

UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA



Profesor Patrocinante:

D.Sc. Pablo Esteban Aqueveque Navarro.

Profesor co-guía:

Dr. Roberto Cano-de-la-Cuerda.

Informe de Tesis
para optar al grado de:

Doctor en Ciencias de la Ingeniería con mención en Ingeniería Eléctrica

Desarrollo e implementación de una estrategia para la evaluación automática del riesgo de caídas en personas usando sensores inerciales

Concepción, octubre de 2021

M.Sc. Britam Arom Gómez Arias

Universidad de Concepción
Facultad de Ingeniería
Departamento de Ingeniería Eléctrica

Profesor Patrocinante:
D.Sc. Pablo Esteban Aqueveque Navarro.

DESARROLLO E IMPLEMENTACIÓN DE UNA ESTRATEGIA PARA LA EVALUACIÓN AUTOMÁTICA DEL RIESGO DE CAÍDAS EN PERSONAS USANDO SENSORES INERCIALES



M.Sc. Britam Arom Gómez Arias

Informe de Tesis
para optar al Grado de

Doctor en Ciencias de la Ingeniería con mención en Ingeniería Eléctrica

octubre 2021

Resumen

Este trabajo presenta una investigación referente a la identificación y el análisis automático del movimiento humano mientras se realizan evaluaciones clínicas sensorizadas para determinar el riesgo de caídas en población objetivo. El proyecto incluye la implementación de un sistema de medición con una Unidad de Medición Inercial bajo las características propias de un sistema “wearable”: portable, autónomo, inalámbrico y ergonómico, y el posterior procesamiento para la identificación de las actividades realizadas durante la aplicación del “Timed Up & Go Test” de 3-metros y su versión extendida (6-metros).

Con esto, se propone un análisis automático para la extracción de los índices y/o características correspondientes que caracterizan el movimiento humano durante el “Timed Up & Go Test” y la marcha usando el Test de 10 metros como referencia para su versión extendida y, de esta manera, otorgar una evaluación automática y específica del riesgo de caídas usando algoritmos de aprendizaje automático.

Los resultados obtenidos en cuanto a la identificación del riesgo en cada una de las actividades observadas durante la realización del “Timed Up & Go Test” van de bien a excelente, con un “Recall” (sujetos con riesgo de caídas respecto al total de sujetos con riesgo) de un 88.46% en las fases de pararse y del primer giro, hasta un 100% en las fases del primer giro y en la marcha del “Timed Up & Go Test” no extendido, comprobando que mediante el uso de una Unidad de Medición Inercial ubicada en la espalda y algoritmos de aprendizaje automático se puede determinar el riesgo de caídas en sujetos durante el “Timed Up & Go Test” y su versión extendida, no solo de manera global, sino también de manera específica al segmentar las actividades realizadas durante su ejecución.

Esta tesis contribuye a la investigación y desarrollo de sistemas para el análisis y monitoreo clínico del movimiento humano, centrándose en el reconocimiento automático de actividad humana y en la extracción de índices que caracterizan el riesgo de caídas.



A mi familia, grupo de investigación y desarrollo...

Gracias por todo

Agradecimientos

Este trabajo ha sido apoyado por una gran cantidad de personas, de las cuales el Dr. Pablo Aqueveque ha participado de manera activa, involucrándose en cada etapa del mismo desde los inicios en aquellos años en donde se le ofrecía un trabajo con sensores inerciales a un estudiante de pregrado. Gracias por todo lo que aportó, desde los recursos, las oportunidades y el tiempo dedicado para llevar a cabo esta etapa de mi vida.

Durante estos años, Paulina Ortega ha colaborado en la búsqueda de oportunidades y ha funcionado como el complemento perfecto para llevar mi trabajo ingenieril a la realidad, enfocando protocolos y tecnologías no sólo al servicio de la ciencia, sino que al servicio de la comunidad. En particular, este trabajo tiene mucho de ella, de su experiencia, guía y ganas de aportar en la comunidad académica y social.

En los últimos dos años de mi trabajo doctoral, el Dr. Roberto Cano de la Cuerda se incorporó al equipo de trabajo, funcionando como guía no sólo en la redacción de este trabajo, sino que en los artículos publicados a revistas internacionales ayudándome a cumplir con los requisitos necesarios para llegar a esta instancia en mi formación profesional. Espero poder seguir trabajando en conjunto en la mejora de los desarrollos tecnológicos e investigaciones que puedan salir de aquí en adelante.

A mi grupo de investigación, agradecer su ambiente y apoyo interdisciplinario que muchas veces aportaron a sacar adelante la gran cantidad de tecnologías, prototipos y proyectos con los que siempre trabajamos y que fueron de vital importancia para este trabajo. De este grupo quiero agradecer de manera especial a Enrique Germany y Francisco Saavedra, quienes aportaron conocimiento, recursos y tiempo de trabajo en el desarrollo de los sensores desarrollados en este proyecto.

Quiero agradecer todo el apoyo recibido por mi familia en estos años de desarrollo académico. El apoyo de mi Emilia (mi gran compañera de la viday aventuras) y su familia (incluye a pepita, damarita y kitita) ha sido fundamental antes y durante mi trabajo doctoral, ya que las facilidades y la compañía entregada de manera desinteresada han permitido mantener los ánimos en alto, sobre todo durante los tiempos de pandemia.

Finalmente, quiero agradecer a todas las personas que han participado de alguna u otra

manera en este proyecto, pues es evidente que ningún buen trabajo es realizado por una sola persona.



Índice General

Resumen	I
Agradecimientos	III
Índice de Figuras	VIII
Índice de Tablas	XVI
1. Introducción	1
2. Estado del Arte	3
2.1. Poblaciones con riesgo de caídas	3
2.2. Manejo clínico convencional del riesgo de caídas	3
2.3. Medición de movimiento con Unidad de Medición Inercial (del inglés <i>Inertial Measurement Unit</i> , IMU)	6
2.4. Medición y análisis automático de movimiento humano aplicado a la evaluación clínica del riesgo de caídas mediante el Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go) y Test de 10 metros Marcha (T10M) usando Unidad de Medición Inercial (del inglés <i>Inertial Measurement Unit</i> , IMU)/sensores Magnéticos - Velocidad Angular - Gravedad (del inglés <i>Magnetic - Angular Rate - Gravity Sensors</i> , MARG)	7
2.4.1. Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go) sensorizado	10
2.4.2. Test de 10 metros Marcha (T10M) sensorizado	11
2.4.2.1. Contacto inicial y Contacto final durante la marcha	12
2.4.2.2. Longitud de paso	13
2.5. Discusión estado del arte	15
3. Hipótesis y Objetivos	16
3.1. Hipótesis	16
3.2. Objetivo General	16
3.3. Objetivos específicos	16
3.4. Alcances y Limitaciones	17
3.5. Metodología de Investigación	18

	VI
3.6. Publicaciones y Congresos	21
3.6.1. Publicaciones Indexadas	21
3.6.2. Capítulos de Libros	21
3.6.3. Conferencias	21
3.6.4. Proyectos	22
4. Desarrollo de unidad de medición	23
4.1. Diseño electrónico	23
4.2. Implementación sensor	24
4.3. Validación sensor	25
5. Algoritmos para extracción de características	32
5.1. Segmentación automática del test Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go)	32
5.1.1. Algoritmo de segmentación	32
5.1.1.1. Identificación de los eventos de levantarse/sentarse	32
5.1.1.2. Identificación de los eventos de giro	36
5.1.2. Validación	40
5.1.2.1. Procedimiento de medición	41
5.1.2.2. Validación prueba instrumentalizada frente al procedimiento clínico estándar	42
5.1.2.3. Análisis de segmentación de actividades	46
5.2. Extracción de los índices del ciclo de la marcha	51
5.2.1. Algoritmo para la identificación de los eventos del ciclo de la marcha	51
5.2.1.1. Cálculo índices temporales	53
5.2.1.2. Cálculo índices espaciales - Longitud de paso	56
5.2.2. Validación	57
5.2.2.1. Procedimiento de medición	58
5.2.2.2. Validación prueba sensorizada frente al método patrón	60
5.2.2.3. Validación cálculo parámetros temporales	60
5.2.2.4. Validación estimación longitud de paso	64
6. Distribución de los datos en población objetivo	65
6.1. Análisis de características en Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go)	65
6.2. Análisis de características de la marcha	72

7. Selección de modelos y características para estimación específica del riesgo de caída	77
7.1. Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go) de 3-metros	79
7.1.1. Fase de transición a sedestación	79
7.1.2. Fase de transición bípeda a sedente	80
7.1.3. Fase de giro de los 3-metros	82
7.1.4. Fase de giro antes de sentarse	83
7.1.5. Fase de marcha	84
7.2. Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go) extendido	86
7.2.1. Fase de marcha	86
7.3. Discusión	89
8. Conclusiones	92
A. Esquemáticos	104
A.1. Esquemático sensor Unidad de Medición Inercial (del inglés <i>Inertial Measurement Unit</i> , IMU)	104



Índice de Figuras

2.1. Actividades realizadas en la prueba de Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go). 1 = levantarse, 2 = caminar ida, 3 = giro en la marca de retorno, 4 = caminar vuelta, 5 = giro previo a sentarse y 6 = sentarse.[Elaboración Propia]	4
2.2. Esquema simplificado de un acelerómetro Sistema Micro-electromecánico (del inglés <i>Micro Electric and Mechanical System</i> , MEMS) de tipo capacitivo, donde C1 es la capacitancia de la primera barra respecto a la masa móvil y C2 es la capacitancia de la segunda barra respecto a la masa móvil.[Elaboración Propia] .	6
2.3. Esquema simplificado de un giroscopio Sistema Micro-electromecánico (del inglés <i>Micro Electric and Mechanical System</i> , MEMS) de brazos vibrantes.[Elaboración Propia]	7
3.1. Metodología del trabajo de tesis. Los cuadros sombreados están sujeto a cambios dependiendo del contexto sanitario de la pandemia del covid-19. F1: Desarrollo Unidad de Medición, F2: Generación Base de Datos, F3: Algoritmo de análisis automático, F4: Validación de la pregunta de investigación.	19
3.2. Algoritmo general propuesto para el análisis general del riesgo de caídas en población objetivo. Flecha segmentada indica características obtenidas sólo en la versión extendida del Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go).	20
4.1. Esquema general del diseño del sensor desarrollado.[Elaboración Propia]	24
4.2. Sensor IMU desarrollado para análisis de movimiento.[Elaboración Propia]	24

4.3. Ubicación del sensor desarrollado para análisis de movimiento humano. El sensor se ubica y programa de tal manera en que los ejes del acelerómetro (a_x , a_y , a_z) entregan sus medidas positivas en movimientos a favor de las flechas (al igual que para los datos del magnetómetro m_x , m_y , m_z). Los datos de velocidad angular del giroscopio (g_x , g_y , g_z) entregan sus medidas positivas con rotaciones siguiendo la regla de la mano derecha. [Elaboración Propia]	25
4.4. Ángulos adquiridos durante la medición en posición estática. Los ángulos son calculados a partir de la representación cuaternaria de orientación y las orientaciones Pitch y Yaw se encuentran superpuestas. [Elaboración Propia]	26
4.5. Medición de los sensores inerciales al posicionar la unidad de medición con el plano X e Y perpendicular al vector de gravedad. [Elaboración Propia]	27
4.6. Medición de los sensores inerciales al posicionar la unidad de medición con el plano X y Z perpendicular al vector de gravedad. [Elaboración Propia]	27
4.7. Medición de los sensores inerciales al posicionar la unidad de medición con el plano Z e Y perpendicular al vector de gravedad. [Elaboración Propia]	28
4.8. Equipamiento y procedimiento realizado para la validación dinámica del sensor implementado. [Elaboración Propia]	29
4.9. Señales obtenidas durante el procedimiento de obtención del error dinámico del sensor implementado. Se ilustra la orientación en su formato de ángulos de navegación para ilustrar de mejor manera las variaciones obtenidas. [Elaboración Propia]	30
4.10. Gráficos de error de las mediciones obtenidas para cada orientación respecto a los valores observados en el goniómetro manual utilizado. [Elaboración Propia]	31
5.1. Identificación de los eventos de sentarse y levantarse usando la señal <i>Pitch</i>	33
5.2. Señal de inclinación con la máxima inclinación identificada [Elaboración Propia]	33
5.3. Resultado del método usado para la búsqueda e identificación del inicio y el final de los eventos de levantarse y sentarse. [Elaboración Propia]	35

5.4. Algoritmo automático de segmentación basado en características para las actividades de levantarse y sentarse, así como para el inicio y final del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). [Elaboración Propia] 36

5.5. Identificación de los eventos de giro usando la señal Yaw. 37

5.6. Resultado del método usado para la búsqueda e identificación del inicio y el final de los eventos de giro. [Elaboración Propia] 39

5.7. Algoritmo automático de segmentación basado en características para las actividades de giro durante el Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). [Elaboración Propia] 40

5.8. Características medidas después de la segmentación de las actividades realizadas en el Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). [Elaboración Propia] 40

5.9. Configuración utilizada para las mediciones del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). 42

5.10. Configuración utilizada para las mediciones del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) en laboratorio mientras los datos son medidos inalámbricamente de manera simultánea en una plataforma de adquisición. 43

5.11. Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico estándar en sujetos jóvenes. (a) coeficiente de correlación de Pearson entre Unidad de Medición Inercial (del inglés *Inertial Measurement Unit*, IMU) y el análisis de grabación por video; (b) Gráfico Bland-Altman entre IMU y el análisis de grabación de vídeo. 45

5.12. Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico estándar en personas mayores. (a) coeficiente de correlación de Pearson entre Unidad de Medición Inercial (del inglés *Inertial Measurement Unit*, IMU) y el análisis de grabación por video; (b) Gráfico Bland-Altman entre IMU y el análisis de grabación de vídeo. 46

5.13. Coeficiente de correlación de Pearson para el tiempo de segmentación para cada subtarea de la prueba Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) en sujetos jóvenes. (a) fin de pararse/inicio de la marcha de ida; (b) fin de la marcha de ida/inicio del giro 1; (c) fin del giro 1/inicio de la marcha de regreso; (d) fin de la marcha de regreso/inicio del giro 2; (e) fin del giro 2; (f) inicio de sentarse; (g) fin de sentarse. 47

5.14. Gráficos de error de la segmentación resultante para cada subtarea del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) en sujetos jóvenes. Las líneas segmentadas corresponden al error medio. (a) fin de pararse/inicio de la marcha de ida; (b) fin de la marcha de ida/inicio del giro 1; (c) fin del giro 1/inicio de la marcha de regreso; (d) fin de la marcha de regreso/inicio del giro 2; (e) fin del giro 2; (f) inicio de sentarse; (g) fin de sentarse. 49

5.15. Gráficos de error de la segmentación resultante para cada subtarea del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) en personas mayores. Las líneas segmentadas corresponden al error medio. (a) fin de pararse/inicio de la marcha de ida; (b) fin de la marcha de ida/inicio del giro 1; (c) fin del giro 1/inicio de la marcha de regreso; (d) fin de la marcha de regreso/inicio del giro 2; (e) fin del giro 2; (f) inicio de sentarse; (g) fin de sentarse. 50

5.16. Eventos típicos realizados durante un ciclo de marcha normal. [Elaboración Propia] 51

5.17. Señales características de un acelerómetro de tres ejes en la espalda baja durante la marcha. [Elaboración Propia] 52

5.18. Eventos del ciclo de la marcha identificados en un sujeto con riesgo de caída usando un acelerómetro de tres ejes en la espalda baja. [Elaboración Propia] . . 53

5.19. Modelo biomecánico de cuerpo rígido usado para la estimación del largo de paso. [Elaboración Propia] 56

5.20. Configuración usada para la validación del algoritmo a usar para la extracción de los eventos del ciclo de la marcha. [Elaboración Propia] 57

5.21. Ubicación de los marcadores infrarrojos para la realización de las pruebas de análisis de marcha usando un laboratorio de captura de movimiento optoelectrónico. 59

5.22. Gráficos de caja para evidenciar la distribución de la estimación de los índices temporales del ciclo de la marcha respecto al método patrón en sujetos sanos. (a) Cadencia; (b) Tiempo de Zancada; (c) Tiempo de Paso; (d) Tiempo de Soporte Simple; (e) Tiempo de Soporte Doble; (f) Duración de la fase de Apoyo; (g) Duración de la fase de Balanceo.	62
5.23. Gráficos de error de la estimación de los índices temporales del ciclo de la marcha respecto al método patrón en sujetos sanos. Las líneas segmentadas corresponden al error medio. (a) Cadencia; (b) Tiempo de Zancada; (c) Tiempo de Paso; (d) Tiempo de Soporte Simple; (e) Tiempo de Soporte Doble; (f) Duración de la fase de Apoyo; (g) Duración de la fase de Balanceo.	63
5.24. Resultados de las estimaciones del largo de paso con el algoritmo propuesto respecto al método patrón en sujetos sanos. (a) Distribución de las mediciones; (b) Gráfico Bland-Altman para evaluación de error.	64
6.1. Histograma de los tiempos totales de la prueba instrumentalizada. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.	67
6.2. Histograma, gráfico de caja y scatter-plot de las características extraídas de las pruebas de Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go) en la fase de transferencia sedente-bípeda. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.	68
6.3. Histograma , gráfico de caja y scatter-plot de la duración en segundos de las fases de ida y de regreso del Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go). Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.	69

6.4. Histograma , gráfico de caja y scatter-plot de la duración en segundos del primer giro y de la velocidad angular máxima alcanzada en esta etapa del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas. 70

6.5. Histograma , gráfico de caja y scatter-plot de la duración en segundos del giro antes de sentarse y de la velocidad angular máxima alcanzada en esta etapa del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas. 71

6.6. Histograma, gráfico de caja y scatter-plot de las características extraídas de las pruebas de Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) en la fase de transferencia bípedo-sedente. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas. 72

6.7. Distribución de los índices estimados del ciclo de la marcha. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas. 74

6.8. Gráficos de caja de los índices del ciclo de la marcha estimados por extremidad con R = Riesgo, N = Normal, I = Izquierdo, D = Derecho. 75

6.9. Distribución de los índices estimados del ciclo de la marcha usando el promedio de los índices por extremidad. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas. 76

6.10. Gráficos de caja de los índices del ciclo de la marcha estimados como la media de cada extremidad con R = Riesgo, N = Normal 76

7.1. Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa de pararse del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) mediante validación cruzada. Para el caso de Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN) $K = 3$ 80

7.2. Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa de sentarse del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) mediante validación cruzada. Para el caso de Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN) $K = 3$ 81

7.3. Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa del primer giro del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) mediante validación cruzada. Para el caso de Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN) $K = 3$ 82

7.4. Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa del segundo giro del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) mediante validación cruzada. Para el caso de Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN) $K = 3$ 84

7.5. Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos. Para el caso de Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN) $K = 3$ 85

7.6. Resultados obtenidos al evaluar el aporte de las características respecto a las clases a clasificar. 87

7.7. Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos del ciclo de la marcha. Los resultados fueron calculados usando el set de prueba. Para el caso de Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN) $K = 3$ 88

7.8. Algoritmo final propuesto para el análisis específico del riesgo de caídas en población objetivo. Flechas segmentadas indican características obtenidas sólo en la versión extendida del Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go). 89

A.1. Esquemático sensor implementado. [Elaboración Propia] 104



Índice de Tablas

2.1. Test clínicos comúnmente usados para evaluar el riesgo de caída y estabilidad postural [1]. [Elaboración Propia]	9
2.2. Metodologías basadas en sensores inerciales para la identificación de los eventos de contacto inicial contacto inicial del ciclo de la marcha (IC) y contacto final contacto final del ciclo de la marcha (FC) durante la marcha. [Elaboración Propia]	12
2.3. Metodologías basadas en sensores inerciales para la estimación de la longitud del paso. [Elaboración Propia]	14
4.1. Características de los sensores inerciales y magnéticos del sensor implementado.	23
4.2. Resultados validación medición en reposo del sensor implementado.	28
5.1. Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico visual estándar en sujetos jóvenes.	44
5.2. Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico visual estándar en el grupo de personas mayores. La clasificación del riesgo de caída de los sujetos se obtuvo siguiendo el manual del Ministerio de Salud (MINSAL) para la población chilena [2].	45
5.3. Características de los sujetos de prueba para la estimación de parámetros espacio-temporales de la marcha	59
7.1. Desempeño de los modelos o clasificadores propuestos para la identificación del riesgo de caídas en cada una de las sub-fases del Tiempo de Levántate y Anda (del inglés <i>Timed Up & Go Test</i> , TU&Go).	90

Siglas

ABC Scale Escala de confianza del equilibrio de actividades específicas (del inglés *Activities-Specific Balance Confidence Scale*)

AM Adulto Mayor

BBA Evaluación de balance de Brunel (del inglés *Brunel Balance Assessment*)

BEST Sistema de evaluación de balance (del inglés *Balance Evaluation System Test*)

COBS Consistent Overhead Byte Stuffing

EBB Escala de Balance de Berg

EP enfermedad de Parkinson

FC contacto final del ciclo de la marcha

FRT Test de alcance funcional (del inglés *Functional Reach Test*)

GNB Clasificador Naïve Bayes con kernel Gaussiano (del inglés *Gaussian Naïve Bayes*)

IC contacto inicial del ciclo de la marcha

IMU Unidad de Medición Inercial (del inglés *Inertial Measurement Unit*)

KNN Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*)

MARG sensores Magnéticos - Velocidad Angular - Gravedad (del inglés *Magnetic - Angular Rate - Gravity Sensors*)

MEMS Sistema Micro-electromecánico (del inglés *Micro Electric and Mechanical System*)

MINSAL Ministerio de Salud de Chile

PCB Tarjeta de Circuito Impresa (del inglés *Printed Circuit Board*)

POMA Evaluación de movilidad orientada al desempeño (del inglés *Performance Oriented Mobility Assessment*)

RL Clasificador por Regresión Logística

rms Valor Cuadrático Medio (del inglés *Root Mean Square*)

SVM Máquina de Soporte Vectorial (del inglés *Support Vector Machine*)

T10M Test de 10 metros Marcha

TCT Test de Control de Tronco

TIS Escala de discapacidad de tronco (del inglés *Trunk Impairment Scale*)

TU&Go Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*)



1. Introducción

Esta tesis estudia las aplicaciones que conciernen al monitoreo y diagnóstico automático del movimiento humano usando sensores inerciales y magnéticos en población sana y con riesgo de caída.

Existen diversas herramientas que permiten valorar las características individuales del movimiento humano. Actualmente son reconocidos los laboratorios de análisis de movimiento humano de alta complejidad, los cuales permiten analizar las alteraciones que podrían presentar sujetos sanos [3]. Además, estos espacios de análisis han sido ampliamente utilizados en sujetos con patología neurológica y ortopédica, lo que ha permitido profundizar en la comprensión de diversas variables cinemáticas, cinéticas, biomecánicas y fisiológicas del movimiento humano y sus afecciones. Sin embargo, su alto costo junto con la necesidad de profesionales especializados en su manejo e interpretación de los resultados, ha dificultado su incorporación en todos los niveles de atención de salud.

En el mercado chileno hay un escaso desarrollo de dispositivos para la medición y evaluación del movimiento humano. A nivel nacional, existen alrededor de 7 laboratorios optoelectrónicos para el análisis del movimiento, los que generalmente se encuentran en Instituciones Académicas o Instituciones de Salud Privada (Facultad de Medicina Universidad de Chile – Santiago, Clínica las Condes – Santiago, Laboratorio de Marcha y Movimiento Teletón – San Pedro, Laboratorio de Movimiento de la Universidad Católica de la Santísima Concepción – Concepción, Laboratorio de Movimiento Universidad Autónoma de Chile – Santiago, Laboratorio del Movimiento Humano de la Universidad de Magallanes – Punta Arenas, Laboratorio para el Análisis del Movimiento Humano del Centro de Rehabilitación Club los Leones – Punta Arenas).

Lo anterior, ha mantenido a profesionales clínicos a utilizar escalas e instrumentos de valoración para evaluar las alteraciones que presentan las distintas poblaciones en relación al riesgo de caídas que ingresan a procesos de rehabilitación, tales como, cinta métrica y/o goniómetros, test de marcha de 6, 10 y 12 metros, test de marcha de 3,6 y 12 minutos, test de riesgo de caídas de 3 metros o Tiempo de Levántate y Anda (del inglés *Timed Up & Go Test*, TU&Go) o de 6 metros (en su versión extendida), escala de Balance de Berg, Tinetti POMA, BESTest, Mini-BESTest, ente otros [4]. Si bien estas escalas y pruebas clínicas han sido sometidos a diversos análisis estadísticos para evaluar su validez en distintas poblaciones, esto no ha sido detallado

para todas las poblaciones y grupos etarios chienos, encontrándose escasa evidencia nacional en relación a poblaciones con riesgo de caída, lo que contribuye a un alto error inter-evaluador y , a su vez, va en desmedro de los intentos por objetivar la valoración clínica.

