. Discusión

Los resultados de esta memoria demuestran el potencial de la segmentación automática, tanto mediante el modelo de consenso ponderado de jurados como utilizando el algoritmo de programación lineal entera (ILP), para identificar eventos y cuantificar subetapas en el test Timed Up and Go (TUG). Esta aproximación permite ir más allá del análisis del tiempo total, posibilitando una caracterización más específica y objetiva del desempeño funcional del paciente.

El modelo de consenso ponderado de jurados se basa en la integración de múltiples señales (o "jurados") para cada etapa, permitiendo que, si uno de ellos no detecta la ocurrencia de un evento, otra señal pueda suplir esa carencia. Esta lógica otorga mayor sensibilidad al método, como se evidencia en los resultados de la Tabla 6-2, ya que aumenta la probabilidad de captar transiciones en la ejecución del TUG, incluso ante señales ruidosas o participantes atípicos. Por otro lado, el modelo ILP minimiza el error seleccionando la señal que tiene menor error absoluto promedio, donde si bien, se obtiene una mejor precisión temporal, la sensibilidad se ve disminuida, ya que solo una señal es responsable de detectar cada evento. Así, cuando la señal seleccionada no es representativa para cierto participante, el evento puede no ser detectado.

La segmentación manual ofrece una referencia, no solo para el tiempo total, sino para caracterizar la duración de cada subetapa. Sin embargo, este método implica un error asociado al criterio individual y a la reacción temporal al marcar el inicio o término de cada evento, como ocurre al iniciar o pausar la adquisición de los datos. En la segmentación automática, el consenso ponderado logra valores cercanos a los de referencia, reduciendo el error en comparación a métodos más tradicionales, basados en umbrales fijos o la utilización de una o dos señales [38].

En la Tabla 6-1 se observa que el error absoluto promedio (MAE) es mayor en fases breves y de transición, especialmente en la subetapa Sentarse. Esto puede explicarse por la simultaneidad de eventos: durante el segundo giro y el sentado, algunos participantes realizan el giro y la transición al sentado en un solo movimiento (caso 1), mientras que otros hacen una pausa en bipedestación antes de sentarse (caso 2), como se discute en el Capítulo 4.6.1 [51]. Estas diferencias clínicas generan

dificultad para delimitar de manera exacta el inicio y término de los eventos, tanto para el observador como para el algoritmo.

Respecto a la correlación de Pearson (Tabla 6-5), ambos algoritmos muestran alto acuerdo con el ground truth para la duración total (consenso: 0.92–0.96; ILP: 0.81–0.95). Sin embargo, a nivel de subetapa la correlación es variable: en las fases de Caminata Ida y Caminata Vuelta, la correlación es alta ($>0.7-0.9$), confirmando que los algoritmos segmentan de manera fiable estos intervalos más estables y prolongados. En contraste, Pararse, Primer Giro y Sentarse muestran correlaciones considerablemente menores (<0.5), reflejando la mayor dificultad de segmentar fases breves, transiciones rápidas y eventos que pueden superponerse, tanto en la segmentación manual como automática. A su vez, la variabilidad entre intentos es moderada, destacando la necesidad de evaluar la robustez inter-intentos en estudios futuros y explorar estrategias para estabilizar la detección en fases críticas.

El análisis de las duraciones promedio por subetapa mediante segmentación manual (Tabla 6-3) evidencia que, para los tres rangos etarios, las etapas de mayor duración corresponden a Caminata Ida y Caminata Vuelta, seguidas de los giros, mientras que Pararse es la más breve. El algoritmo de consenso ponderado (Tabla 6-4) reproduce correctamente esta tendencia en comparación a los tiempos de referencia, aunque existen diferencias absolutas atribuibles a las ya mencionadas dificultades en la segmentación de eventos solapados.

Tanto el análisis manual como el automático muestran que, a mayor edad, mayor duración en cada subetapa y en el tiempo total del TUG, con diferencias especialmente notorias entre los grupos de 60-69 y 70+ años (2.47 segundos en el tiempo total), lo que puede tener relevancia para la estratificación del riesgo de caídas y la definición de puntos de corte poblacionales. Incluso la diferencia entre los grupos 49-59 y 60-69 años es prácticamente significativa (0.29 segundos). Esto refuerza la importancia de analizar los tiempos de corte ajustados para la población chilena [57], considerando la tendencia observada en la Fig. 6-3 y 6-4.