Por otra parte, existen areas rurales con un alto índice de envejecimiento en la población donde el acceso a un control continuo de padecimientos de índole motor es complejo, debido a la inexistencia de sistemas de análisis de movimiento humano [5].

Recientemente, nuevas tecnologías han aparecido para cubrir el vacío que existe entre los laboratorios de movimiento altamente tecnológicos y las escalas utilizadas en ambiente clínico. Sensores electromecánicos como acelerómetros, giroscopios y magnetómetros proveen una alternativa para el análisis de movimiento humano sin las limitaciones anteriormente descritas (costo y complejidad). Numerosos estudios han reportado el uso de sistemas basados en sensores inerciales (acelerómetros y giroscopios) y magnéticos (magnetómetros) para el análisis del movimiento con un aumento en la precisión y confiabilidad, ya que gracias a su pequeño tamaño y bajo consumo, resultan una atractiva opción para el análisis del movimiento en ambientes no controlados [6, 7, 8].

Así, esta tesis propone un método que identifica actividades típicas dentro de pruebas clínicas para la evaluación del riesgo de caída, permitiendo extraer características a partir de Unidad de Medición Inercial (del inglés *Inertial Measurement Unit*, IMU) para su posterior análisis, con el fin de entregar una valoración objetiva y automática del movimiento humano.

2. Estado del Arte

2.1. Poblaciones con riesgo de caídas

El número de personas mayores de 60 años está aumentando rápidamente en todo el mundo. Las razones principales de este cambio demográfico son el aumento de la expectativa de vida [9]. Esto se ha transformado en un problema de salud pública [10], ya que el envejecimiento está directamente asociado a una disminución física y cognitiva, lo que implica un aumento en el riesgo de discapacidad, dependencia y comorbilidades [9, 11]. La detección temprana de la disminución de las funciones motora y cognitiva es fundamental para iniciar precozmente las medidas preventivas que permitan entretener el progreso del envejecimiento y mantener la independencia del Adulto Mayor (AM) [12]. Por otra parte, es en este rango etario en el que se encuentra la prevalencia de enfermedades neurológicas: ≥ 60 años para enfermedad de Parkinson, y 65 ± 15 años para secuelas de accidente cerebrovascular [13, 14].

Una de las consecuencias asociadas al envejecimiento y a secuelas por enfermedades neurológicas es el aumento del riesgo de caídas, las cuales han sido definidas como “eventos accidentales en el cual las personas caen luego de perder el control de su centro de gravedad y de no realizar ningún esfuerzo por restaurarlo o este esfuerzo es insuficiente” [15].

Aproximadamente, un tercio de la población ≥ 65 años ha experimentado una caída al año. Adicionalmente, esta frecuencia aumenta un 50 % en sujetos ≥ 85 años. Entre el 20 % y el 30 % de las caídas resultan en una lesión y requieren de atención médica, constituyendo la principal causa de muerte o lesión no fatal en los adultos mayores AM [16, 17, 18]. Por tanto, la detección precoz de la función disminuida es importante para iniciar precozmente las medidas preventivas que permitan mantener su independencia funcional.

2.2. Manejo clínico convencional del riesgo de caídas

Normalmente, los profesionales de la rehabilitación realizan la evaluación del riesgo de caídas por medio de la observación y la aplicación de pruebas y escalas de evaluación. Escalas e instrumentos de valoración como el “test” de marcha de 6, 10 y 12 metros [19], “test” de marcha

de 3, 6 y 12 minutos [20], TU&Go de 3 metros [21] o de 6 metros (en su versión extendida) [22], permiten evaluar y medir el equilibrio y control postural dinámico en sujetos sanos o con algún problema motor [20]. Uno de los más utilizados a nivel mundial es el TU&Go, el cual mide el balance dinámico y la movilidad funcional en AM, así como también en población neurológica [23, 24, 25].

El TU&Go es una evaluación simple que puede ser aplicada casi en cualquier localización con unas mínimas condiciones, y consiste en que el sujeto debe ponerse de pie desde una silla, caminar 3 metros, girar, regresar a la silla caminando y sentarse en la silla nuevamente (ver Figura 2.1). La variable controlada es el tiempo total en segundos que el sujeto se toma en realizar el circuito, el cual se correlaciona con el riesgo de caída [21, 24, 25].

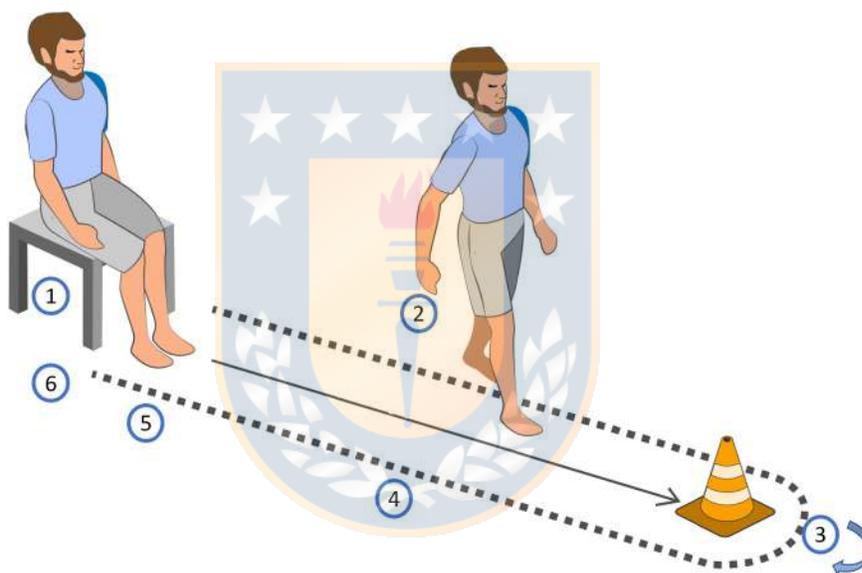


Fig. 2.1: Actividades realizadas en la prueba de TU&Go. 1 = levantarse, 2 = caminar ida, 3 = giro en la marca de retorno, 4 = caminar vuelta, 5 = giro previo a sentarse y 6 = sentarse.[Elaboración Propia]

Algunas ventajas del TU&Go es la simplicidad y corta duración en su aplicación. Adicionalmente, requiere de poco equipamiento y permite que los sujetos con algún impedimento funcional puedan ejecutar la prueba. Sin embargo, una de las limitaciones que presenta es que no es capaz de determinar el riesgo de manera categórica en sujetos con mayores dificultades. Barry et al. [26] menciona que una limitación en el valor predictivo de la prueba podría ser explicado debido a que consiste en una prueba que evalúa el balance y equilibrio de forma general, lo que podría mejorar al ser combinado con herramientas tecnológicas de análisis de movimiento, como los laboratorios para el análisis de movimiento y sensores inalámbricos como IMU [25, 26].

Comúnmente, en la práctica clínica, el TU&Go se combina con la aplicación de otras escalas de evaluación como la Estación Unipodal, la escala de Balance de Berg, Tinetti Evaluación de movilidad orientada al desempeño (del inglés *Performance Oriented Mobility Assessment*, POMA), o Test de 10 metros Marcha (T10M) que han sido validadas en distintas poblaciones con riesgo de caídas [27, 28, 29]. Estas escalas permiten evaluar y valorar en su conjunto el riesgo de caídas, el balance y la velocidad de marcha de los distintos pacientes, permitiendo observar el nivel funcional de estos y determinar las estrategias de intervención pertinentes. Sin embargo, al complicar el proceso de evaluación del riesgo de caídas, hace que la medición sea tediosa lo que afecta el desempeño del sujeto a medir durante la ejecución de la prueba.

En el manual del Ministerio de Salud de Chile (MINSAL) para el tratamiento de pacientes con riesgo de caídas recomiendan el uso de el TU&Go en conjunto a la estación unipodal para evaluar el riesgo de caídas [2], lo que constituye un procedimiento de valoración muy corto y sencillo, pero que deja de lado los problemas asociados a la traslación del paciente. Para subsanar lo anterior, en el último tiempo se ha optado por la utilización de una versión extendida del TU&Go, que permite evaluar marcha en una distancia mayor a los 3 metros de la prueba original [22].

Dadas las limitaciones anteriormente mencionadas, se han desarrollado algunos métodos basados en sensores inerciales que, gracias a la reducción progresiva en su tamaño y precio, se ha logrado posicionar como una alternativa confiable y precisa en las aplicaciones para el análisis y seguimiento del movimiento humano [7, 8], permitiendo monitorizar de manera no invasiva a sujetos con y sin desórdenes motores, entre las que destacan el monitoreo y observación de personas mayores de forma remota mediante sistemas de alarma personal [30], detección y clasificación de caídas [31, 32], diagnóstico y tratamiento médico [33], monitoreo de niños en forma remota en el hogar, rehabilitación y/o fisioterapia [34], investigación biomecánica [35], ergonomía [36], ciencias del deporte, ballet y danza [37] y animación [38]. Así, se han identificado diversas metodologías que utilizan diferentes arreglos de sensores inerciales, variando la cantidad [39, 40], los datos utilizados [41] y los algoritmos para la interpretación de los datos, permitiendo instrumentalizar una gran cantidad de pruebas y exámenes comúnmente usados en la práctica clínica, siendo las áreas de evaluación y detección del riesgo de caída y la biomecánica del ciclo de la marcha los que han tenido el mayor enfoque de la comunidad científica y profesional [42].

2.3. Medición de movimiento con IMU

Los sensores inerciales son aquellos sensores electrónicos cuyas mediciones se basan en la variación de alguna variable que representa movimiento respecto a una referencia que se considera fija, y dentro de esta categoría se tienen a los acelerómetros y giroscopios [43].

En la Figura 2.2 se ilustra el funcionamiento de un acelerómetro Sistema Micro-electromecánico (del inglés *Micro Electric and Mechanical System*, MEMS), en el que dos placas fijas representan las masas en reposo, las que al aplicar una fuerza y producir desplazamiento, genera un cambio en la capacitancia entre ellas con respecto a una fija, que es proporcional a la aceleración producida.

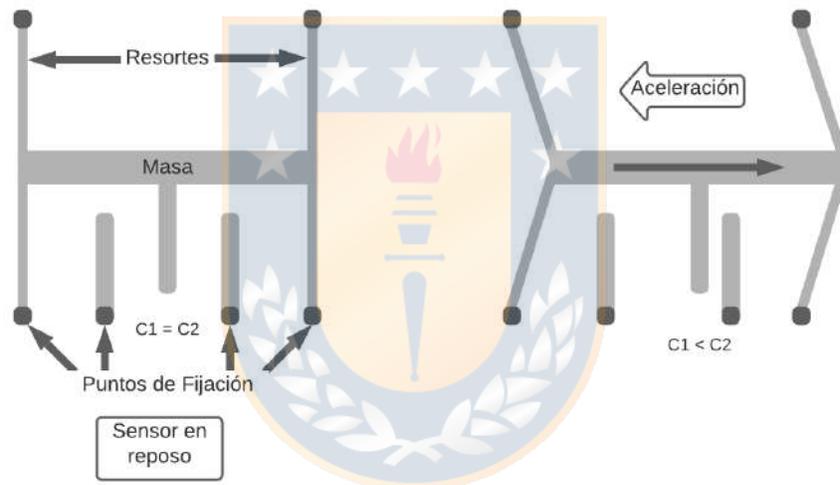


Fig. 2.2: Esquema simplificado de un acelerómetro MEMS de tipo capacitivo, donde $C1$ es la capacitancia de la primera barra respecto a la masa móvil y $C2$ es la capacitancia de la segunda barra respecto a la masa móvil. [Elaboración Propia]

El giroscopio es un elemento que puede medir o mantener la orientación basado en el principio del momento angular. La referencia inercial usada por este sensor es la fuerza de Coriolis. Cuando una velocidad angular es aplicada por el constante movimiento y oscilación de dos masas en direcciones opuestas, la fuerza Coriolis actúa sobre cada masa en direcciones opuestas, lo que resulta en la vibración de unos piezoeléctricos, cuya vibración es proporcional a la velocidad angular, y es traducido en una salida de voltaje. Lo anterior se ilustra en la Figura 2.3.

Estos elementos pueden ser usados de manera independiente o juntos para estimar las variables de movimiento de un cuerpo en el espacio. Hoy en día, existen MEMS que incorporan

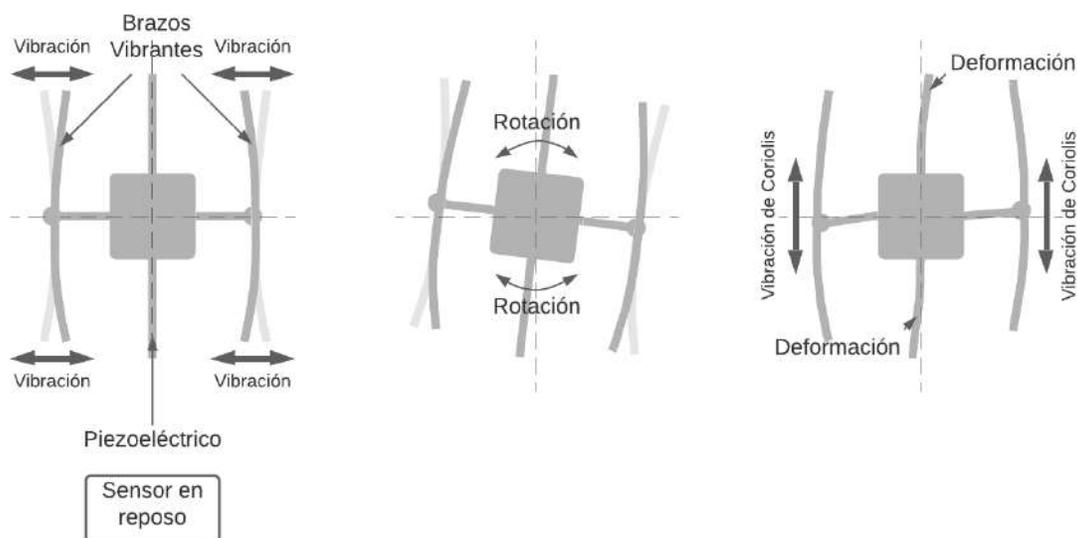


Fig. 2.3: Esquema simplificado de un giroscopio MEMS de brazos vibrantes. [Elaboración Propia]

los sensores inerciales en un solo encapsulado denominado IMU, permitiendo medir de manera precisa no sólo aceleraciones y velocidades angulares, sino que fusionarlos mediante algoritmos para obtener la orientación de un cuerpo u objeto en el espacio [43, 44]. Además, junto a los sensores ya mencionados, es posible mejorar el rendimiento en la estimación de orientación usando sensores magnéticos que miden la intensidad del campo magnético de la tierra, recibiendo el nombre de sensores Magnéticos - Velocidad Angular - Gravedad (del inglés *Magnetic - Angular Rate - Gravity Sensors*, MARG) [44].

2.4. Medición y análisis automático de movimiento humano aplicado a la evaluación clínica del riesgo de caídas mediante el TU&Go y T10M usando IMU/MARG

Normalmente, los profesionales de la rehabilitación realizan evaluaciones a través de la observación, así como mediante la aplicación de escalas o instrumentos de evaluación, que brindan un cierto nivel de objetividad a las evaluaciones. Existe un gran número de tests y escalas que permiten evaluar y valorar el equilibrio estático, el equilibrio dinámico y la marcha de sujetos sanos o con problemas motores [45], por ejemplo: Escala de Balance de Berg (EBB), Test de Control de Tronco (TCT), Test de alcance funcional (del inglés *Functional Reach Test*, FRT), Sistema de evaluación de balance (del inglés *Balance Evaluation System Test*, BEST), Escala

de discapacidad de tronco (del inglés *Trunk Impairment Scale*, TIS), Evaluación de balance de Brunel (del inglés *Brunel Balance Assessment*, BBA), Escala de confianza del equilibrio de actividades específicas (del inglés *Activities-Specific Balance Confidence Scale*, ABC Scale). Mientras el TU&Go mide el equilibrio dinámico y la movilidad funcional en adultos mayores, así como en la población neurológica [23, 24, 46], el T10M permite medir a partir de la velocidad de marcha la independencia de las personas y los principales parámetros espacio-temporales cuando es instrumentalizado, como velocidad de marcha, longitud de paso, cadencia, entre otros. En la tabla 2.1 se presentan algunos de los test clínicos más utilizados para la evaluación del riesgo de caídas y estabilidad postural.



Tabla 2.1: Test clínicos comúnmente usados para evaluar el riesgo de caída y estabilidad postural [1]. [Elaboración Propia]

Test	Propósito	Área	Tipo de evaluación	Descripción	Modo de aplicación	Costo	Tiempo
T10M	Nivel de independencia.	Movilidad Marcha, Evaluación vestibular	Funcional, Evaluación	Medida de rendimiento (velocidad de marcha).	El individuo camina una distancia predeterminada (según la variación aplicada) en el que el tiempo es medido. La distancia recorrida se divide por el tiempo medido.	Papel y lápiz. Gratis	≥ 5 min.
TU&Go	Medición del riesgo de caídas.	Balance, Movilidad Funcional, Evaluación vestibular	Observador.	El individuo inicia sentado con la espalda apoyada al respaldo de una silla. Al inicio de la prueba, el paciente se levanta de la silla y camina 3 metros para después girar y regresar al punto de inicio y sentarse. Se registra el tiempo que le tomó completar el circuito.	Papel y lápiz. Gratis	Gratis	≤ 3 min.
Tinetti	Percepción del balance y estabilidad durante actividades de la vida diaria.	Actividades de la vida diaria, Balance, Movilidad Funcional, Marcha, Evaluación vestibular	Percepción del paciente	Un cuestionario de 10 ítems diseñado para evaluar la confianza del paciente al realizar 10 actividades de la vida diaria sin riesgo de caerse como un indicador de como el temor a caerse impacta en el rendimiento físico. Mientras mayor sea el puntaje (100 máximo) menor es la confianza del paciente.	Papel y lápiz. Gratis	Gratis	10 a 15 min.
EBB	Balance estático y riesgo de caídas en adultos.	Balance, Movilidad Funcional.	Medida de rendimiento (Puntaje).	Escala que considera 14 ítems que incluyen actividades estáticas y dinámicas de dificultad variada. Cada actividad es evaluada de 0 a 4 puntos, determinada por la habilidad del paciente al ejecutar la actividad en cuestión. El puntaje máximo es 56.	Papel y lápiz. Equipamiento	5 a 20 min.	
TCT	Nivel de recuperación de sujetos con accidente cerebro-vascular.	Balance, Movilidad Funcional.	Medida de rendimiento (Puntaje).	Escala que a partir de la evaluación de 4 aspectos de la movilidad de tronco asigna un puntaje de 0 a 100 (máximo) indicando si es incapaz de moverse sin asistencia o si puede realizar los movimientos evaluados con completa normalidad.	Papel y lápiz. Equipamiento	5 a 20 min.	
FRT	Estabilidad postural.	Balance, Movilidad Funcional, Evaluación Vestibular.	Medida de rendimiento (Puntaje).	Evalúa la estabilidad del paciente al medir la distancia máxima de alcance hacia adelante mientras se encuentra de pie en una posición fija.	Papel y lápiz. Equipamiento	5 min.	
BEST	Estabilidad postural y equilibrio.	Balance, Movilidad Funcional, Evaluación Vestibular.	Medida de rendimiento (Puntaje).	Orienta e identifica los 6 sistemas de control de equilibrio para poder diseñar mejores enfoques en la rehabilitación del mismo a partir de 36 ítems en 6 secciones, evaluados de 0 a 108 puntos.	Papel y lápiz. Gratis.	Gratis.	15 a 20 min.
TIS	Deterioro motor de tronco.	Balance estático y dinámico.	Medida de rendimiento (Puntaje).	Consta de tres subescalas: equilibrio estático al sentarse, equilibrio dinámico al sentarse y coordinación. Cada subescala contiene entre tres y diez elementos. La puntuación TIS varía de un mínimo de 0 a un máximo de 23.	Papel y lápiz. Equipamiento	5 a 20 min.	
BBA	Balance funcional en pacientes secuestrados de accidente cerebro-vascular.	Balance.	Medida de rendimiento (Puntaje).	Serie jerárquica de 12 pruebas de rendimiento funcional que van desde el equilibrio sentado con apoyo hasta tareas avanzadas de pasos. La evaluación consta de tres secciones: sentarse, pararse y caminar.	Papel y lápiz. Gratis.	Gratis.	10 min.
ABC Scale	Autoinforme de medida de la confianza del equilibrio.	Balance, Movilidad Funcional.	Percepción del paciente.	Medida subjetiva de confianza para realizar diversas actividades ambulatorias sin caerse o experimentar una sensación de inestabilidad a partir de 16 actividades puntuadas de 0 (sin confianza) a 100 (con confianza).	Papel y lápiz. Permisos de uso	Permisos de uso (No gratis).	5 a 10 min.

Los laboratorios optoelectrónicos para el análisis de movimiento proporcionan mediciones precisas, son costosos y su aplicación lleva mucho tiempo, ya que se requiere capacitación y experiencia para interpretar los resultados. Además, en varios países existen localidades rurales o remotas sin recursos para estos sistemas de evaluación tecnológica avanzada.

En los últimos años se ha observado un desarrollo de diferentes dispositivos que utilizan sensores inerciales, aplicaciones y/o teléfonos inteligentes como una alternativa de bajo costo a los sistemas optoelectrónicos, que han permitido visualizar específicamente las fases en las que los sujetos podrían presentar mayores problemas con la consiguiente probabilidad de caída durante la aplicación del test TU&Go [47].

La falta de tecnologías validadas y de bajo costo disponibles comercialmente para capturar el movimiento humano con precisión y confiabilidad ha establecido una escasa masificación de las alternativas de medición objetiva para evaluar el movimiento humano, principalmente en países sub-desarrollados o en vías de desarrollo, donde no todos tienen el conocimiento o la prioridad para incorporar tecnología en sus metodologías de medición y evaluación. [48, 49, 50]

2.4.1. TU&Go sensorizado

Si bien la sensorización del TU&Go es relativamente nueva, diferentes autores indican que las fases de la prueba TU&Go corresponden a: la transición sedente-bípeda, marcha hacia la marca de 3 metros, gira en la marca de tres metros, caminar de regreso a la silla, girar y transferencia bípeda-sedente [12, 45, 25]. A pesar de existir diferentes actividades dentro de la realización de la prueba, estas no son consideradas. La identificación, segmentación y análisis de las sub-fases del TU&Go podría aumentar su valor predictivo en relación al riesgo de caídas y a una evaluación más completa referente a las fases en las que los sujetos/pacientes presentan mayores dificultades.

Así, se ha demostrado que es posible implementar una segmentación automática de estas fases o actividades mediante algoritmos basados en características [25, 51], algoritmos complejos basados en aprendizaje automático [12, 46] o mediante análisis de componentes principales [52] – como técnicas basadas en la descomposición Wavelet [53] – utilizando los datos generados por sensores inerciales.

Los algoritmos basados en características tienen la ventaja de ser simples de implementar, pero su desempeño se ve disminuido debido a la gran variabilidad que existe en la morfología

de las señales que utilizan para realizar la segmentación – velocidad angular y aceleración – aquellas que dependen del entorno y el tiempo de ejecución de las actividades a identificar.

Una forma de reducir las desventajas de los métodos basados en características es utilizar los datos de orientación de las IMU [47, 54]. Estos ángulos de orientación se han utilizado en diferentes partes del cuerpo para la segmentación de actividades durante la ejecución de la prueba, ya que presentan baja variabilidad en sus características inter-sujetos, lo que permite extraer características de cada fase de forma independiente [55, 56].

2.4.2. T10M sensorizado

Se han desarrollado numerosas metodologías y algoritmos basados en sensores inerciales para la identificación de los eventos de contacto final del ciclo de la marcha (FC) y contacto inicial del ciclo de la marcha (IC) a partir de diferentes datos: aceleraciones lineales o vectoriales de acelerómetros, velocidades angulares de giroscopios, ángulos del ciclo de la marcha, entre otros, los que varían en la cantidad y posición de los sensores utilizados [57, 58, 59, 60].



2.4.2.1. Contacto inicial y Contacto final durante la marcha

Tabla 2.2: Metodologías basadas en sensores inerciales para la identificación de los eventos de contacto inicial IC y contacto final FC durante la marcha. [Elaboración Propia]

Autor	Sensor	Cantidad	Ubicación	Algoritmo	Resultados	Sujetos
Sejdic et al.	Acelerómetro triaxial	1	L4 - L5.	Basado en características.	100 % de los eventos de postura con un error promedio de 1.18 ± 0.09 [s] usando un sistema de captura de movimiento.	35 sujetos (Sanos, Parkinson, Neuropatía periférica) [61].
González et al.	Acelerómetro triaxial	1	L3.	Basado en características.	100 % de los eventos con un error promedio de 0.013 ± 0.035 [s] para el IC y 0.009 ± 0.054 [s] para el FC usando una plataforma de fuerza.	11 sujetos (Sanos) [62].
Kose et al.	Acelerómetro triaxial	1	Cintura.	Descomposición de ondas estacionarias.	96 % de los eventos con un error de 0.06 ± 0.04 [s] para el IC y 0.05 ± 0.03 [s] para el FC usando conmutadores de pedal.	8 sujetos (Sanos) [63].
McCamley et al.	Acelerómetro triaxial	1	Cintura.	Descomposición Wavelet.	100 % de los eventos con un error promedio de 0.02 ± 0.04 [s] para el IC y 0.03 ± 0.03 [s] para el FC usando un tapete instrumentado de 4 metros .	18 sujetos (Sanos) [64].
Aminian et al.	Acelerómetro triaxial	2	Muslo izquierdo y derecho.	Basado en características.	100 % de los eventos de postura con un error máximo de 0.74 ± 0.04 [s] usando sensores de presión debajo del pie.	12 sujetos (Saludable, Artroplastia de Cadera) [65].
Jasiewicz et al.	Giroscopio uniaxial	2	Pierna izquierdo y derecho.	Basado en características.	100 % de los eventos con un error promedio de -0.014 ± 0.023 [s] para el IC y -0.023 ± 0.028 [s] para el FC usando pedales en sujetos sanos.	41 sujetos (sanos, lesión de la médula espinal) [66].
Sabatini et al.	Giroscopio uniaxial	1	Pie	Característica.	100 % de los eventos con un error medio de -0.002 [s] para el IC y 0.035 [s] para el FC utilizando conmutadores de pedal	5 sujetos (Sanos) [67].
Aminian et al.	Giroscopio uniaxial	2	Pierna izquierdo y derecho.	Wavelet + Basado en características	100 % de los eventos de FC con un error promedio de 0.01 [s] usando sensores de presión debajo del pie.	20 sujetos (sanos) [68].

En la Tabla 2.2 se indican diferentes métodos que utilizan sensores inerciales para identificar y aislar el IC y FC durante el ciclo de la marcha, destacando el número utilizado, su ubicación en el cuerpo y si han sido evaluados en sujetos sanos o con problemas motores. Sólo se indican algoritmos con no más de 2 sensores.

2.4.2.2. Longitud de paso

A partir de los parámetros espacio-temporales, el más complejo de estimar con precisión utilizando sensores inerciales es la longitud del paso, pues su estimación depende de un proceso de doble integración de las aceleraciones o una integración simple de las velocidades angulares obtenidas de los sensores inerciales, cuyo cálculo produce un error acumulativo principalmente en caminatas de baja velocidad [69, 70]. Para ello, se han propuesto diferentes métodos que tratan este problema (ver Tabla 2.3).



Tabla 2.3: Metodologías basadas en sensores inerciales para la estimación de la longitud del paso. [Elaboración Propia]

Autor	Sensor	Cantidad	Ubicación	Modelo	Algoritmo	Resultados	Sujetos
Rafael et al.	Acelerómetro uniaxial	1	Cintura, L3 - L4.	Modelo de péndulo invertido.	Algoritmos de estimación de dos fases: integración doble de los datos del acelerómetro durante la fase de soporte único con el modelo de péndulo invertido y una estimación del desplazamiento hacia adelante con el porcentaje del tamaño del pie.	Estimaciones de error de -5.50 % a 6.07 % a partir de la distancia recorrida usando dos camcoders.	16 sujetos (Sanos, Parkinson) [69].
Zijlstra et al.	Acelerómetro uniaxial	1	Cintura.	Modelo de péndulo invertido.	Doble integración de los datos del acelerómetro utilizando un filtro Butterworth de cuarto orden para atenuar el error de integración.	Subtimaciones generales de 16 % en la longitud de la zancada y la velocidad de la zancada utilizando una cinta de correr que mide las fuerzas de reacción del suelo.	15 sujetos (Sanos, Parkinson) [71].
Álvarez et al.	Acelerómetro uniaxial	1	Cintura.	Modelo de péndulo invertido.	Doble integración de los datos del acelerómetro con el algoritmo de detección de velocidad cero.	Errores entre 1.4 % y 4.4 % en 170 [m] caminaron usando un camcorder. Solo presenta resultados en largas distancias.	8 sujetos (sanos) [72].
Salarian et al.	Giroscopio uniaxial	2	Piernas izquierda y derecha.	Modelo de doble péndulo.	Ángulos de piernas utilizando la serie de Fourier y optimización del último cuadrado.	Error medio de 0.038 ± 0.066 [m] usando un sistema de captura de movimiento.	Tres conjuntos de datos de 20 (Entrenamiento), 36 (Pruebas) y 15 (Evaluación) sujetos (Sanos, Reemplazo de cadera, Coxartrosis) [60].
Doheny et al.	IMU	1	Piernas izquierda y derecha.	Modelo rígido de parte inferior del cuerpo.	Ángulo máximo entre las piernas en su máxima extensión para obtener la longitud de la zancada más un factor de corrección optimizado.	Error medio de 0.09 ± 0.07 [m] usando el sistema de plataforma de presión GAITRite.	7 sujetos (Sanos) [70].

Así, las tablas 2.2 y 2.3 presentan diferentes metodologías que se utilizan por separado o juntas [73] para describir los parámetros espaciales y temporales de la marcha utilizando sensores inerciales.

2.5. Discusión estado del arte

Se ha realizado una extensa revisión bibliográfica que abarca desde la problemática a abordar, hasta diferentes metodologías que existen para el análisis de movimiento humano centrándose en modelos de segmentación automático y en análisis de marcha usando IMU.

Si bien los algoritmos presentados permiten generar una gran cantidad de información sobre el movimiento de las personas en evaluación (Variables espacio-temporales del ciclo de la marcha), éstas no son utilizadas mas allá de la caracterización del mismo, dejando de lado potenciales aplicaciones referentes a evaluaciones y diagnósticos automáticos.

En el área de análisis de movimiento para evaluación del riesgo de caídas usando TU&Go, existen modelos que permiten la evaluación automática clasificando la evaluación desde un punto de vista global: hay o no riesgo de caídas. En general, los algoritmos se centran en la extracción de características y en la segmentación de actividades más que en la generación de una herramienta que permita evaluar detalladamente el riesgo de caídas, ilustrando en qué transferencia motora o sub-fase del test clínico tiene más riesgo, con la finalidad de centrar terapias de rehabilitación enfocadas en el problema detectado.

Es por lo anterior, que en esta tesis se propone y evalúa una herramienta que permita entregar de manera automática y oportuna un informe diagnóstico profundo referente al riesgo de caídas real de AM, usando un sistema intuitivo y de bajo costo basado en IMU.

Según lo investigado, para la evaluación del riesgo de caídas se utilizarán las escalas de evaluación clínicas validadas para el manejo del riesgo de caídas (test de equilibrio, TU&Go y T10M) mientras se mide de manera simultánea con IMU. Para evitar redundancias en la toma de mediciones, en lugar de realizar pruebas usando el T10M, se usará la versión extendida del TU&Go. Esto permite la extracción de variables relacionadas al movimiento (aceleraciones, velocidades y orientaciones), además de la duración de actividades con algoritmos automáticos de segmentación y de análisis de marcha, los que a su vez permitirán establecer rangos de normalidad y así definir un set de reglas para el diagnóstico automático del riesgo de caídas.

3. Hipótesis y Objetivos

3.1. Hipótesis

Mediante una matriz de sensores inerciales ubicados en la espalda y utilizando una máquina de aprendizaje automático se puede determinar el riesgo global y específico de caídas en AM durante el TU&Go discriminando por sub-fase.

3.2. Objetivo General

Desarrollar un sistema de análisis automático de movimiento humano basado en sensores inerciales en población AM mayor a 60 años y enfermedad de Parkinson con riesgo de caídas.

3.3. Objetivos específicos

- Desarrollar un sensor inalámbrico de movimiento basado en sensores inerciales liviano, pequeño y autónomo.
- Implementar una plataforma de adquisición de datos para el sensor inalámbrico de movimiento.
- Generar una base de datos de las mediciones de los sensores inerciales en la espalda durante las pruebas clínicas propuestas en AM.
- Determinar las características heurísticas, temporales y/o frecuenciales a utilizar mediante técnicas de extracción y selección de características de las pruebas clínicas utilizadas.
- Desarrollar y proponer una herramienta de análisis automático del riesgo de caídas evaluando la validez de diferentes modelos para medir y diagnosticar el riesgo de caídas usando una IMU en la espalda en adultos.

- Validar el sistema implementado de análisis automático de movimiento humano basado en sensores inerciales en población AM mayor a 60 años y enfermedad de Parkinson con riesgo de caídas.
- Determinar la validez de constructo que existe entre el sistema de análisis de movimiento humano implementado y las escalas de evaluación de riesgo de caídas utilizadas en la práctica clínica.

3.4. Alcances y Limitaciones

- La investigación considera la validación de un sistema prototipo con una muestra predefinida, en la que se reclutan voluntarios de Concepción, región del Biobío, Chile, por lo que no es posible hacer inferencia a todas las poblaciones con riesgo de caídas.
- Con un coeficiente de correlación de un 98 % con un error de tipo 1 del 5 % y un error del tipo 2 de 1 % se estima que para que la muestra sea estadísticamente significativa, se debe medir un mínimo de 7 sujetos por grupo (AM). Sin embargo, se consideran en el proceso de estimación del tamaño muestral otras co-variables, como el nivel de riesgo de caídas, el diagnóstico y el estadio de la patología. Considerando estas variables, el tamaño total de la muestra del estudio completo es de 21 sujetos.
- El reclutamiento, protocolos de medición y selección de pacientes fué presentado al comité de ética de la Facultad de Medicina de la Universidad de Concepción y fué aprobado con el código CEC10-2019.
- Los alcances y objetivos del trabajo de tesis podrían verse afectados por el contexto de pandemia mundial de COVID-19 iniciada en diciembre del 2019, afectando los protocolos de medición y resultados, debido a las políticas de prevención sanitaria y cuarentenas aplicadas a la ciudad de Concepción, Chile.
- Debido al contexto sanitario se considerará el uso de bases de datos disponibles online de población AM para el entrenamiento y validación de la propuesta de este trabajo de tesis.

3.5. Metodología de Investigación

En este trabajo de investigación se propone la implementación de un sistema automático para el análisis del riesgo de caídas en población objetivo usando TU&Go en su versión de 3-metros o en TU&Go extendido. El proceso de desarrollo considera los objetivos planteados en esta tesis lo que permitió establecer una herramienta objetiva para la segmentación de las sub-fases de la prueba clínica, así como también la extracción de características temporales y espaciales de movilidad y de la marcha durante su ejecución usando un solo IMU.

Para resolver la pregunta de investigación planteada en esta tesis se desarrolló una herramienta tecnológica basada en matrices de sensores inerciales y magnéticos para la medición de variables de aceleración, velocidad y orientación mientras se realiza las actividades del TU&Go.

Con los datos obtenidos en sujetos sanos y sujetos con riesgo de caídas, identificados con apoyo de profesionales del área de la salud, se generó una base de datos que permitió implementar algoritmos automáticos para la extracción de características temporales e índices de movilidad los que se utilizaron como entrada para un sistema de análisis automático. Este sistema de análisis automático permitió proponer un algoritmo que no sólo considera la obtención del puntaje final del TU&Go, sino que además, mediante algoritmos de inteligencia artificial, indica en qué actividad de la vida diaria el paciente tiene riesgo de caer. La figura 3.1 ilustra la metodología usada para evaluar la pregunta de investigación que se divide en 4 fases:

- F1: Desarrollo Unidad de Medición.
- F2: Generación Base de Datos.
- F3: Algoritmo de análisis automático.
- F4: Validación de la pregunta de investigación.

El área sombreada está sujeto a cambios dependiendo de la disponibilidad de voluntarios, ya que corresponden a población de riesgo en el contexto sanitario de la pandemia del covid-19, en cuyo caso se optará por la utilización de bases de datos disponibles en línea para evaluar el TU&Go y la marcha (T10M) en la versión extendida del test.

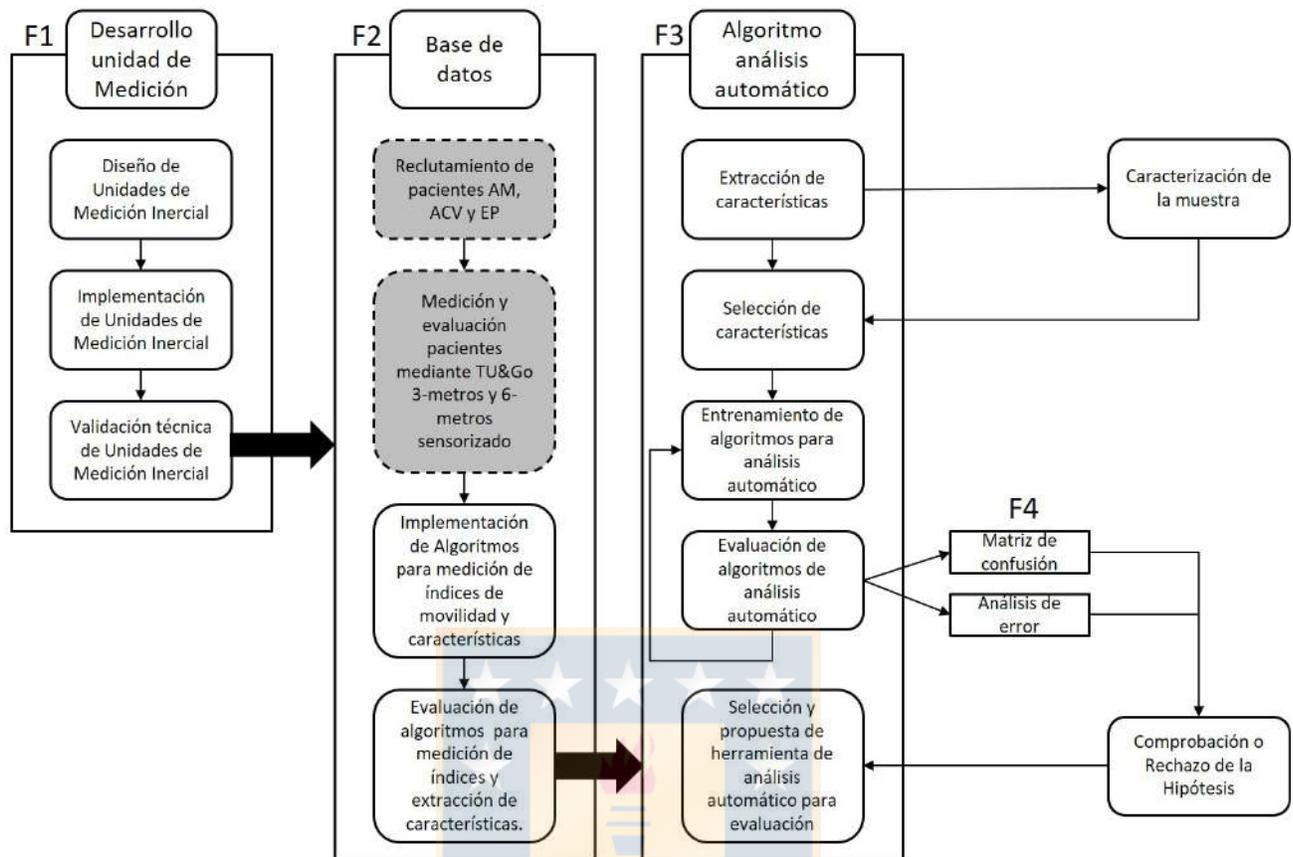


Fig. 3.1: Metodología del trabajo de tesis. Los cuadros sombreados están sujetos a cambios dependiendo del contexto sanitario de la pandemia del covid-19. F1: Desarrollo Unidad de Medición, F2: Generación Base de Datos, F3: Algoritmo de análisis automático, F4: Validación de la pregunta de investigación.

Se detalla que las bases de datos que cumplen con los requisitos para explorar la factibilidad de lo propuesto son:

- Physionet “Long Term Movement Monitoring Database” [83]
- Repositorio del artículo “Intra-rater, inter-rater and test-retest reliability of an instrumented Timed Up and Go (iTUG) test in patients with Parkinson’s disease”. [81]

En la figura 3.2 se ilustra el algoritmo general a implementar para resolver la pregunta de investigación y que será evaluado con métricas de desempeño la capacidad para evaluar e identificar el riesgo de caídas de manera específica.

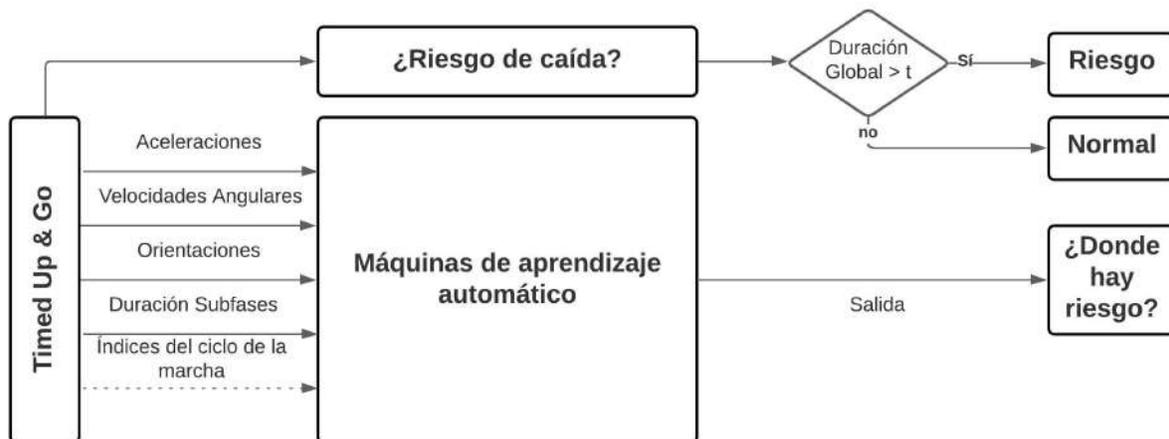


Fig. 3.2: Algoritmo general propuesto para el análisis general del riesgo de caídas en población objetivo. Flecha segmentada indica características obtenidas sólo en la versión extendida del TU&Go.

Los pasos a seguir para llevar a cabo la construcción del algoritmo de evaluación propuesto y que consideran los objetivos planteados en la sección anterior, son:

- Diseño e implementación de un sensor capaz de medir aceleraciones, velocidades y orientaciones.
- Propuesta y evaluación de algoritmos para extraer características espacio-temporales de movilidad y de marcha en población objetivo durante la ejecución del TU&Go.
- Como el desarrollo de esta tesis se vió afectada por el contexto sanitario de la pandemia de covid-19, impidiendo la medición de la población objetivo con el sistema propuesto, se buscarán bases de datos públicas disponibles cuyo protocolo de medición se asemejen al planteado en este trabajo.
- Análisis de las características extraídas para observar su distribución, correlación (en el caso de haberlas), presencia de datos atípicos y comportamiento general.
- Selección y evaluación de las características extraídas y de los modelos de aprendizaje automático.
- Propuesta final de sistema (sensor, algoritmo y plataforma) para la evaluación automática del riesgo de caídas.

3.6. Publicaciones y Congresos

3.6.1. Publicaciones Indexadas

- Android Platform for Realtime Gait Tracking Using Inertial Measurement Units. EJTM3. DOI: 10.4081/ejtm.2016.6144
- Use of a Single Wireless IMU for the Segmentation and Automatic Analysis of Activities Performed in the 3-m Timed Up and Go Test. Sensors. DOI: <https://doi.org/10.3390/s19071647>.
- Validation of a portable system for spatial-temporal gait parameters based on a single inertial measurement unit and a mobile application. EJTM3. DOI: <https://doi.org/10.4081/ejtm.2020.900>
- A Novel Capacitive Step Sensor to Trigger Stimulation on Functional Electrical Stimulators Devices for Drop Foot. IEEE Trans Neural Syst Rehabil Eng. DOI: 10.1109/TNSRE.2020.3039174

3.6.2. Capítulos de Libros

- After Stroke Movement Impairments: A Review of Current Technologies for Rehabilitation - Capítulo de libro: Physical Disabilities - Therapeutic Implications. [En línea] <https://www.intechopen.com/books/physical-disabilities-therapeuticimplications/after-stroke-movement-impairments-a-review-of-current-technologies-rehabilitation>

3.6.3. Conferencias

- Neural Network Algorithm to Detect the Gait Phases and Trigger a Drop Foot Stimulator Using Inertial Sensors - 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2017 - Jeju, Corea del Sur.
- Using Inertial Sensors to Detect the Gait Phases and Trigger a Drop Foot Stimulator - International Functional Electrical Stimulation Society IFESS 2017 - Londres, Inglaterra.
- Sistema de análisis de marcha basado en unidades de medición inercial - Iberdiscap 2017 - Bogotá, Colombia. IX Congreso Iberoamericano de Tecnologías de Apoyo a la Discapacidad.

- Identification of Toe-off and Heel Strike events using a single Inertial Measurement Unit - 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2018 - Honolulu, USA.
- Portable Device for Thoracic Electrical Bio-impedance Acquisition - 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2018 - Honolulu, USA.
- Wireless Low-Cost Bioimpedance Measurement Device for Lung Capacity Screening - 41th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2019 - Berlin, Alemania.
- Measurement of the Human Balance with one Inertial Sensor in Lower Back - 2019 IEEE Global Humanitarian Technology Conference, Seattle - USA.
- Segmentación automática del test Timed up and Go utilizando un solo sensor inercial de movimiento - Buenos Aires, Argentina. X Congreso Iberoamericano de Tecnologías de Apoyo a la Discapacidad, Iberdiscap 2019.
- Step capacitive array sensor to trigger stimulation on Functional Electrical Stimulators devices for Drop Foot- 42th Annual International Conference of the IEEE Engineering in Medicine and Biology Society 2020 - Montreal, Canada.

3.6.4. Proyectos

- Proyecto VIU adjudicado el año 2016 titulado: Desarrollo de un sistema para el análisis de movimiento humano basado en sensores inerciales, COD.- VIU15E0027

4. Desarrollo de unidad de medición

Se diseñó e implementó un sensor IMU en conjunto con el equipo de desarrollo del laboratorio de Ingeniería Biomédica de la Universidad de Concepción, Concepción, Chile.

4.1. Diseño electrónico

El sensor debe tener las características de ser un dispositivo cómodo, liviano, autónomo e inalámbrico, y debe entregar información sobre el movimiento humano a una frecuencia suficiente. Así, es que se diseñó una unidad de medición que consiste en un sensor BNO055 de Bosh Sensortec [74] que tiene un acelerómetro de tres ejes, un giroscopio de tres ejes y un magnetómetro de tres ejes (ver Tabla 4.1), así como un procesador interno capaz de fusionar los datos inerciales y magnéticos utilizando un filtro Kalman para entregar con precisión la orientación en cuaterniones. Esto, para evitar las singularidades de las representaciones de ángulos de Euler (representación tridimensional). Luego, los datos de orientación se obtienen con una precisión de ± 1 grado.

Tabla 4.1: Características de los sensores inerciales y magnéticos del sensor implementado.

Sensor	Eje	Rango	Ancho de Banda	Resolucion	Frecuencia
Acelerometro	XYZ	± 16 G	62.5 Hz	14 bits (≈ 1.95 mG)	100 Hz
Giroscopio	XYZ	± 2000 dps	32 Hz	16 bits (≈ 0.061 dps)	100 Hz
Magnetómetro	XY	± 1300 [μ T]	10 Hz	13 bits (≈ 317 [η T])	20 Hz
-	Z	± 2500 [μ T]	10 Hz	15 bits (≈ 152 [η T])	20 Hz

Usando un microcontrolador NXP de 32 bits con un procesador ARM Cortex-M0+ se mide a una frecuencia de 100 [Hz] y se envían a una aplicación a través de Bluetooth 3.0 de ST electronics sin problemas de oclusión, dispositivo que ha sido usado en varias aplicaciones para el desarrollo de tecnologías de monitoreo no-invasivo [ref]. Para asegurar la transferencia sin pérdida de datos y a una alta frecuencia de muestreo se usa Consistent Overhead Byte Stuffing (COBS) para la codificación del paquete de datos [75]. Todo el sistema funciona con una batería LiPo de 3.7 [V]–500 [mAh], que le otorga al sensor hasta 10 horas de autonomía.

4.2. Implementación sensor

Usando la plataforma de diseño Eagle de Autodesk, se implementó el diseño electrónico del sensor siguiendo con el diseño general ilustrado en la Figura 4.1.