Una de las ventajas más relevantes de la segmentación automática es la posibilidad de acceder a las señales asociadas a cada subetapa, permitiendo caracterizar no solo su duración, sino parámetros

adicionales como la velocidad de giro, ángulo de inclinación del tronco, aceleración y otras variables biomecánicas de interés, que superan el análisis clásico del tiempo total del TUG [11], [26] .

Por otro lado, debe reconocerse que todas las metodologías presentan fuentes de error inherente. En la segmentación manual, el criterio subjetivo y la latencia humana afectan la exactitud, mientras que en la segmentación automática la precisión depende tanto de la calidad de las señales como de la definición operacional de cada evento.

7.2. Conclusión

La presente memoria contribuye de manera significativa al avance en la evaluación funcional y objetiva del riesgo de caídas en personas adultas y mayores, mediante la validación y optimización de un algoritmo automático para la segmentación de subetapas del test Timed Up and Go (TUG) utilizando sensores inerciales. Los resultados obtenidos evidencian que el enfoque de consenso ponderado de jurados, basado en la integración de múltiples señales y criterios, permite una detección robusta y precisa de eventos críticos del TUG, superando las limitaciones de los métodos tradicionales basados exclusivamente en el tiempo total o en umbrales fijos.

Se ha demostrado que la segmentación automática posibilita una caracterización más detallada de la movilidad funcional, permitiendo identificar patrones específicos de dificultad en fases como los giros o la transición al sentado, los cuales suelen pasar desapercibidos en la evaluación clínica convencional [15], [29], [55]. En particular, el algoritmo propuesto mostró alta sensibilidad y precisión en las etapas de marcha y giros prolongados, reproduciendo las tendencias observadas en el análisis manual y permitiendo analizar diferencias significativas entre distintos grupos etarios. Además, la correlación elevada con la segmentación manual en la duración total y en las fases estables del TUG respalda la fiabilidad de la propuesta, destacando su aplicabilidad clínica para la estratificación del riesgo de caídas.

No obstante, persisten desafíos en la segmentación de eventos breves y de transición, especialmente cuando existen variaciones en la estrategia motora de los participantes (como la pausa entre el giro y el sentado), lo que sugiere la necesidad de seguir perfeccionando los criterios

adaptativos y considerar la integración de métodos basados en aprendizaje automático para fases críticas. La variabilidad inter-intentos observada también enfatiza la importancia de robustecer los algoritmos frente a diferencias intra e inter-sujeto, aspecto crucial para su uso en la práctica clínica real.

Una de las principales ventajas de este enfoque es la posibilidad de extraer, a partir de las señales inerciales, parámetros biomecánicos adicionales relevantes para el análisis clínico, lo que abre nuevas oportunidades para la evaluación cuantitativa y el seguimiento longitudinal de la movilidad en poblaciones envejecidas o con riesgo aumentado de caídas.

7.3. Trabajo Futuro

Como proyección, se plantea el perfeccionamiento del algoritmo desarrollado para su aplicación en distintas poblaciones y rangos etarios, incluyendo personas con patologías neurológicas como la enfermedad de Parkinson. Resulta fundamental adaptar y validar la segmentación automática en estos grupos, considerando sus particularidades clínicas y patrones de movimiento.

Asimismo, se propone avanzar en la caracterización de variables cinemáticas adicionales a la duración de cada subetapa, tales como la potencia generada, ángulos de inclinación, velocidades angulares y aceleraciones durante las transiciones del test TUG. El análisis de estos parámetros permitirá obtener valores de referencia diferenciados por edad y condición clínica, potenciando la identificación temprana de alteraciones funcionales.

Finalmente, se recomienda integrar estos algoritmos a soluciones portátiles y de bajo costo basadas en IMU, facilitando su uso en entornos clínicos y comunitarios para el monitoreo y diagnóstico objetivo del riesgo de caídas. De esta manera, se contribuye a la consolidación de herramientas tecnológicas accesibles y precisas que puedan impactar de manera positiva la atención y prevención en salud pública.