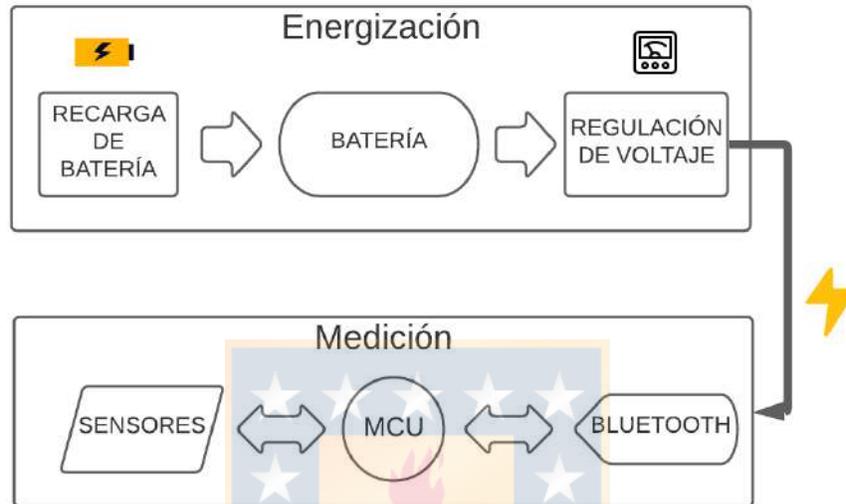


Fig. 4.1: Esquema general del diseño del sensor desarrollado.[Elaboración Propia]

El esquemático electrónico puede verse en el Anexo A. El diseño de la Tarjeta de Circuito Impresa (del inglés *Printed Circuit Board*, PCB) consideró las limitantes asociadas a la caja elegida, cuyas dimensiones son de 35x45x15 [mm]. Así, se diseñó la PCB que se indica en a Figura 4.2.

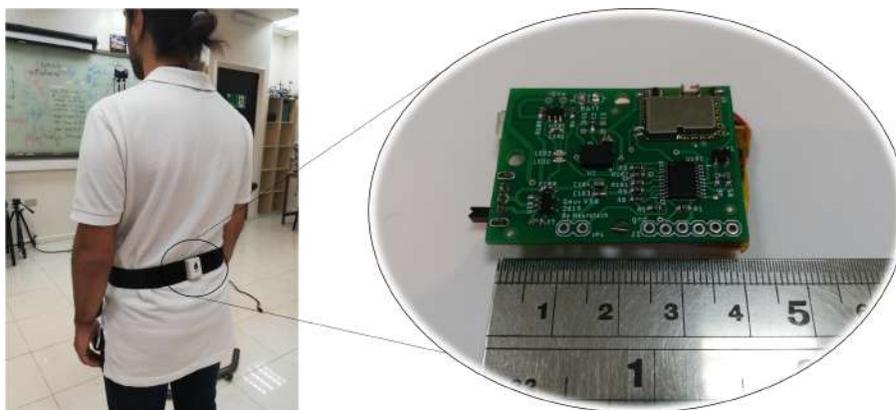


Fig. 4.2: Sensor IMU desarrollado para análisis de movimiento.[Elaboración Propia]

El sensor es fijado en la espalda baja de los voluntarios mediante un velcro en una banda

elástica de 50 [mm] de ancho con un diseño ajustable (ver Figura 4.3).

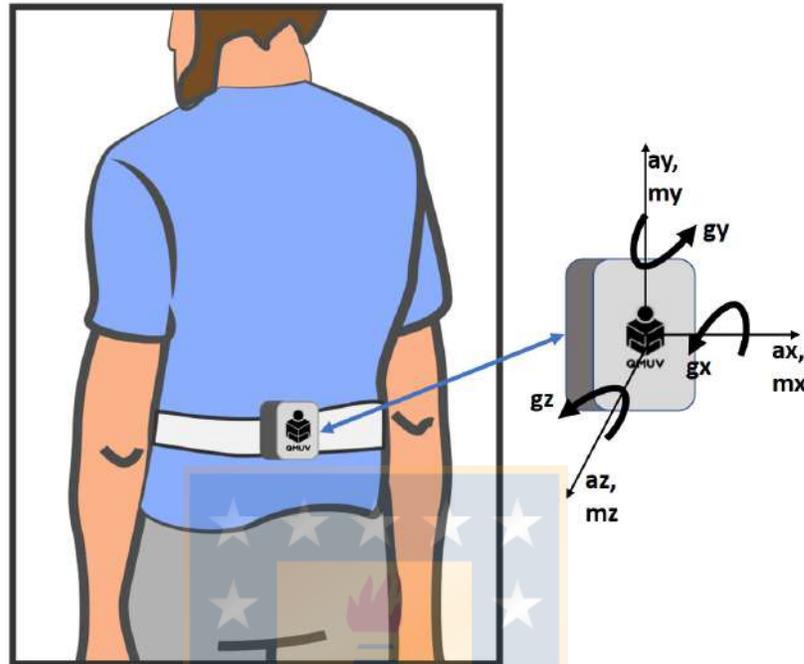


Fig. 4.3: Ubicación del sensor desarrollado para análisis de movimiento humano. El sensor se ubica y programa de tal manera en que los ejes del acelerómetro (a_x , a_y , a_z) entregan sus medidas positivas en movimientos a favor de las flechas (al igual que para los datos del magnetómetro m_x , m_y , m_z). Los datos de velocidad angular del giroscopio (g_x , g_y , g_z) entregan sus medidas positivas con rotaciones siguiendo la regla de la mano derecha.[Elaboración Propia]

4.3. Validación sensor

Después de la implementación de la unidad de medición, se realizaron dos tipos de validación, entre las que se incorporan mediciones de nivel de desempeño estático – “drift”, error de alineación u “offset” y estimación de ruido mediante el cálculo del Valor Cuadrático Medio (del inglés *Root Mean Square*, rms) – y dinámico (error de medición).

Para la evaluación de “drift” el sensor se dejó midiendo por 140 minutos en una posición estática y libre de interferencias electromagnéticas mientras se guardaba la información de las orientaciones en una tarjeta de memoria “microSD”. Recordar que ninguna prueba clínica de

las detalladas en este trabajo tiene una duración mayor a 25 minutos, por lo que el tiempo de medición representa el comportamiento del sensor en cualquiera de los “test” mencionados en el “Estado del Arte”. En la figura 4.4 se ilustran las formas de onda obtenidas.

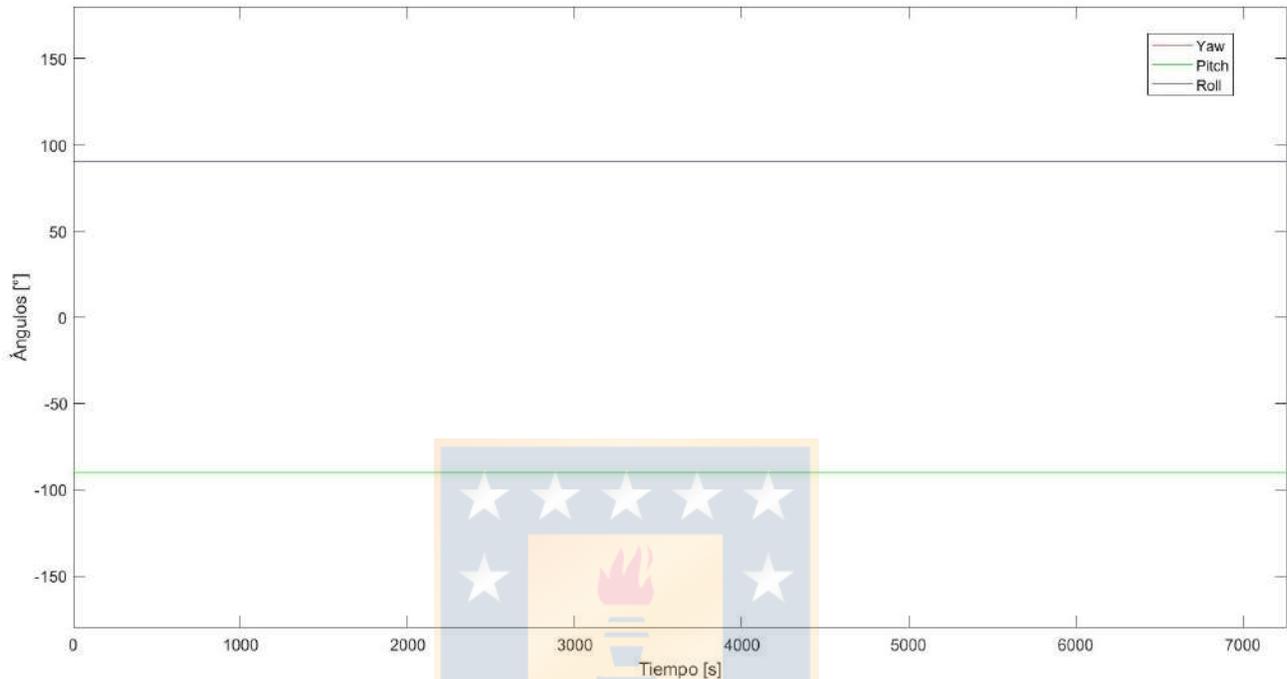


Fig. 4.4: Ángulos adquiridos durante la medición en posición estática. Los ángulos son calculados a partir de la representación cuaternaria de orientación y las orientaciones Pitch y Yaw se encuentran superpuestas. [Elaboración Propia]

Para la estimación del ruido de los sensores inerciales (acelerómetro y giroscopio) se usa el cálculo del rms. En el “datasheet” del IMU, para el acelerómetro se presenta este valor mediante un parámetro de ruido espectral expresado en $\mu G/\sqrt{Hz}$ ($150 [\mu G/\sqrt{Hz}] - 190 [\mu G/\sqrt{Hz}]$), que al multiplicarse por la raíz cuadrada del ancho de banda de medición ($62.5 [Hz]$), este resultado es el ruido de aceleración rms nominal del sensor ($0.0011 [G] - 0.0015 [G]$). Para el giroscopio, la densidad de ruido espectral se representa como $^{\circ}/s/\sqrt{Hz}$ ($0.014 [^{\circ}/s/\sqrt{Hz}]$), que al multiplicarse por la raíz cuadrada de la frecuencia de muestreo se obtiene la densidad de ruido en su valor rms, que en este caso al estar muestreando a $100 [Hz]$ debería entregar valores de ruido entre $0.14 [^{\circ}/s]$ y $0.3 [^{\circ}/s]$ según “datasheet”. El error de alineación se realizó al posicionar el sensor en 3 orientaciones diferentes durante 1 minuto: plano X e Y perpendicular al vector de gravedad (ver figura 4.5), plano X y Z perpendicular al vector de gravedad (ver figura 4.6) y plano Z e Y perpendicular al vector de gravedad (ver figura 4.7), de esta manera se pudo estimar los errores de medición entre $0 [G]$ y $1 [G]$. El cálculo de “drift” se presenta como el rango de desviación

de los ángulos de orientación por unidad de tiempo respecto a su valor inicial.

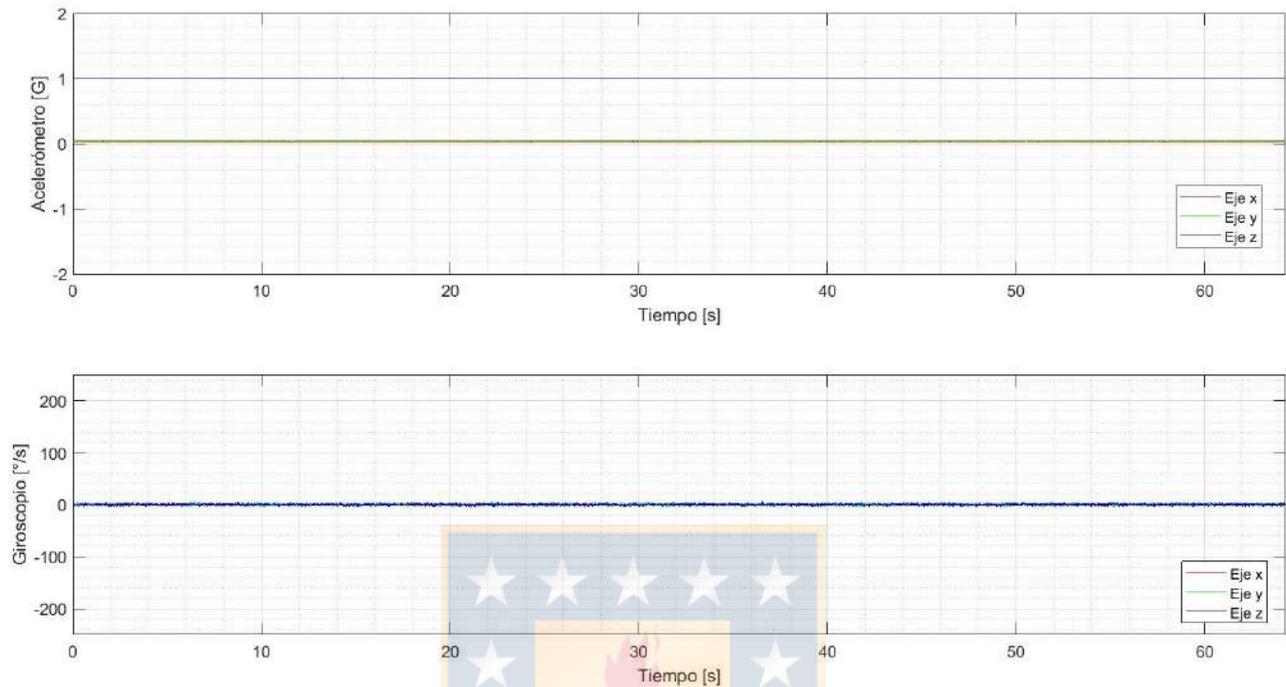


Fig. 4.5: Medición de los sensores inerciales al posicionar la unidad de medición con el plano X e Y perpendicular al vector de gravedad. [Elaboración Propia]

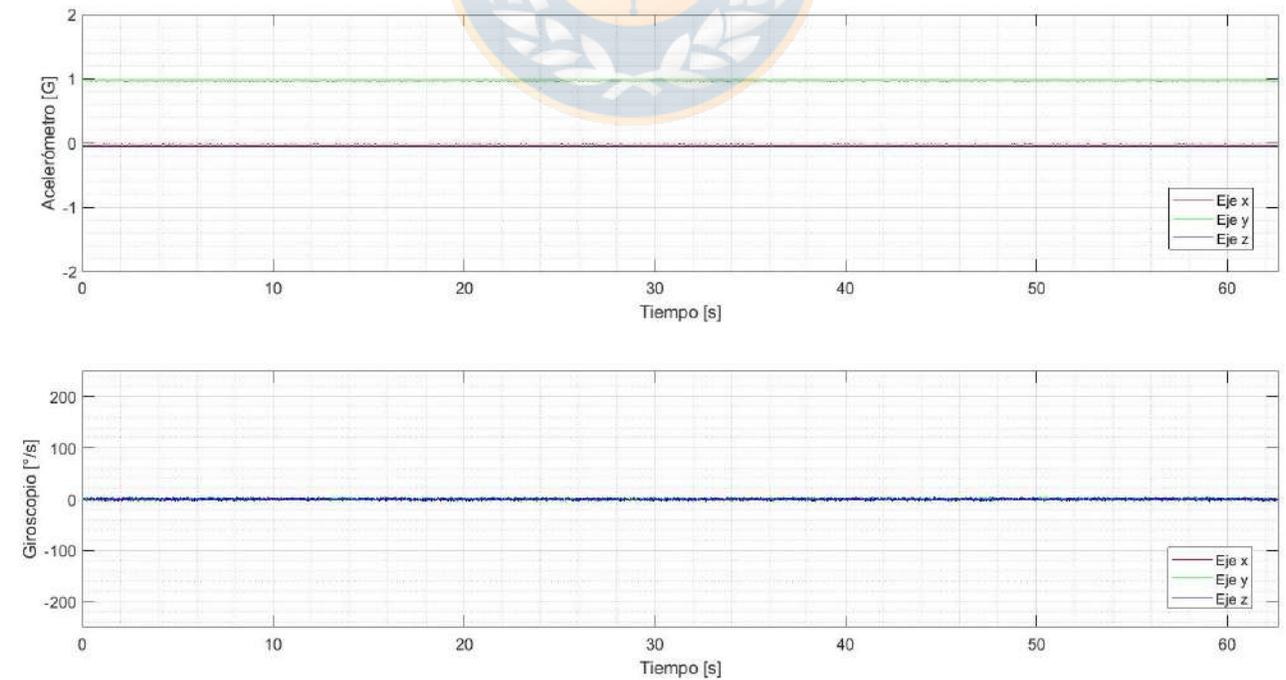


Fig. 4.6: Medición de los sensores inerciales al posicionar la unidad de medición con el plano X y Z perpendicular al vector de gravedad. [Elaboración Propia]

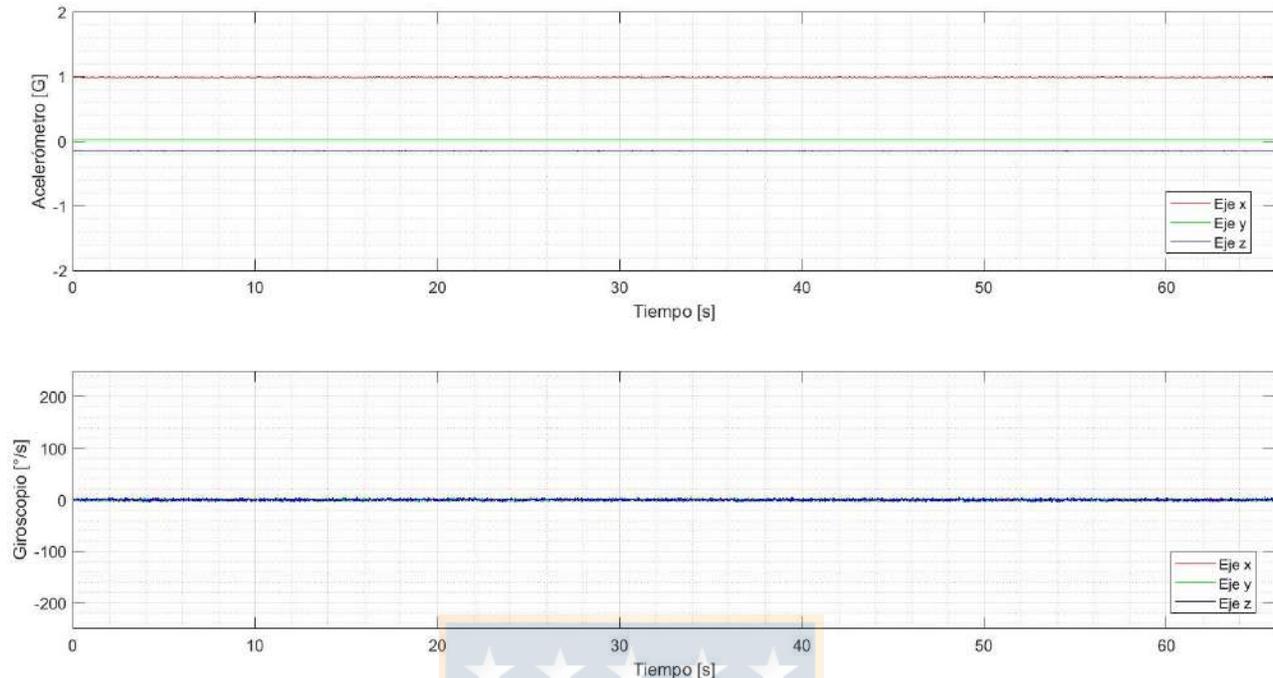


Fig. 4.7: Medición de los sensores inerciales al posicionar la unidad de medición con el plano Z e Y perpendicular al vector de gravedad. [Elaboración Propia]

Los resultados se presentan en la tabla 4.2.

Tabla 4.2: Resultados validación medición en reposo del sensor implementado.

Sensor	Eje/Orientación	RMS	Drift	Offset
Acelerómetro	X	0.0011 [G]	-	0.013 [G]
	Y	0.0011 [G]	-	0.033 [G]
	Z	0.0014 [G]	-	0.150 [G]
Giroscopio	X	1.12 [°/s]	-	-
	Y	1.42 [°/s]	-	-
	Z	1.41 [°/s]	-	-
	Yaw	-	0	-
	Pitch	-	$2.88e-6$ [°/s]	-
	Roll	-	$1.60e-5$ [°/s]	-

De los resultados obtenidos, se observa una clara predominancia de ruido en las señales del giroscopio (en sus tres ejes), debido a que si bien las señales son obtenidas a 100 [Hz], el filtro interno para el cálculo de los ángulos adquiere las señales de velocidad angular a una frecuencia

más alta, que según los valores de densidad de ruido debe ser alrededor de los 1000 [Hz]. En general las señales del acelerómetro son de buena calidad, siendo la de mejor calidad la que corresponde al eje “X”. Sobre los ángulos de orientación obtenidos, aunque en algunos ejes hay “drift”, se observa que este es muy pequeño de acuerdo a el lapso de medición presentado.

Para el cálculo de error dinámico, la bibliografía establece que el procedimiento se debe hacer utilizando algún instrumento patrón mecanizado para el cálculo punto a punto del error [77], obteniendo parámetros relacionados al error cuadrático medio. Sin embargo, en esta ocasión, al no contar con un sistema mecánico para comparar las mediciones entregadas por el sensor, se optó por la utilización de un goniómetro manual con el sensor ubicado en las tres orientaciones – como se presenta en la figura 4.8 – en el que se fue variando en rangos de 10 grados en un sentido hasta llegar a una variación de 180 grados respecto a la posición inicial, desde el cual se hizo el mismo ejercicio pero en sentido contrario. Las señales adquiridas para cada prueba se ilustran en la figura 4.9.

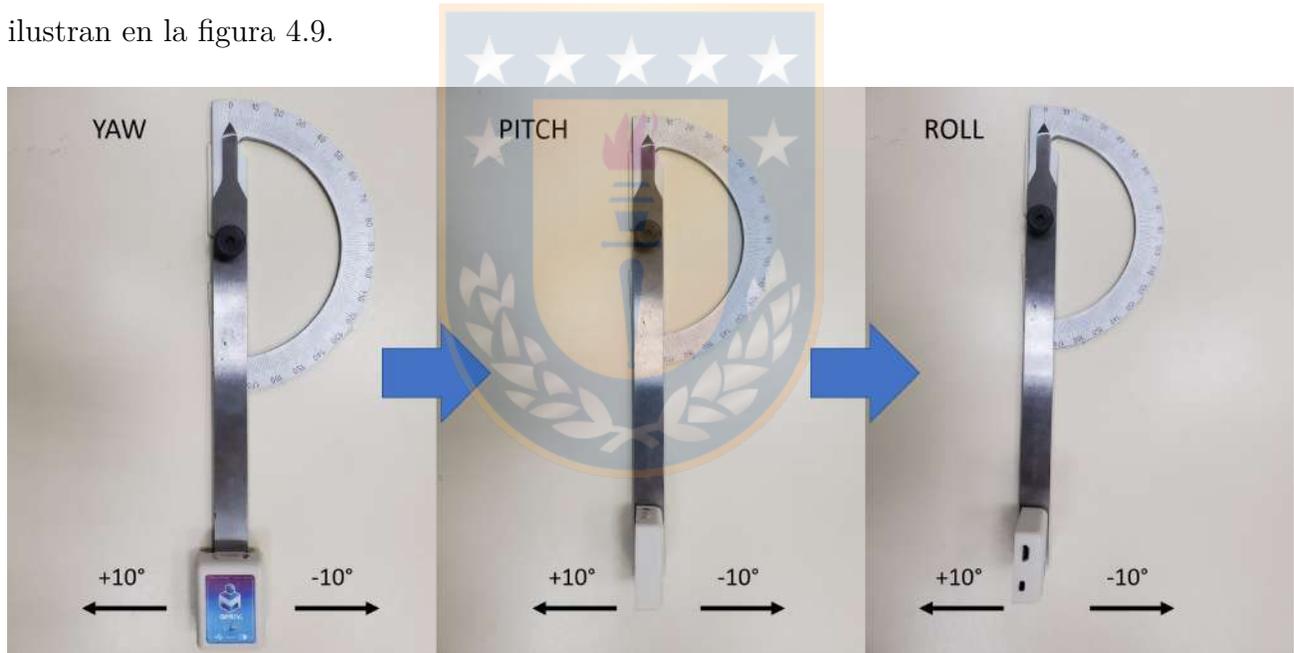


Fig. 4.8: Equipamiento y procedimiento realizado para la validación dinámica del sensor implementado. [Elaboración Propia]

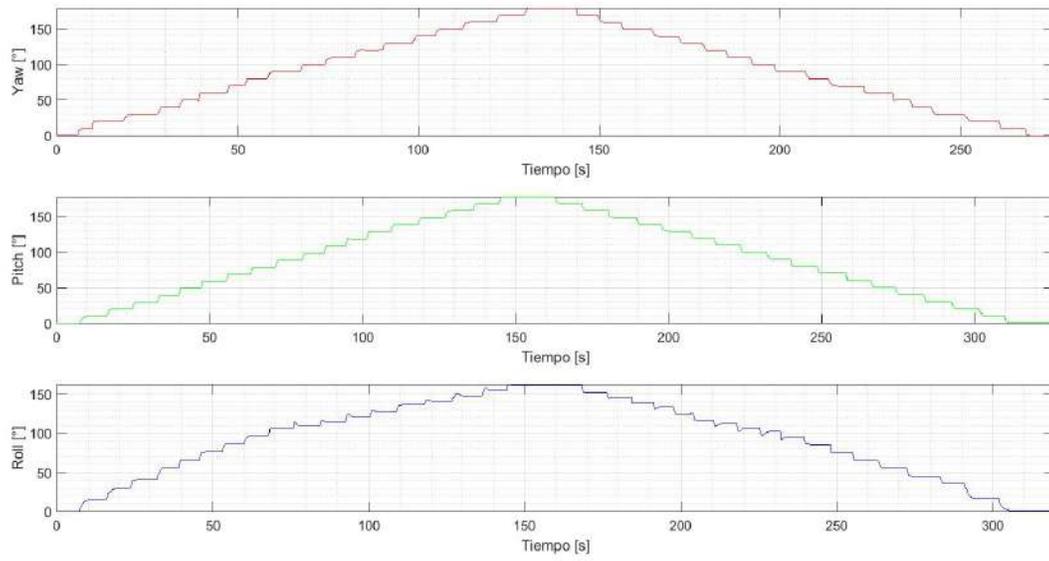


Fig. 4.9: Señales obtenidas durante el procedimiento de obtención del error dinámico del sensor implementado. Se ilustra la orientación en su formato de ángulos de navegación para ilustrar de mejor manera las variaciones obtenidas. [Elaboración Propia]

Tras el proceso de obtención de los datos durante la validación dinámica, se procedió a comparar las mediciones estáticas, es decir, cuando se llegaba al valor asociada a la variación definida (10 grados cada 5 segundos), y se comparó con los datos registrados de manera visual en el goniómetro digital. Los gráficos de error para cada orientación se ilustra en la figura 4.10.

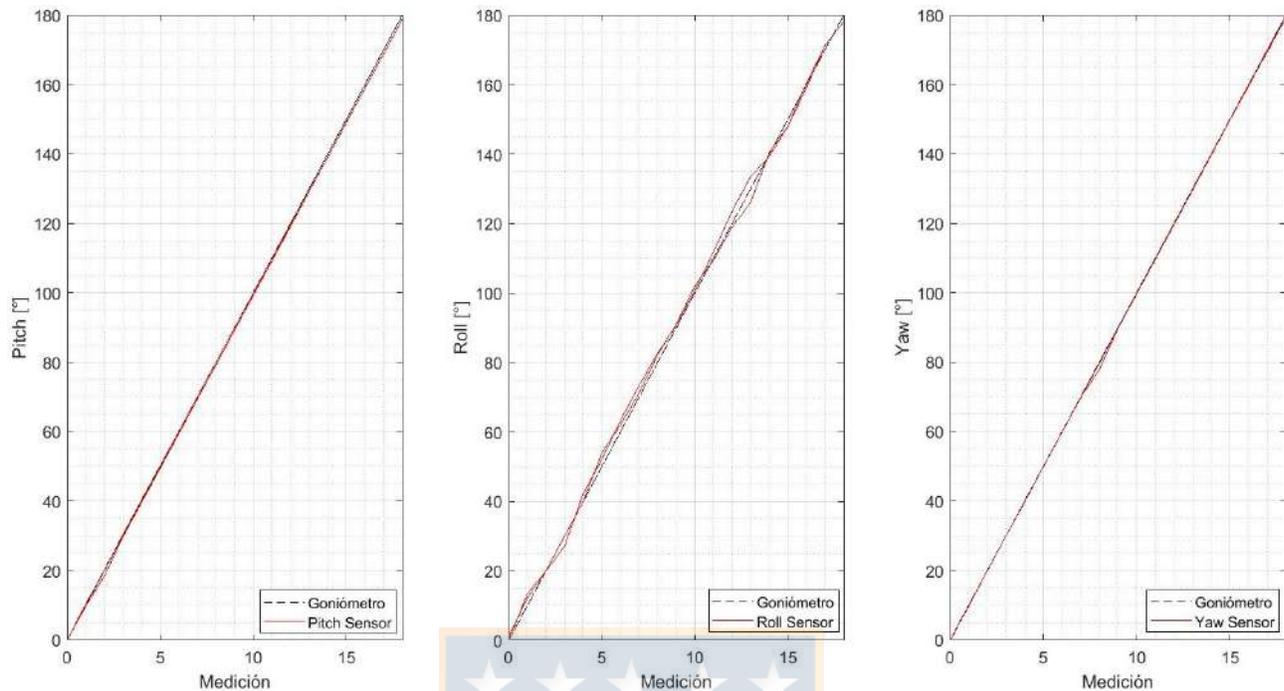


Fig. 4.10: Gráficos de error de las mediciones obtenidas para cada orientación respecto a los valores observados en el goniómetro manual utilizado. [Elaboración Propia]

Los resultados obtenidos indican un error medio de $0.25 \pm 0.36^\circ$ para “Yaw”, $0.47 \pm 0.53^\circ$ para “Pitch” y $-0.74 \pm 1.92^\circ$ para “Roll”, siendo el que peor desempeño presentó. Si bien, en este trabajo el procedimiento de validación del sensor involucra un factor humano bastante importante, se menciona que en otros trabajos publicados el mismo sensor utilizado ya ha sido validado, comparando su comportamiento con otros sensores comerciales que entregan orientación de manera embebida, en los que se reportan resultados comparables a sistemas ópticos (error $\pm 7^\circ$) [76] y se posicionan como la mejor alternativa comercial, con un error de estimación estático de 0.7° , 0.03° y 0.08° para orientaciones de yaw, pitch y roll respectivamente tras 24 horas de medición continua y, errores dinámicos alrededor de 1.4° , 0.8° y 4.6° para orientaciones de yaw, pitch y roll respectivamente [77].

5. Algoritmos para extracción de características

En este capítulo se presenta un método de segmentación basado en características que utiliza una única IMU inalámbrica para analizar los datos de los sensores inerciales y proporcionar un informe completo sobre el riesgo de caídas a partir de las características temporales y los índices de movilidad extraídos.

5.1. Segmentación automática del test TU&Go

Para la segmentación de las actividades de levantarse, caminar, girar y sentarse, se diseñó un algoritmo que procesa las señales de inclinación (*Pitch*) y rotación (*Yaw*) de un sensor inercial colocado en la espalda baja de un sujeto, entre L3 - L4, aproximadamente.

5.1.1. Algoritmo de segmentación

5.1.1.1. Identificación de los eventos de levantarse/sentarse

Para determinar los eventos de levantarse y sentarse, se utilizó la señal *Pitch*, que corresponde a las inclinaciones del tronco durante las actividades a identificar. Cuando un sujeto se levanta o se sienta de una silla, tiende a hacer una ligera inclinación hacia adelante con respecto a la posición de reposo hasta que recupera su inclinación inicial (ver Figura 5.1), que incluso se puede observar en sujetos con movilidad reducida [78].

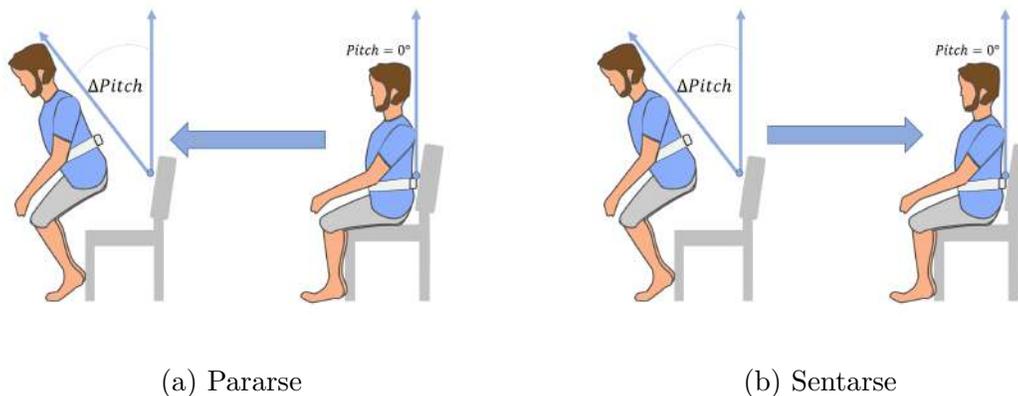


Fig. 5.1: Identificación de los eventos de sentarse y levantarse usando la señal *Pitch*.

Para acondicionar la señal *Pitch*, la señal de inclinación es filtrada usando un filtro media de orden $N = 5$ (ver Ecuación (5.1)) y se normaliza por el máximo absoluto de la señal filtrada, como se ve en la ecuación (5.2):

$$Pitch_{smooth}(n) = \frac{1}{N} [Pitch(n) + Pitch(n+1) + \dots + Pitch(n+N-1)], \quad (5.1)$$

$$Pitch_{norm}(n) = \frac{Pitch_{smooth}(n)}{\max(|Pitch_{smooth}|)}. \quad (5.2)$$

Luego, la señal de *Pitch* se procesa usando un detector de máximos locales, encontrando T_{peak1} y T_{peak2} , que corresponde al ángulo máximo de inclinación durante los eventos de levantarse y sentarse, respectivamente. (vea la Figura 5.2).

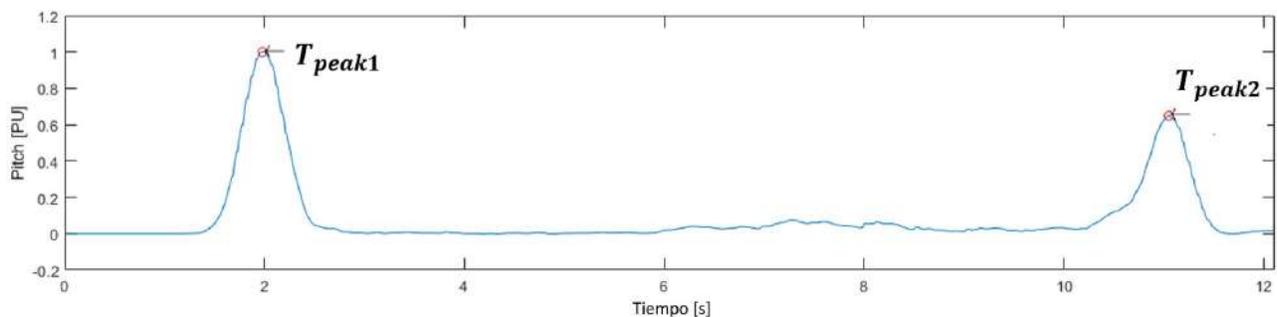


Fig. 5.2: Señal de inclinación con la máxima inclinación identificada [Elaboración Propia]

Luego, se calcula la derivada de la señal a la izquierda de T_{peak1} , como se indica en la Ecuación

(5.3), y a la derecha de T_{peak1} , como indicado en la Ecuación (5.4), para iniciar la búsqueda del evento de levantarse, donde i es un iterador. Por lo tanto, el inicio y el final de la acción para levantarse es obtenida usando las ecuaciones (5.5) y (5.6), respectivamente, con un factor de 0.05 como condición de término de búsqueda, que se encontró experimentalmente:

$$\Delta_1 = |Pitch_{norm}(T_{peak1} - i - 0.1) - Pitch_{norm}(T_{peak1} - i)| < 0.05, \quad i = 0, 0.1, 0.2, \dots, \quad (5.3)$$

$$\Delta_2 = |Pitch_{norm}(T_{peak1} + i + 0.1) - Pitch_{norm}(T_{peak1} + i)| < 0.05, \quad i = 0, 0.1, 0.2, \dots, \quad (5.4)$$

$$levantarse_i = T_{peak1} - i, \quad (5.5)$$

$$sentarse_f = T_{peak1} + i. \quad (5.6)$$

De manera similar, a través de la misma metodología, la acción de sentarse se busca usando la diferencia entre las muestras a la izquierda de T_{peak2} , como se indica en la Ecuación (5.7), y a la derecha de T_{peak2} , como se indica en la Ecuación (5.8). Luego, el inicio y el final de la acción de sentarse se obtienen usando las Ecuaciones (5.9) y (5.10), respectivamente:

$$\Delta_3 = |Pitch_{norm}(T_{peak2} - i - 0.1) - Pitch_{norm}(T_{peak2} - i)| < 0.05, \quad i = 0, 0.1, 0.2, \dots, \quad (5.7)$$

$$\Delta_4 = |Pitch_{norm}(T_{peak2} + i + 0.1) - Pitch_{norm}(T_{peak2} + i)| < 0.05, \quad i = 0, 0.1, 0.2, \dots, \quad (5.8)$$

$$sentarse_i = T_{peak2} - i, \quad (5.9)$$

$$sentarse_f = T_{peak2} + i. \quad (5.10)$$

La Figura 5.3 muestra el resultado final del método de búsqueda y la Figura 5.4 muestra el método propuesto la identificación de las acciones de levantarse/sentarse lo que permite extraer las características temporales asociadas a la duración de cada una de las actividades realizadas durante la prueba además de otros parámetros de movilidad como aceleraciones y grados de inclinación.

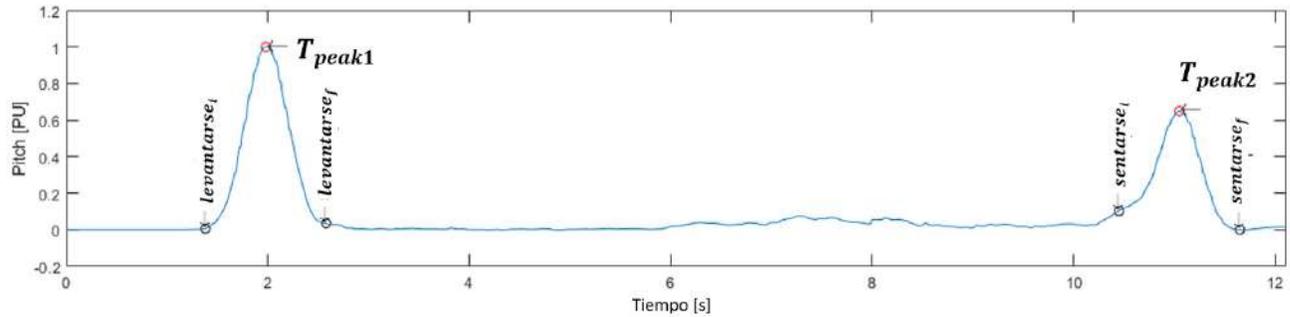


Fig. 5.3: Resultado del método usado para la búsqueda e identificación del inicio y el final de los eventos de levantarse y sentarse. [Elaboración Propia]



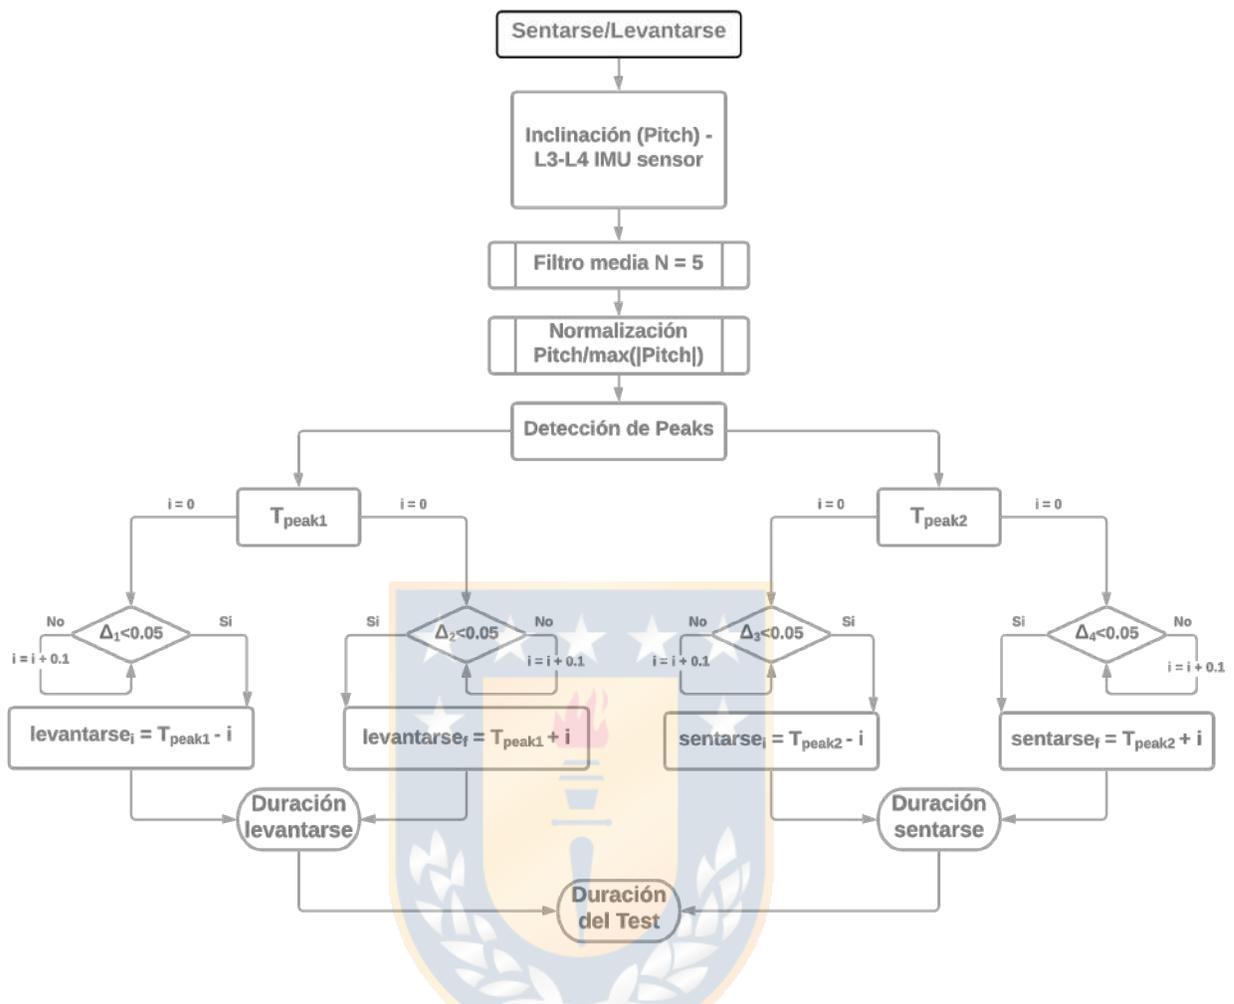


Fig. 5.4: Algoritmo automático de segmentación basado en características para las actividades de levantarse y sentarse, así como para el inicio y final del TU&Go. [Elaboración Propia]

5.1.1.2. Identification de los eventos de giro

Para determinar los giros alrededor de la marca de 3 metros y antes de sentarse, se usa *Yaw*, que corresponde a los cambios en la orientación del sensor ubicado en la espalda durante los giros. Cuando un sujeto realiza la prueba TU&Go, se somete a un circuito que lo obliga a realizar giros de 180 grados, los cuales pueden ser medidos de manera inequívoca por el sensor, ya que, durante los giros, el sensor también cambia su orientación junto a él (ver Figura 5.5).

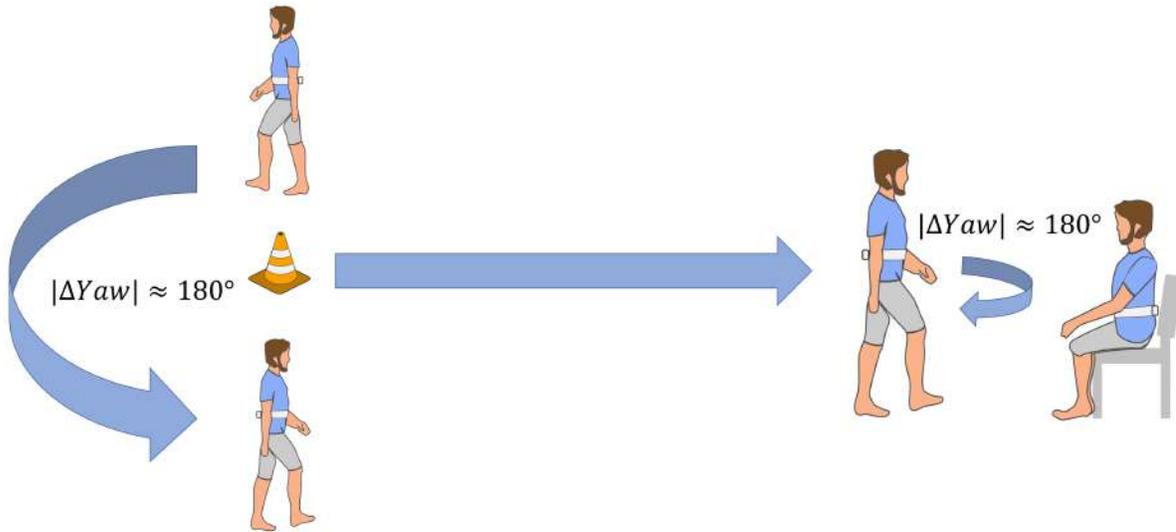


Fig. 5.5: Identificación de los eventos de giro usando la señal Yaw.

Para acondicionar la señal de cambio de orientación, tal como para el caso de la señal de inclinación, es suavizada con un filtro media de orden $N = 5$ (ver Ecuación (5.11)) y normalizada por el valor absoluto del máximo de la señal, como se ilustra en la Ecuación (5.12):

$$Yaw_{smooth}(n) = \frac{1}{N} [Yaw(n) + Yaw(n+1) + \dots + Yaw(n+N-1)], \quad (5.11)$$

$$Yaw_{norm}(n) = \frac{Yaw_{smooth}(n)}{\max(|Yaw_{smooth}|)}. \quad (5.12)$$

Luego, la señal de rotación es derivada para identificar el valor máximo $\max(d/dt)$ y el mínimo $\min(d/dt)$, los que son útiles para identificar los puntos de inicio y término de cada giro.

Luego, a través de una ventana deslizante de 0.1 segundos o 10 muestras (Ecuaciones (5.13) y (5.14)), se busca el inicio del giro en la marca de los 3 metros calculando la media de las muestras en la ventana a la izquierda de $\max(d/dt)$ y el final del giro de 3 metros calculando la media de las muestras en la ventana a la derecha de $\max(d/dt)$ usando las ecuaciones (5.15) y (5.16), respectivamente:

$$W_1 = [T_{\max(d/dt)} - 0.01 - i, T_{\max(d/dt)} - i], \quad (5.13)$$

$$W_2 = [T_{max(d/dt)} + i, T_{max(d/dt)} + 0.01 + i], \quad (5.14)$$

$$\overline{W_1} > 0.02, \quad i = 0, 0.01, 0.02, 0.03, \dots, \quad (5.15)$$

$$\overline{W_2} < 0.9, \quad i = 0, 0.01, 0.02, 0.03, \dots \quad (5.16)$$

Finalmente, el inicio y el final del giro en la marca de 3 metros se obtienen mediante las ecuaciones (5.17) y (5.18), respectivamente:

$$giro\ 1_i = \min(W_1), \quad (5.17)$$

$$giro\ 1_f = \max(W_2). \quad (5.18)$$

Por otro lado, utilizando una ventana deslizante de 0.1 segundos o 10 muestras (Ecuaciones (5.19) y (5.20)), se busca el inicio del giro antes del evento de sentarse calculando la media de las muestras en la ventana a la izquierda de $\min(d/dt)$ y el final del giro antes del evento de sentarse calculando la media de las muestras en la ventana a la derecha de $\min(d/dt)$ usando las ecuaciones (5.21) y (5.22), respectivamente:

$$W_3 = [T_{min(d/dt)} - 0.01 - i, T_{min(d/dt)} - i], \quad (5.19)$$

$$W_4 = [T_{min(d/dt)} + i, T_{min(d/dt)} + 0.01 + i], \quad (5.20)$$

$$\overline{W_3} < 0.9, \quad i = 0, 0.01, 0.02, 0.03, \dots, \quad (5.21)$$

$$\overline{W_4} > 0.02, \quad i = 0, 0.01, 0.02, 0.03, \dots \quad (5.22)$$

De manera similar, el inicio y el final del giro previo al evento de sentarse se obtienen mediante las ecuaciones (5.23) y (5.24), respectivamente:

$$giro2_i = \min(W_3), \quad (5.23)$$

$$giro2_f = \max(W_4). \quad (5.24)$$

La Figura 5.6 muestra el resultado final del método de búsqueda y la Figura 5.7 indica el método de identificación de las actividades de giro propuestas lo que permite extraer las características temporales asociadas a la duración de cada una de las actividades realizadas durante la prueba además de otros parámetros de movilidad como velocidades angulares y potenciales parámetros del ciclo de la marcha.