Capítulo 8. Glosario

TUG	: Prueba de Levantarse y Andar, en inglés, Timed Up and Go.
IMU	: Unidad de Medición Inercial, en inglés, Inertial Measurement Unit.
MOCAP	: Captura de Movimiento, en inglés, Motion Capture.
ILP	: Programación Lineal Entera, en inglés, Integer Linear Programming

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] 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.
- [36] 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.
- [37] 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.
- [38] J. H. Ansai, A. C. S. Farche, P. G. Rossi, L. P. de Andrade, T. H. Nakagawa, y A. C. de M. Takahashi, «Performance of Different Timed Up and Go Subtasks in Frailty Syndrome», *Journal of Geriatric Physical Therapy*, vol. 42, n.º 4, p. 287, dic. 2019, doi: 10.1519/JPT.000000000000162.
- [39] 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>
- [40] 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.
- [41] 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.
- [42] 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.
- [43] 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.
- [44] 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.
- [45] 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: 18 de noviembre de 2024. [En línea]. Disponible en: <https://repositorio.udec.cl/handle/11594/8893>
- [46] 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.

- [47] 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.
- [48] E. P. Washabaugh, T. Kalyanaraman, P. G. Adamczyk, E. S. Clafin, 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.
- [49] 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.
- [50] 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.
- [51] 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.
- [52] 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.
- [53] N. Millor, P. Lecumberri, M. Gómez, A. Martínez-Ramírez, y M. Izquierdo, «An evaluation of the 30-s chair stand test in older adults: frailty detection based on kinematic parameters from a single inertial unit», *J Neuroeng Rehabil*, vol. 10, p. 86, ago. 2013, doi: 10.1186/1743-0003-10-86.
- [54] M. Schenkman, R. A. Berger, P. O. Riley, R. W. Mann, y W. A. Hodge, «Whole-Body Movements During Rising to Standing from Sitting», *Physical Therapy*, vol. 70, n.º 10, pp. 638-648, oct. 1990, doi: 10.1093/ptj/70.10.638.
- [55] R. Z. U. Rehman *et al.*, «Turning Detection During Gait: Algorithm Validation and Influence of Sensor Location and Turning Characteristics in the Classification of Parkinson's Disease», *Sensors*, vol. 20, n.º 18, Art. n.º 18, ene. 2020, doi: 10.3390/s20185377.
- [56] G. M. Nasira y S. A. Kumar, «A Backpropagation neural network implementation for hybrid algorithm in solving Integer Linear Programming Problems», en *2010 Second International conference on Computing, Communication and Networking Technologies*, jul. 2010, pp. 1-6. doi: 10.1109/ICCCNT.2010.5591664.
- [57] J. U. Ll y F. V. R, «Sensibilidad y especificidad de la prueba Timed Up and Go. Tiempos de corte y edad en adultos mayores», *Revista Médica de Chile*, vol. 149, n.º 9, Art. n.º 9, jun. 2021, Accedido: 4 de enero de 2025. [En línea]. Disponible en: <https://www.revistamedicadechile.cl/index.php/rmedica/article/view/8752>

**UNIVERSIDAD DE CONCEPCION – FACULTAD DE INGENIERIA
RESUMEN DE MEMORIA DE TITULO**

Departamento : Departamento de Ingeniería Eléctrica
Carrera : Ingeniería Civil Biomédica
Nombre del memorista : Loreto Valentina Rojas Sandoval
Título de la memoria : Evaluación Crítica de Algoritmos de Segmentación del test Timed Up and Go (TUG) basados en IMU
Fecha de la presentación oral :

Profesor(es) Guía : Pablo Aqueveque Navarro
Profesor(es) Revisor(es) : Paulina Ortega Bastidas y Pedro Pinacho Davidson
Concepto :
Calificación :

Resumen (máximo 200 palabras)

El Timed Up and Go (TUG) evalúa movilidad y riesgo de caídas, pero su enfoque tradicional (tiempo total) ignora aspectos cualitativos. La integración de sensores inerciales (IMU) y algoritmos permite segmentar el TUG en subetapas, mejorando la detección de deficiencias.

Este estudio desarrolló y validó un algoritmo automático de segmentación usando una IMU. Se comparó con el sistema OptiTrack y se evaluó su precisión, sensibilidad, error promedio (MAE) y correlación con segmentación manual.

En 75 participantes de diferentes edades, el algoritmo logró sensibilidad y precisión de hasta 0.97, con MAE <1 segundo en la mayoría de subetapas. Mostró alta correlación ($r > 0.90$) con la segmentación manual en duración total y fases estables. Además, se observó un aumento progresivo en los tiempos de ejecución según la edad, destacando su utilidad para detectar variaciones funcionales.

Los resultados demuestran que la segmentación automática con IMU complementa la evaluación clínica, ofreciendo métricas objetivas para monitorear y prevenir caídas. Esta herramienta facilita la integración del TUG automatizado en entornos de salud con alta precisión.