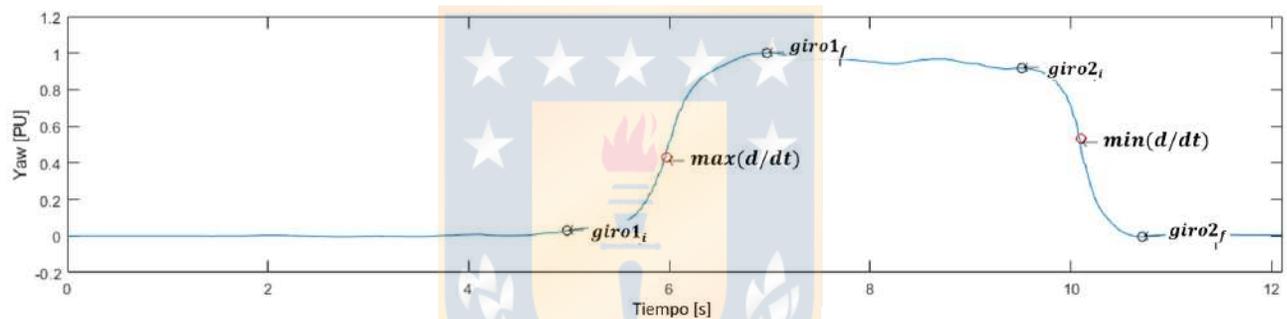


Fig. 5.6: Resultado del método usado para la búsqueda e identificación del inicio y el final de los eventos de giro. [Elaboración Propia]

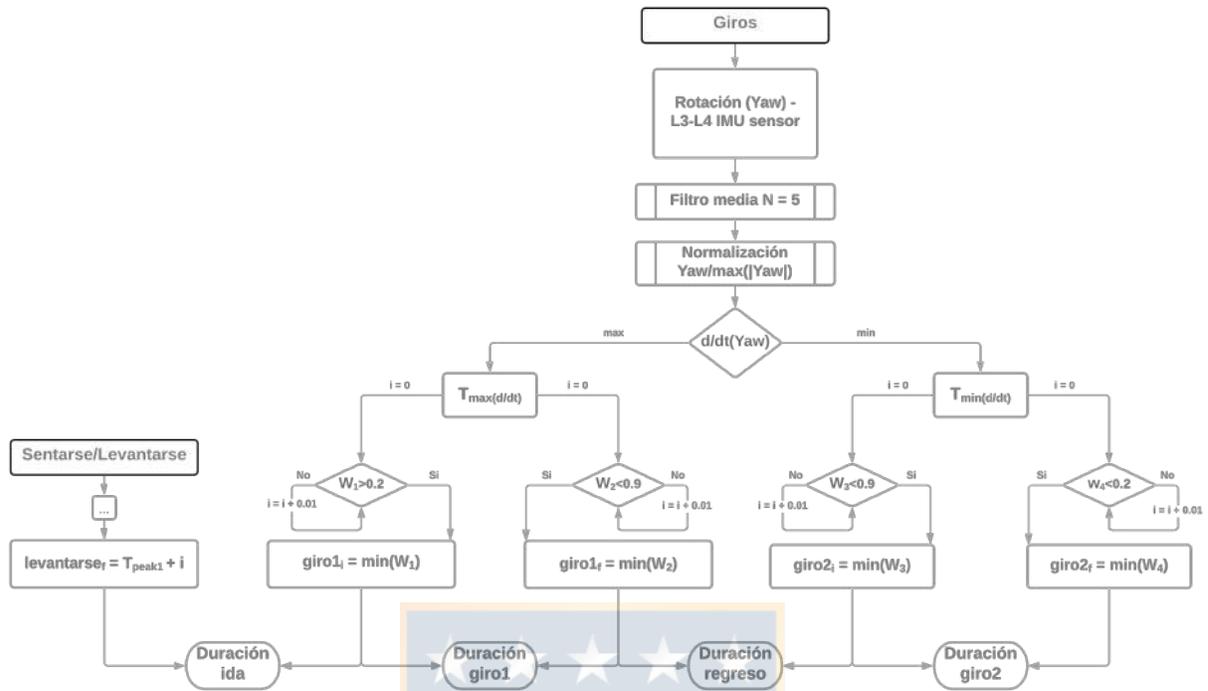


Fig. 5.7: Algoritmo automático de segmentación basado en características para las actividades de giro durante el TU&Go. [Elaboración Propia]

De esta manera, el resultado final de segmentación con las características temporales extraídas se puede ver, a modo de ejemplo, en la Figura 5.8.



Fig. 5.8: Características medidas después de la segmentación de las actividades realizadas en el TU&Go. [Elaboración Propia]

5.1.2. Validación

Para validar el algoritmo de segmentación propuesto, se reclutaron un total de 25 sujetos jóvenes sanos (18 hombres y 7 mujeres) entre 25 y 33 años, y 12 personas mayores (7 hombres

y 5 mujeres) entre 59 y 93 años.

Los criterios de exclusión fueron el diagnóstico de enfermedad neurológica, vestibular, musculoesquelética o sistémica que pudiera alterar la capacidad de caminar; el diagnóstico de cualquier enfermedad cardiovascular, respiratoria o metabólica u otras condiciones que pudieran interferir con el presente estudio; haber sido sometidos a cirugía en tronco y miembros inferiores al menos dos años antes del presente estudio, el uso de dispositivos de asistencia para la marcha y la presencia de alteraciones visuales graves que pudieran alterar el patrón de la marcha.

Las mediciones se realizaron en el laboratorio de Ingeniería Biomédica y en las instalaciones del departamento de Kinesiología de la Universidad de Concepción. Antes de las mediciones, se explicó la prueba a los participantes y se realizaron dos ensayos sin recopilación de datos para verificar la comprensión de cada participante. La autorización se solicitó mediante consentimiento informado, el cual fue aprobado por el Comité de Bioseguridad, Bioética y Ética de la Facultad de Medicina de la Universidad de Concepción.

5.1.2.1. Procedimiento de medición

El sensor desarrollado se ubica en la parte posterior de la espalda a la altura de L3–L5 para sujetos jóvenes y ancianos. Se ha demostrado que el uso de una única IMU en esa posición permite la detección de todos los eventos de la marcha, elementos biomecánicos de la pelvis y otros factores de cinemática espacial y temporal [61, 63, 79].

La prueba TU&Go se realizó siguiendo las recomendaciones de [56]. A tres metros de la silla, se utilizó un cono para marcar el lugar donde los pacientes debían girar para volver al punto de partida. Antes de realizar las pruebas, se explicó el procedimiento con una demostración, para resolver y aclarar dudas. Cada participante fue grabado a 60 fps usando una cámara de video digital de alta resolución GOPRO HERO 7 usando el modo de Campo de Visión Lineal para reducir la distorsión de la imagen.

Tres repeticiones de la prueba TU&Go fueron realizadas por el grupo de adultos mayores, utilizando para el análisis el desempeño del tiempo superior de la prueba realizada. Para el grupo joven, solo se realizó una prueba.

La Figura 5.9 muestra la configuración utilizada para las mediciones.

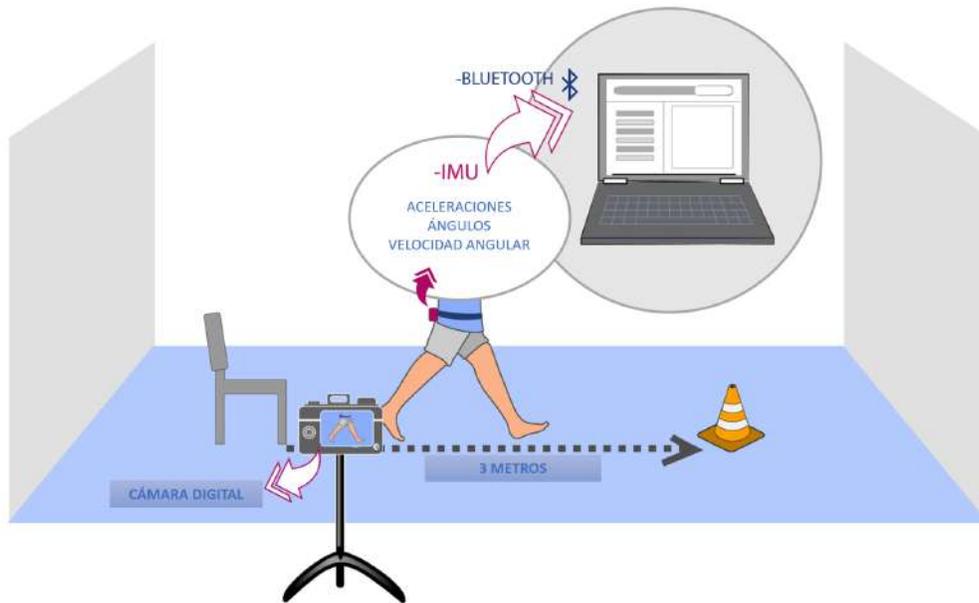


Fig. 5.9: Configuración utilizada para las mediciones del TU&Go.

5.1.2.2. Validación prueba instrumentalizada frente al procedimiento clínico estándar

Los datos se analizaron utilizando MATLAB R2017b para obtener los resultados presentados en esta sección. La grabación de video se analizó usando el editor de video Wondershare Filmora versión 8.4.0. En la Figura 5.10 se observa el plano de grabación sagital usado para la segmentación por video mientras los datos son enviados a una plataforma de adquisición mientras se realiza el TU&Go.



Fig. 5.10: Configuración utilizada para las mediciones del TU&Go en laboratorio mientras los datos son medidos inalámbricamente de manera simultánea en una plataforma de adquisición.

Para evaluar el desempeño de la metodología propuesta en relación al procedimiento clínico visual estándar, se tabuló el tiempo total de cada prueba TU&Go capturada en videos para población joven y mayor, obtenida como el promedio de los tiempos observados fotograma a fotograma por dos evaluadores diferentes para compensar el error inter-evaluador. Esto se utilizó para observar el error de medición y el coeficiente de correlación de Pearson con respecto a la aplicación clínica típica para evaluar el nivel diagnóstico de la prueba instrumentalizada con el sensor y algoritmo propuesto respecto a la práctica clínica real. Los resultados se presentan en la Tabla 5.1 y se muestran en la Figura 5.11.

Tabla 5.1: Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico visual estándar en sujetos jóvenes.

Sujeto	Altura [cm]	Peso [kg]	Edad [años]	Sexo	Duración video [s]	Duración IMU [s]
Sujeto 1	179	93	25	masculino	10.46	10.26
Sujeto 2	168	70	25	masculino	10.73	10.56
Sujeto 3	176	81	28	masculino	10.66	10.52
Sujeto 4	164	68	26	femenino	8.60	8.24
Sujeto 5	160	68	25	femenino	8.63	8.43
Sujeto 6	162	70	29	masculino	8.00	7.92
Sujeto 7	168	80	26	femenino	10.40	9.83
Sujeto 8	152	48	25	femenino	10.16	9.29
Sujeto 9	195	90	26	femenino	10.30	10.01
Sujeto 10	190	80	29	masculino	10.66	10.63
Sujeto 11	169	68	29	masculino	10.60	10.62
Sujeto 12	153	77	27	masculino	10.60	10.61
Sujeto 13	160	73	33	femenino	10.93	10.76
Sujeto 14	172	81	31	femenino	10.26	10.09
Sujeto 15	168	70	26	masculino	10.50	10.38
Sujeto 16	173	79	28	masculino	10.46	10.40
Sujeto 17	170	73	25	masculino	10.50	10.36
Sujeto 18	163	60	32	masculino	8.86	8.83
Sujeto 19	175	70	28	masculino	8.83	8.72
Sujeto 20	171	68	33	masculino	9.06	8.98
Sujeto 21	165	70	32	masculino	8.36	8.18
Sujeto 22	179	73	26	masculino	10.10	9.94
Sujeto 23	185	79	26	masculino	9.16	8.99
Sujeto 24	190	83	30	masculino	10.33	10.33
Sujeto 25	160	58	29	masculino	10.30	9.99

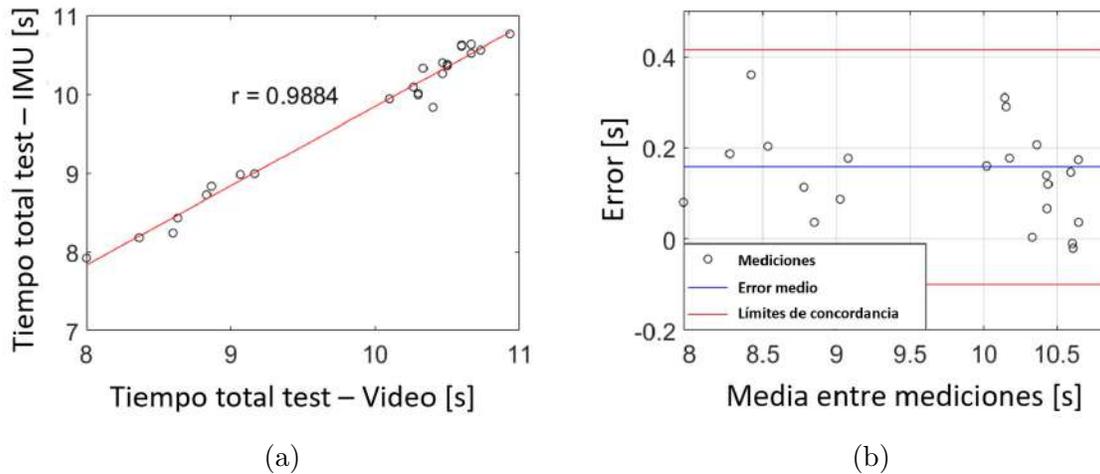


Fig. 5.11: Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico estándar en sujetos jóvenes. **(a)** coeficiente de correlación de Pearson entre IMU y el análisis de grabación por video; **(b)** Gráfico Bland-Altman entre IMU y el análisis de grabación de vídeo.

Además, se utilizó la metodología propuesta en adultos mayores para evaluar el desempeño en la población objetivo. De igual forma, los resultados obtenidos se presentan en la Tabla 5.2 y la Figura 5.12.

Tabla 5.2: Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico visual estándar en el grupo de personas mayores. La clasificación del riesgo de caída de los sujetos se obtuvo siguiendo el manual del Ministerio de Salud (MINSAL) para la población chilena [2].

Sujeto	Altura [cm]	Peso [kg]	Edad [años]	Sexo	Duración video [s] (Riesgo)	Duración IMU [s] (Riesgo)
Sujeto 1	168	75	60	masculino	11.00 (Riesgo)	10.51 (Riesgo)
Sujeto 2	168	72	60	masculino	9.63 (No)	8.98 (No)
Sujeto 3	156	90	63	masculino	10.73 (Riesgo)	10.57 (Riesgo)
Sujeto 4	170	68	65	masculino	9.76 (No)	9.59 (No)
Sujeto 5	179	64	71	masculino	12.00 (Riesgo)	11.95 (Riesgo)
Sujeto 6	157	62	60	femenino	13.76 (Riesgo)	13.13 (Riesgo)
Sujeto 7	178	93	67	masculino	9.36 (No)	9.27 (No)
Sujeto 8	160	51	63	femenino	9.03 (No)	8.87 (No)
Sujeto 9	145	70	59	femenino	10.43 (Riesgo)	9.92 (No)
Sujeto 10	173	84	59	masculino	10.60 (Riesgo)	10.23 (Riesgo)
Sujeto 11	160	68	59	femenino	9.33 (Riesgo)	9.44 (Riesgo)
Sujeto 12	157	61	93	femenino	43 (Alto riesgo)	42.99 (Alto riesgo)

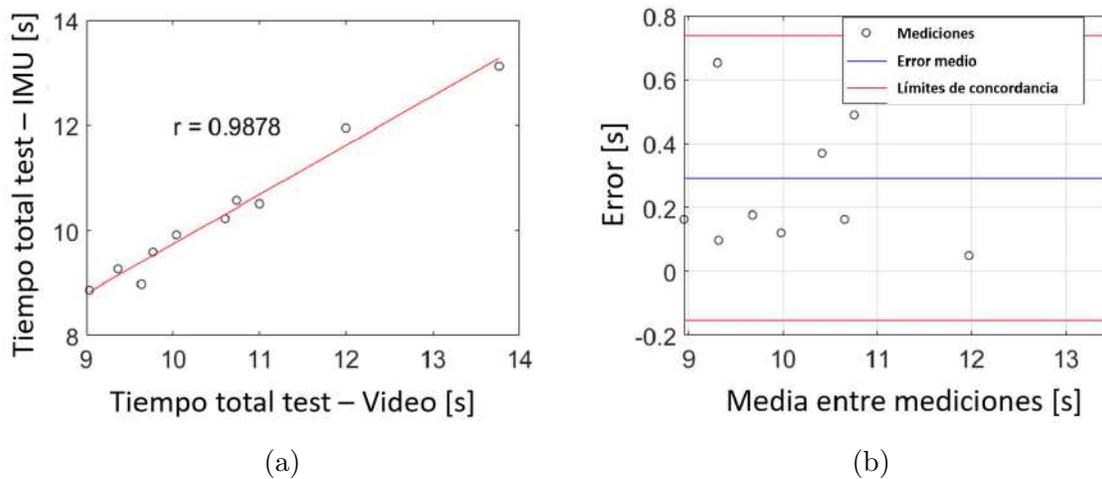


Fig. 5.12: Resultados de las mediciones obtenidas por la metodología propuesta versus el procedimiento clínico estándar en personas mayores. **(a)** coeficiente de correlación de Pearson entre IMU y el análisis de grabación por video; **(b)** Gráfico Bland-Altman entre IMU y el análisis de grabación de video.

El sistema de medición con la metodología propuesta tiene un desempeño similar al obtenido para sujetos jóvenes sanos, con un coeficiente de correlación de Pearson de 0.9878 (ver Figura 5.12) y un error medio de 0.20 ± 0.22 s como se muestra en la Figura 5.12. Además, la metodología propuesta fue capaz de clasificar correctamente el 92 % de los sujetos medidos según su riesgo de caída, teniendo en cuenta el tiempo total de la prueba valorada por la IMU, incluyendo sujetos con alto riesgo de caída (ver Sujeto 12 de la Tabla 5.2).

5.1.2.3. Análisis de segmentación de actividades

Para evaluar el desempeño del algoritmo de segmentación propuesto, se analizaron los videos de las pruebas de cada sujeto y se tabuló el tiempo de cada etapa para compararlo con los tiempos obtenidos al procesar los datos de inclinación (*Pitch*) y la rotación del sensor (*Yaw*).

La Figura 5.13 muestra la correlación para el tiempo de segmentación de cada actividad para los sujetos jóvenes, mostrando que la correlación mínima se obtiene en la identificación de la transición entre el final de la bipedestación y el inicio de la primera caminata con un Coeficiente de correlación de Pearson de 0.8138 (ver Figura 5.13a). La mejor correlación ocurre en los tiempos de identificación de la transición entre el final del primer giro y el inicio de la marcha de vuelta con un coeficiente de correlación de Pearson de 0.9854 (ver Figura 5.13d). Lo

anterior indica que el sistema de medición tiene un alto grado de concordancia con respecto a una segmentación visual.

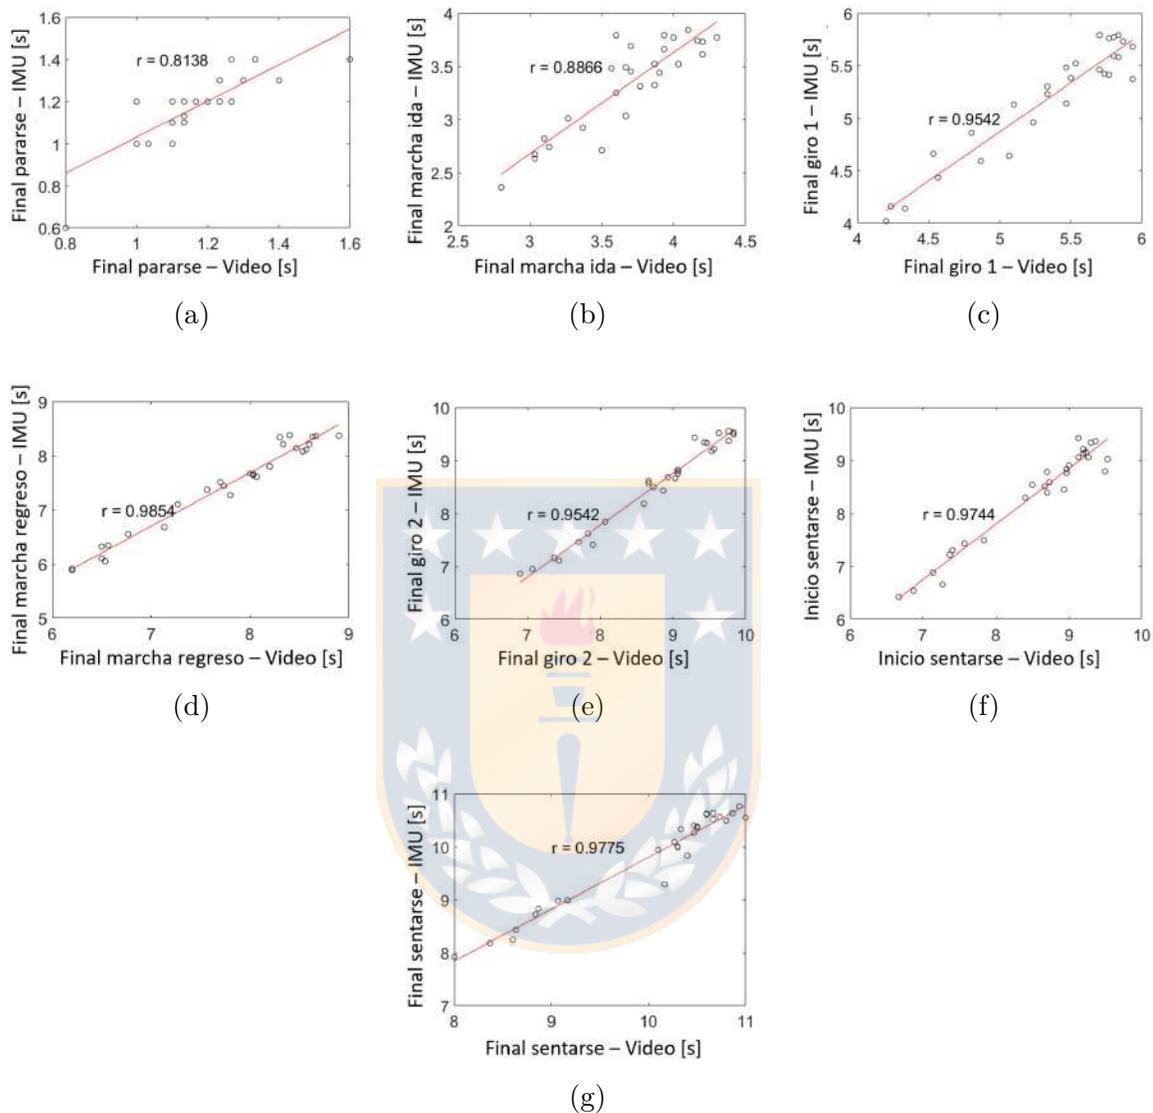


Fig. 5.13: Coeficiente de correlación de Pearson para el tiempo de segmentación para cada subtarea de la prueba TU&Go en sujetos jóvenes. (a) fin de pararse/inicio de la marcha de ida; (b) fin de la marcha de ida/inicio del giro 1; (c) fin del giro 1/inicio de la marcha de regreso; (d) fin de la marcha de regreso/inicio del giro 2; (e) fin del giro 2; (f) inicio de sentarse; (g) fin de sentarse.

La Figura 5.14 muestra los errores de medición entre la metodología de segmentación propuesta para cada actividad durante la prueba TU&Go en los sujetos jóvenes en comparación con el análisis de vídeo. En la Figura 5.14a, se observa que el algoritmo de segmentación es

capaz de identificar la transición de la transferencia sedente a bípeda con un error medio de -0.02 [s]. La Figura 5.14b muestra que la transición entre el final de la marcha de ida y el comienzo del primer giro se identifica con un error medio de 0.36 [s]. La Figura 5.14c muestra que la transición entre el final del primer giro y la marcha de regreso se identifica con un error medio de 0.11 [s]. La figura 5.14d muestra que la transición entre el final de la marcha de regreso y el comienzo del giro previo a sentarse se identifica con un error medio de 0.25 [s]. La actividad del giro previo a sentarse se identifica con un error medio de 0.16 [s] (ver Figura 5.14e). Con respecto a la actividad de sentarse, el algoritmo identifica su inicio con un error medio de 0.18 [s] (ver Figura 5.14f) y el final con un error medio de 0.24 [s] (ver Figura 5.14g).



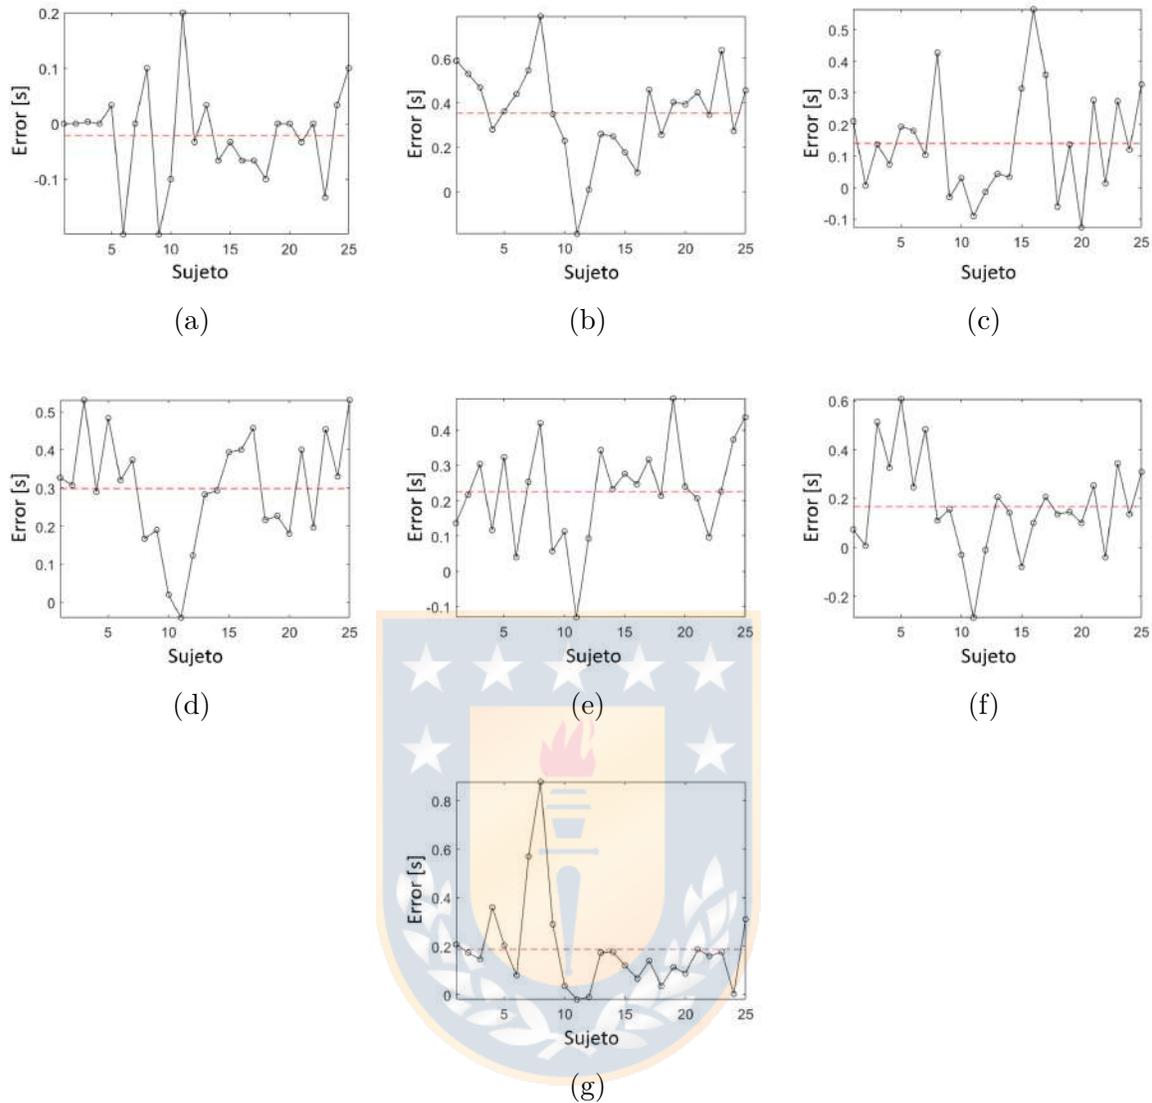


Fig. 5.14: Gráficos de error de la segmentación resultante para cada subtarea del TU&Go en sujetos jóvenes. Las líneas segmentadas corresponden al error medio. **(a)** fin de pararse/inicio de la marcha de ida; **(b)** fin de la marcha de ida/inicio del giro 1; **(c)** fin del giro 1/inicio de la marcha de regreso; **(d)** fin de la marcha de regreso/inicio del giro 2; **(e)** fin del giro 2; **(f)** inicio de sentarse; **(g)** fin de sentarse.

La Figura 5.15 muestra los errores de medición entre la metodología de segmentación propuesta para cada actividad durante la prueba TU&Go en el grupo de personas mayores en comparación con el análisis de video. En la Figura 5.15a, se observa que el algoritmo de segmentación es capaz de identificar la transición de la transferencia sedente a bípeda con un error medio de 0.07 [s]. La Figura 5.15b muestra que la transición entre el final de la marcha de ida y el comienzo del primer giro se identifica con un error medio de 0.29 s [s]. La Figura 5.15c

muestra que la transición entre el final del primer giro y la marcha de regreso se identifica con un error medio de 0.43 s [s]. La figura 5.15d muestra que la transición entre el final de la marcha de regreso y el comienzo del giro previo a sentarse se identifica con un error medio de 0.63 [s]. La actividad del giro previo a sentarse se identifica con un error medio de 0.21 [s] (ver Figura 5.15e). Con respecto a la actividad de sentarse, el algoritmo identifica su inicio con un error medio de 0.25 [s] (ver Figura 5.15f) y el final con un error medio de 0.26 [s] (ver Figura 5.15g).

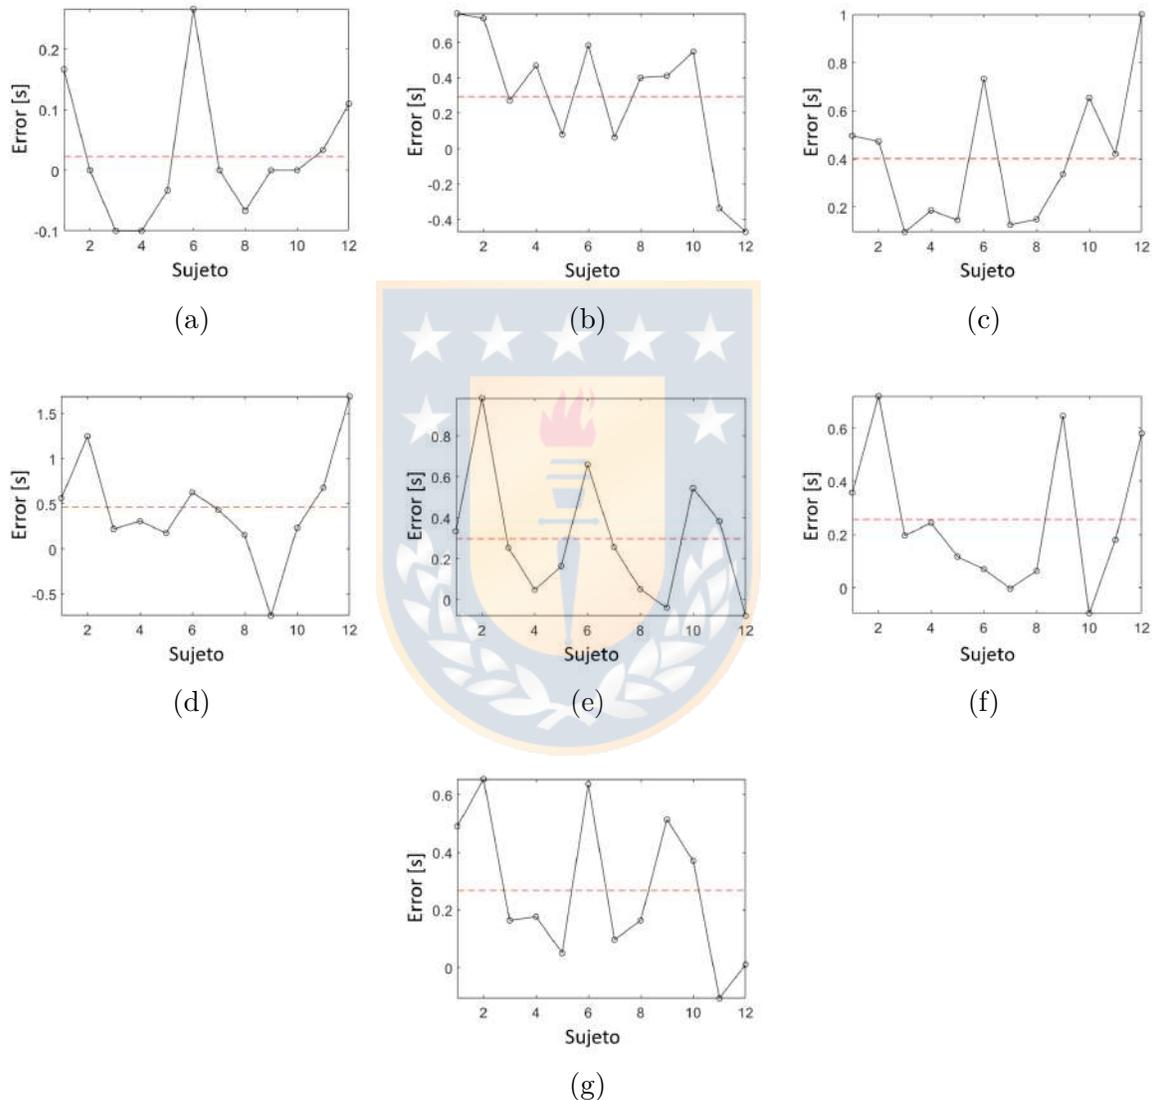


Fig. 5.15: Gráficos de error de la segmentación resultante para cada subtask del TU&Go en personas mayores. Las líneas segmentadas corresponden al error medio. **(a)** fin de pararse/inicio de la marcha de ida; **(b)** fin de la marcha de ida/inicio del giro 1; **(c)** fin del giro 1/inicio de la marcha de regreso; **(d)** fin de la marcha de regreso/inicio del giro 2; **(e)** fin del giro 2; **(f)** inicio de sentarse; **(g)** fin de sentarse.

mencionadas a continuación como: señal antero-posterior de aceleración (A-P), señal vertical de aceleración (V), y señal medio-lateral de aceleración (M-L). Lo anterior para evitar ligar la orientación del sensor a una sola y presentar un algoritmo general.

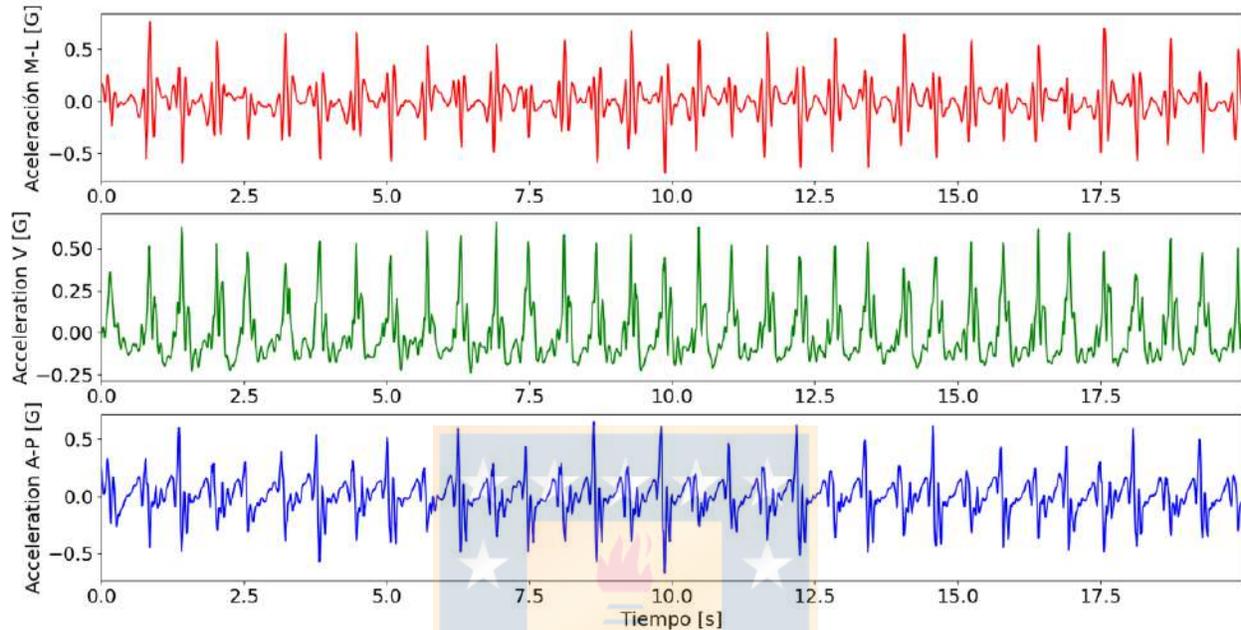


Fig. 5.17: Señales características de un acelerómetro de tres ejes en la espalda baja durante la marcha. [Elaboración Propia]

Durante la ejecución de la marcha se presenta una forma de onda cíclica y característica a partir de las señales A-P, V y M-L del acelerómetro (ver Figura 5.17), que puede ser utilizada para identificar los eventos de IC y FC como se presenta a continuación:

1. Filtrado de la señal A-P con un filtro FIR pasa-bajo de orden 11.
2. Detectar dos cruces por cero consecutivos de la señal A-P filtrada, que tengan una distancia mayor a un umbral definido como la tercera parte de la mayor distancia entre los cruces por cero con el área positivo.
 - a) Si es válido, continuar.
 - b) Si no es válido, volver a paso 1.
3. Buscar máximo local absoluto en A-P. Este punto corresponde al evento de IC.
4. Desde el evento de IC hacia el siguiente cruce por 0 hacia la derecha de la señal A-P, buscar el mínimo local absoluto en la señal V. Este punto corresponde al evento de FC.

5. Entre los eventos de IC y FC identificados, buscar el valor máximo y mínimo absolutos de la señal M-L.
 - a) Si el valor máximo se ubica antes de el valor mínimo, el paso es derecho.
 - b) Si el valor mínimo se ubica antes de el valor máximo, el paso es izquierdo.

El resultado de aplicar el algoritmo anterior se ilustra en la Figura 5.18. Una vez identificados los eventos del ciclo de la marcha, se puede proceder a realizar los cálculos de los índices espacio-temporales que la caracterizan.

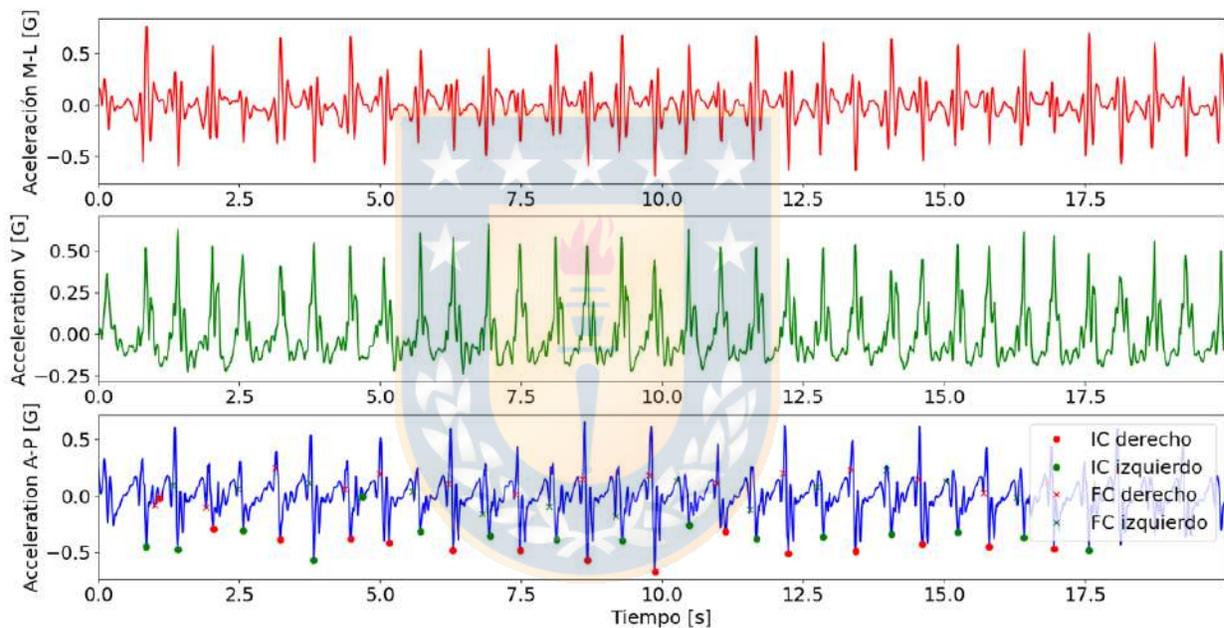


Fig. 5.18: Eventos del ciclo de la marcha identificados en un sujeto con riesgo de caída usando un acelerómetro de tres ejes en la espalda baja. [Elaboración Propia]

5.2.1.1. Cálculo índices temporales

Los índices temporales corresponden a aquellos que, a partir de la duración de sub-eventos del ciclo de la marcha, permiten caracterizarla.

Para calcular el índice del ciclo de la marcha es necesario identificar como mínimo 1 ciclo de marcha para cada extremidad (derecha e izquierda), lo que corresponde a la identificación de 4 eventos de IC y 4 eventos de FC. Si el primer evento detectado corresponde a un IC derecho usar 5.25. Caso contrario, usar 5.26.

$$ciclo_i = \{IC_{R_i}, FC_{L_i}, IC_{L_i}, FC_{R_i}, IC_{R_{i+1}}, FC_{L_{i+1}}, IC_{L_{i+1}}, FC_{R_{i+1}}\} \quad (5.25)$$

$$ciclo_i = \{IC_{L_i}, FC_{R_i}, IC_{R_i}, FC_{L_i}, IC_{L_{i+1}}, FC_{R_{i+1}}, IC_{R_{i+1}}, FC_{L_{i+1}}\} \quad (5.26)$$

De las ecuaciones 5.25 y 5.26, R corresponde a un evento derecho, L corresponde a un evento izquierdo y el sub-índice i es un iterador que va desde 1 hasta el máximo de ciclos identificados. Considerar todos estos eventos en segundos.

Una vez obtenido al menos 1 ciclo de marcha, se pueden calcular los siguientes índices temporales:

- Cadencia: Cantidad de pasos en 1 minuto (ver ecuaciones 5.27 y 5.28).

$$Cadencia_R = \frac{60}{(IC_{R_{i+1}} - IC_{L_i})} \quad (5.27)$$

$$Cadencia_L = \frac{60}{(IC_{L_{i+1}} - IC_{R_i})} \quad (5.28)$$

- Tiempo de zancada: Tiempo que toma en realizar una zancada, definida como el tiempo entre dos IC ipsilaterales (ver ecuaciones 5.29 y 5.30).

$$Tiempodezancada_R = (IC_{R_{i+1}} - IC_{R_i}) \quad (5.29)$$

$$Tiempodezancada_L = (IC_{L_{i+1}} - IC_{L_i}) \quad (5.30)$$

- Tiempo de paso: Tiempo que toma en realizar un paso, definido como el tiempo entre dos IC contralaterales (ver ecuaciones 5.31 y 5.32).

$$Tiempodepaso_R = (IC_{R_{i+1}} - IC_{L_i}) \quad (5.31)$$

$$Tiempodepaso_L = (IC_{L_{i+1}} - IC_{R_i}) \quad (5.32)$$

- Tiempo de soporte simple: Tiempo total en el que solo un pie esta en contacto con el suelo, definido como el tiempo entre un evento de FC y IC ipsilaterales (ver ecuaciones 5.33 y 5.34).

$$Tiempodesoportesimple_R = (IC_{L_i} - FC_{L_i}) \quad (5.33)$$

$$Tiempodesoportesimple_L = (IC_{R_{i+1}} - FC_{R_i}) \quad (5.34)$$

- Tiempo de soporte doble: Tiempo en que ambos pies estan en contacto con el suelo, definido como el tiempo entre un evento de IC y FC contralaterales (ver ecuaciones 5.35 y 5.36).

$$Tiempodesoportedoble_R = (FC_{L_i} - IC_{L_i}) \quad (5.35)$$

$$Tiempodesoportedoble_L = (FC_{R_{i+1}} - IC_{L_i}) \quad (5.36)$$

Además, se pueden extraer parámetros que permiten identificar de manera inmediata el estado general de la marcha:

- Fase de balanceo: Fase general de la marcha en la que un pie se mantiene en el aire. Se calcula como porcentaje del total de 1 ciclo de la marcha (ver ecuaciones 5.37 y 5.38).

$$\%Balanceo_R = \frac{100(FC_{R_i} - IC_{R_i})}{IC_{R_{i+1}} - IC_{R_i}} \quad (5.37)$$

$$\%Balanceo_L = \frac{100(FC_{L_{i+1}} - IC_{L_i})}{IC_{L_{i+1}} - IC_{L_i}} \quad (5.38)$$

- Fase de apoyo: Fase general de la marcha en la que un pie se mantiene en contacto con el suelo. Se calcula como porcentaje del total de 1 ciclo de la marcha (ver ecuaciones 5.39 y 5.40).

$$\%Apoyo_R = \frac{100(IC_{R_{i+1}} - FC_{R_i})}{IC_{R_{i+1}} - IC_{R_i}} \quad (5.39)$$

$$\%Apoyo_L = \frac{100(IC_{L_{i+1}} - FC_{L_i})}{IC_{L_{i+1}} - IC_{L_i}} \quad (5.40)$$

- Factor de simetría: Conociendo la duración o porcentaje de duración de cada fase de la marcha (balanceo y apoyo) para cada extremidad (izquierda y derecha), se puede extraer un factor para ver la simetría de la marcha cuyo valor se encuentra entre 0 y 1. Si el factor es cercano a 0 indica asimetría, donde 0 es asimetría perfecta. Si es cercano a 1 indica simetría, donde 1 es simetría perfecta. El cálculo se ilustra en la ecuación 5.41).

$$F_{simetría} = \frac{\min\{\%Apoyo_R, \%Apoyo_L\}}{\max\{\%Apoyo_R, \%Apoyo_L\}} = \frac{\min\{\%Balanceo_R, \%Balanceo_L\}}{\max\{\%Balanceo_R, \%Balanceo_L\}} \quad (5.41)$$

5.2.1.2. Cálculo índices espaciales - Longitud de paso

Para estimar la longitud del paso (SL) se han utilizado diferentes metodologías, como Rafael et al. [69], Zijlstra et al. [71] y Alvarez et al. [72], que son muy similares. Utilizan el mismo modelo para implementar sus algoritmos (modelo de péndulo invertido) midiendo el desplazamiento del tronco con un solo sensor. Además, presentan buenos resultados en sus investigaciones incluso en pruebas de larga distancia.

Por las razones expuestas en la sección 2.4.2 y ilustrada en la tabla 2.3, se utilizará el algoritmo presentado por Alvarez et al. [72], pues su desempeño ya ha sido evaluado previamente junto con el algoritmo de González et al. con el fin de obtener una estimación precisa.

Por cada paso detectado, es decir, por cada par de IC contralaterales de debe aplicar la fórmula obtenida a partir del modelo de péndulo invertido modificado presente en la Figura 5.19 (ver ecuaciones 5.42 y 5.43).

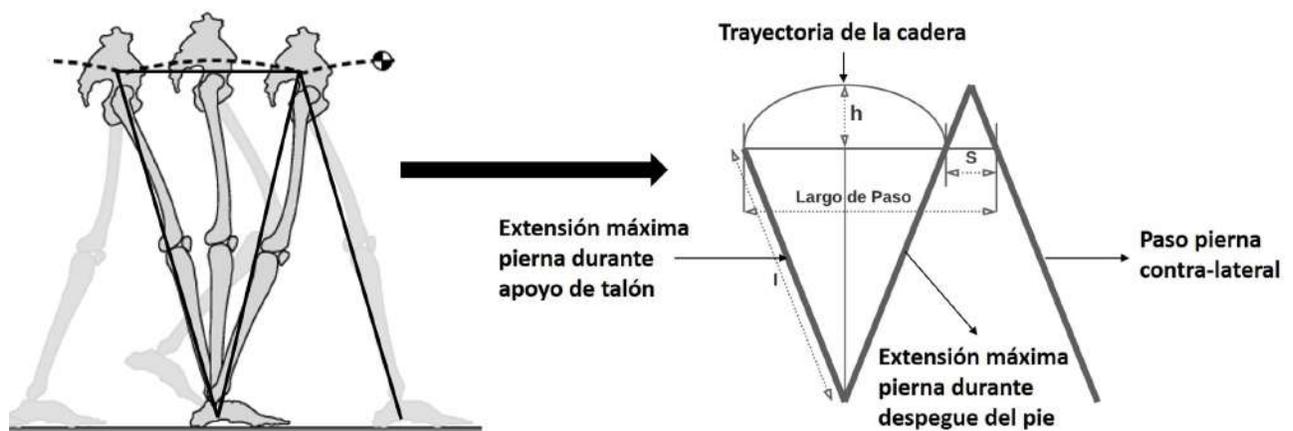


Fig. 5.19: Modelo biomecánico de cuerpo rígido usado para la estimación del largo de paso. [Elaboración Propia]

$$SL_R = 2\sqrt{2l_R h - h^2} + kS_R \quad (5.42)$$

$$SL_L = 2\sqrt{2l_L h - h^2} + kS_L \quad (5.43)$$

Donde l corresponde al largo de la pierna extendida (L para izquierdo y R para derecho), h el desplazamiento vertical de la pelvis obtenido a partir de la doble integración de la señal V (aceleración vertical), S el largo del pie y k un factor de corrección igual a 1.07 pero que depende de la población a medir.

5.2.2. Validación

20 sujetos jóvenes sanos (18 hombres y 2 mujeres) de 23 a 28 años fueron evaluados mediante el sistema de captura de movimiento Vicon modelo Bonita versión 2.7.1 y el software de análisis Polygon 4.4.2 para obtener los parámetros espacio-temporales de la marcha por profesionales capacitados en el uso del sistema de captura de movimiento. La configuración para las mediciones se ilustra en la Figura 5.20.

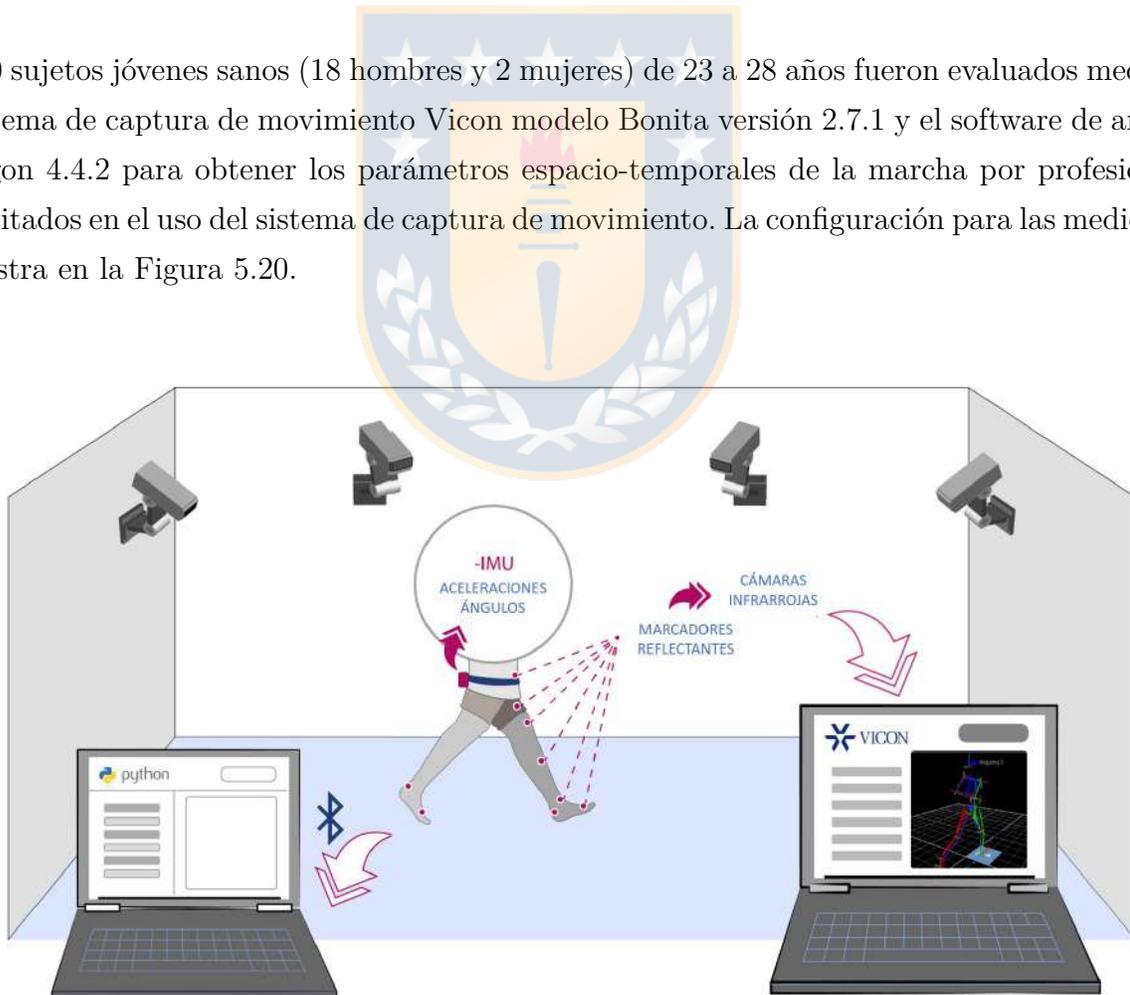


Fig. 5.20: Configuración usada para la validación del algoritmo a usar para la extracción de los eventos del ciclo de la marcha. [Elaboración Propia]

Se solicitó a los voluntarios que vistieran ropa deportiva y zapatos cómodos para realizar las pruebas con el fin de evitar factores externos que pudieran modificar el patrón de marcha de cada uno. La comodidad de los zapatos dependía de la percepción del sujeto y no de los evaluadores. Ningún sujeto fue medido descalzo, ya que nuestra intención es evaluar el algoritmo propuesto en las condiciones menos ideales dentro de un laboratorio de captura de movimiento.

Previo a las mediciones, cada sujeto firmó un documento de consentimiento informado, el cual fue aprobado por el Comité de Bioseguridad, Bioética y Ética de la Facultad de Medicina de la Universidad de Concepción.

Los criterios de exclusión fueron el diagnóstico de enfermedad neurológica, vestibular, musculoesquelética o sistémica que pudiera alterar la capacidad de caminar; el diagnóstico de cualquier enfermedad cardiovascular, respiratoria o metabólica u otra condición que pudiera interferir con el presente estudio; haber sido sometido a cirugía de tronco y miembros inferiores al menos dos años antes del presente estudio, el uso de dispositivos de ayuda para la marcha y la presencia de alteraciones visuales graves que pudieran alterar el patrón de la marcha.

5.2.2.1. Procedimiento de medición

Luego de la calibración del sistema de captura de movimiento y del registro previo de parámetros antropométricos y físicos de cada sujeto detallados en la Tabla 5.3, se ubicaron 16 marcadores reflectantes de 14 [mm] de diámetro en el cuerpo de cada sujeto según el modelo cinemático "Plug-In-Gait"[80] con el sensor IMU como se indica en la Figura 5.21.



Fig. 5.21: Ubicación de los marcadores infrarrojos para la realización de las pruebas de análisis de marcha usando un laboratorio de captura de movimiento optoelectrónico.

Tabla 5.3: Características de los sujetos de prueba para la estimación de parámetros espacio-temporales de la marcha

	Mínimo	Máximo	Media
Edad [Años]	23	28	27.27±0.20
Altura [cm]	151	194	170±20
Peso [kg]	56	118	71.68±17.20
Largo pierna derecha [cm]	82.50	96	88.92±4.98
Largo pierna izquierda [cm]	82.50	95	88.99±4.76
Ancho rodilla derecha [cm]	8.2	10.5	9.46±0.67
Ancho rodilla izquierda [cm]	8	10.3	9.41±0.68
Ancho talón derecho [cm]	6.70	7.80	7.08±0.42
Ancho talón izquierdo [cm]	6.50	7.80	7.11±0.47

En este caso, la sincronización de los sistemas - Inercial y Optoelectrónico - no es importante, ya que el objetivo no es revalidar los algoritmos para la detección de los eventos del ciclo de la marcha, sino la estimación de los parámetros espacio-temporales calculados por cada sistema.

Una vez localizados los marcadores y sensores, se realizó la medición a cada sujeto, a quien se

le solicitó caminar con normalidad, adquiriendo los datos de aceleraciones, velocidades angulares y las orientaciones de la zona lumbar.

5.2.2.2. Validación prueba sensorizada frente al método patrón

Para las mediciones realizadas en el laboratorio de movimiento optoelectrónico, los parámetros espacio-temporales se exportaron del software de análisis Polygon 4.4.2 a una hoja de cálculo, los cuales se compararon con las mediciones obtenidas a partir del algoritmo propuesto para la detección de eventos de IC y FC, y su procesamiento para la estimación de cadencia, tiempo de zancada, tiempo de paso, tiempo de apoyo simple, tiempo de apoyo doble, duración de la fase de zancada, duración de la fase de balanceo y largo de paso.

Las medidas se realizaron a partir del reposo, es decir, el sujeto de pie sin moverse. Así, para evitar singularidades con respecto a las acciones de aceleración - inicio de la marcha - y desaceleración - fin de la marcha - se eliminaron los dos pasos iniciales y los dos pasos finales de cada medición.

5.2.2.3. Validación cálculo parámetros temporales

Para comparar los resultados obtenidos de los parámetros espacio-temporales de la marcha estimados con el sistema propuesto con respecto a los estimados con el sistema de captura de movimiento, se realizó un análisis de distribución (ver Figura 5.22) y error (ver Figura 5.23) de las medidas obtenidas para cada sujeto.

En la Figura 5.22 se puede ver que las distribuciones para cada parámetro se mantienen dentro de las medidas entregadas por el sistema de captura de movimiento con diferencias en los valores extremos. Como los parámetros obtenidos por el sistema de captura de movimiento son de un solo ciclo, mientras que para el sistema propuesto se estimaron como el promedio de los parámetros de varios ciclos de marcha, es evidente que existen ciertas diferencias en las medidas, ya que los parámetros tienden a suavizar la presencia de valores atípicos durante su estimación.

Como en este trabajo solo se evaluaron personas jóvenes y sanas, se espera que los valores obtenidos para cada extremidad sean similares utilizando el mismo sistema de medición.

La Figura 5.23 muestra los errores en las estimaciones. Se observa que todas las mediciones

son capaces de entregar mediciones dentro de los límites de concordancia con poca diferencia respecto al laboratorio de análisis de movimiento. Los mejores resultados obtenidos fueron las estimaciones del tiempo de soporte simple con un error de $\pm 0,05$ [s] (ver Figura 5.23d) y el tiempo de soporte doble con un error de $\pm 0,07$ [s] (ver Figura 5.23e). Los peores resultados obtenidos corresponden a las estimaciones de cadencia, con errores de ± 10 [pasos/min] (ver Figura 5.23a).



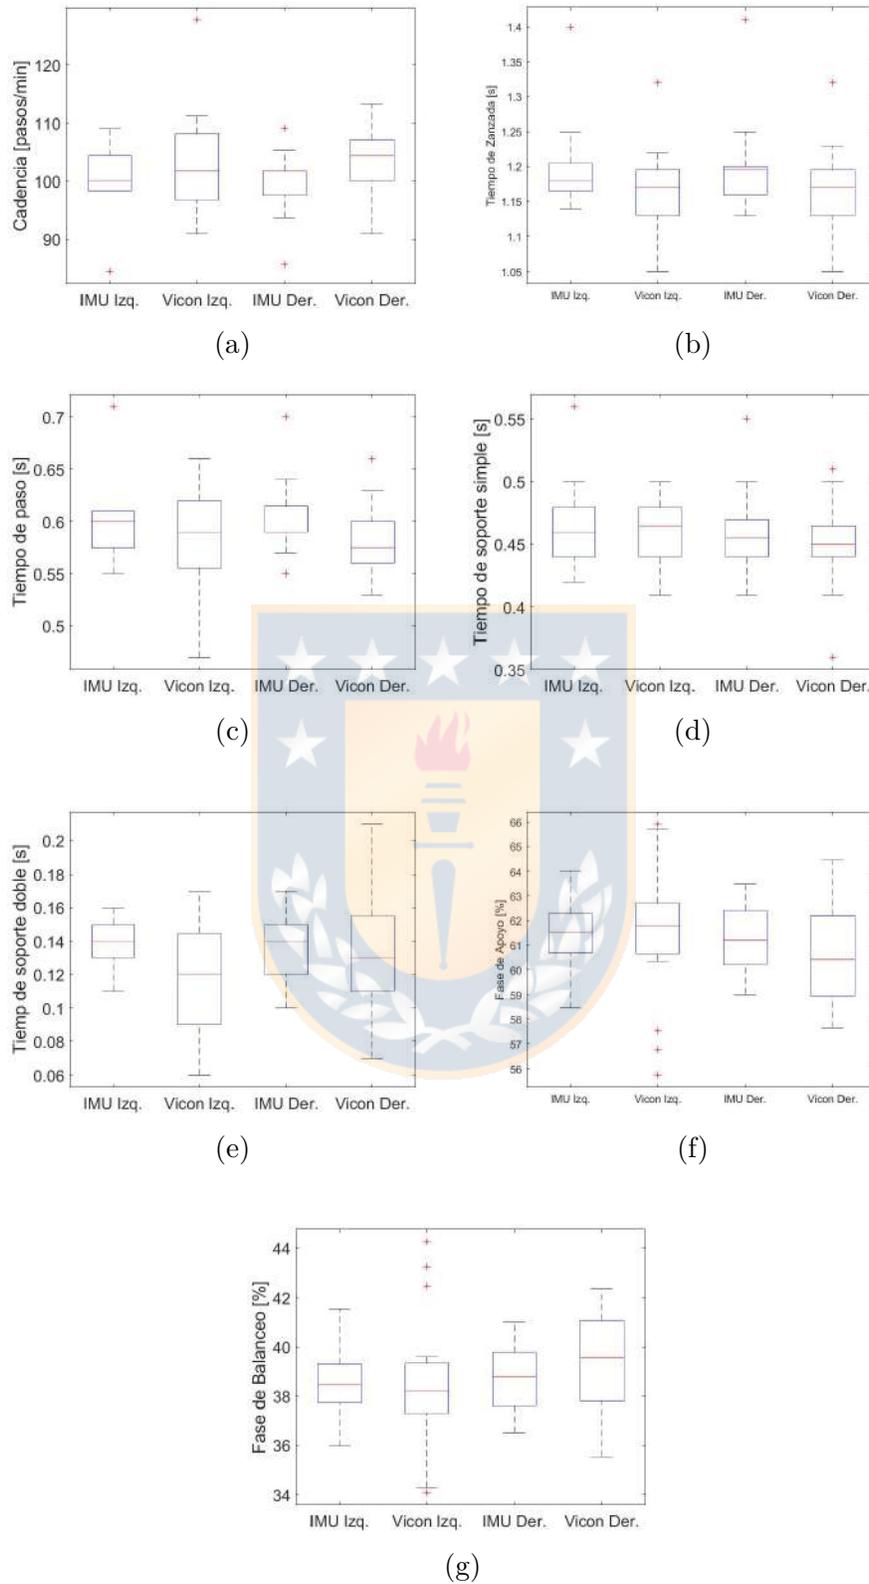


Fig. 5.22: Gráficos de caja para evidenciar la distribución de la estimación de los índices temporales del ciclo de la marcha respecto al método patrón en sujetos sanos. **(a)** Cadencia; **(b)** Tiempo de Zancada; **(c)** Tiempo de Paso; **(d)** Tiempo de Soporte Simple; **(e)** Tiempo de Soporte Doble; **(f)** Duración de la fase de Apoyo; **(g)** Duración de la fase de Balanceo.

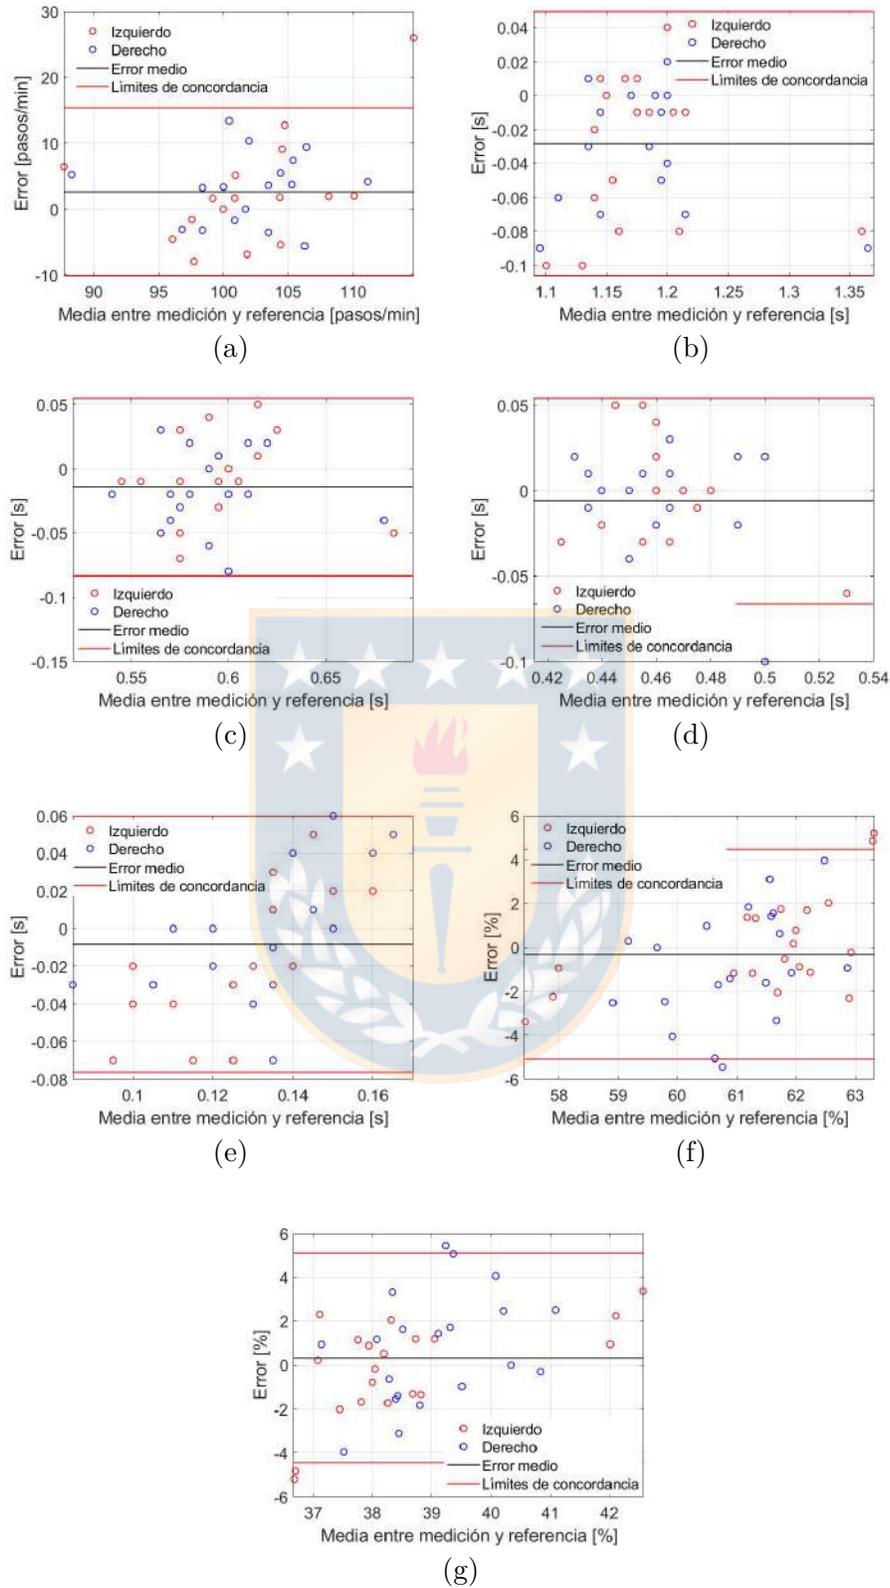


Fig. 5.23: Gráficos de error de la estimación de los índices temporales del ciclo de la marcha respecto al método patrón en sujetos sanos. Las líneas segmentadas corresponden al error medio. (a) Cadencia; (b) Tiempo de Zancada; (c) Tiempo de Paso; (d) Tiempo de Soporte Simple; (e) Tiempo de Soporte Doble; (f) Duración de la fase de Apoyo; (g) Duración de la fase de Balanceo.

5.2.2.4. Validación estimación longitud de paso

Para comparar los resultados de la estimación de la longitud del paso con la proporcionada por el sistema de captura de movimiento, se utilizó un análisis de distribución y error (ver Figura 5.24).

De los resultados se puede observar que el algoritmo usado tiende a subestimar el largo de paso con un error medio de 5 [cm] y un error máximo de 15 [cm], lo que se encuentra dentro de los rangos aceptables reportados por la literatura para este tipo de aplicaciones.

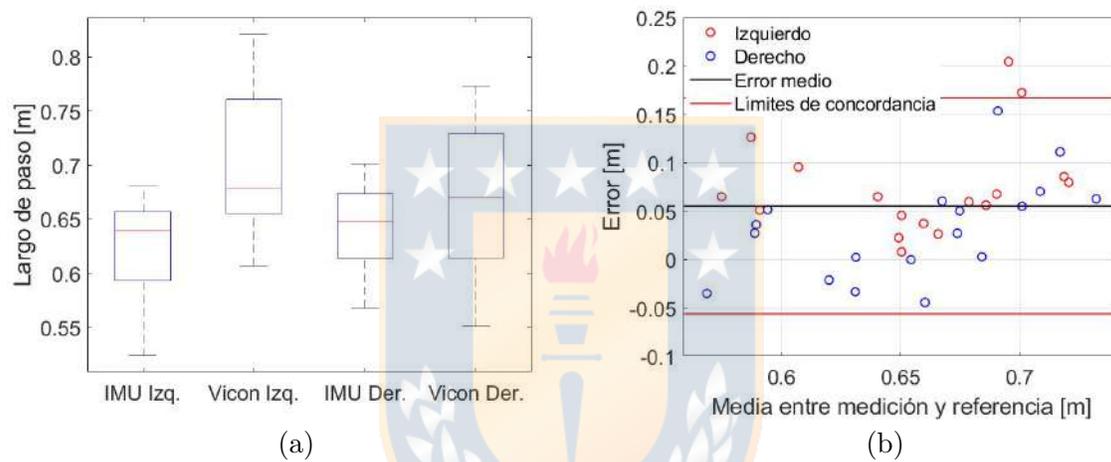


Fig. 5.24: Resultados de las estimaciones del largo de paso con el algoritmo propuesto respecto al método patrón en sujetos sanos. (a) Distribución de las mediciones; (b) Gráfico Bland-Altman para evaluación de error.

6. Distribución de los datos en población objetivo

En este capítulo se presentan los análisis usados para la distribución de las características a partir de las bases de datos escogidas para implementar los modelos de aprendizaje automático para la estimación del riesgo de caída en la población objetivo usando las pruebas propuestas.

Se decidió usar bases de datos, ya que el contexto sanitario impidió la realización de las pruebas en ambiente real.

6.1. Análisis de características en TU&Go

Ante la dificultad en la búsqueda de un conjunto de datos relevantes para la aplicación del algoritmo de segmentación automático propuesto en este trabajo, se decidió usar la información disponible en el repositorio del artículo “Intra-rater, inter-rater and test-retest reliability of an instrumented Timed Up and Go (iTUG) test in patients with Parkinson’s disease” [81], que contiene 224 pruebas de TU&Go a sujetos (66.6 ± 8.1 años) con enfermedad de Parkinson de diversa complejidad, valorados con la clasificación por estadios de Hoehn y Yahr [82]. Estadios avanzados de la enfermedad no fueron incluidos (Hoehn y Yahr > 3.0).

Esta base de datos incluye a sujetos con y sin riesgo de caída caracterizados según el tiempo que se demoraron en realizar la prueba para esta población ($TU\&Go > 11.5$ riesgo de caída). Las pruebas fueron realizadas mientras los voluntarios usaban un IMU en la espalda baja, donde a partir de aceleraciones y velocidades angulares se extrajeron la mayoría de las características propuestas en este trabajo:

- Segmentación:
 - Duración de la transferencia sedente-bípeda (pararse) en segundos.
 - Duración de la marcha de ida en segundos.
 - Duración del giro en la marca de 3 metros en segundos.

- Duración de la marcha de regreso en segundos.
 - Duración del giro antes de sentarse en segundos.
 - Duración de la transferencia bípeda-sedente (sentarse) en segundos.
- Índices de movilidad:
- Inclinación máxima al pararse en grados.
 - Inclinación máxima al sentarse en grados.
 - Velocidad al pararse en grados por segundo.
 - Velocidad al sentarse en grados por segundo.
 - Velocidad en el primer giro (marca de tres metros) en grados por segundo.
 - Velocidad en el segundo giro (antes de sentarse) en grados por segundo.

Datos relacionados a la aceleración, como aceleración máxima al levantarse y sentarse, no fueron posible obtener ya que el repositorio no los reportó.

El histograma de la duración total de la prueba se ilustra en la figura 6.1, en la que se observa que la mayoría de los datos se encuentran concentrados bajo los 10 segundos, con una media de 11.38 ± 3.03 segundos. De los datos a usar se observa una clara tendencia de los datos a inclinarse a sujetos sin riesgo de caída los que corresponden a 181 mediciones contra 83 de los sujetos sin riesgo de caída. En la muestra se puede observar que no existen datos atípicos.

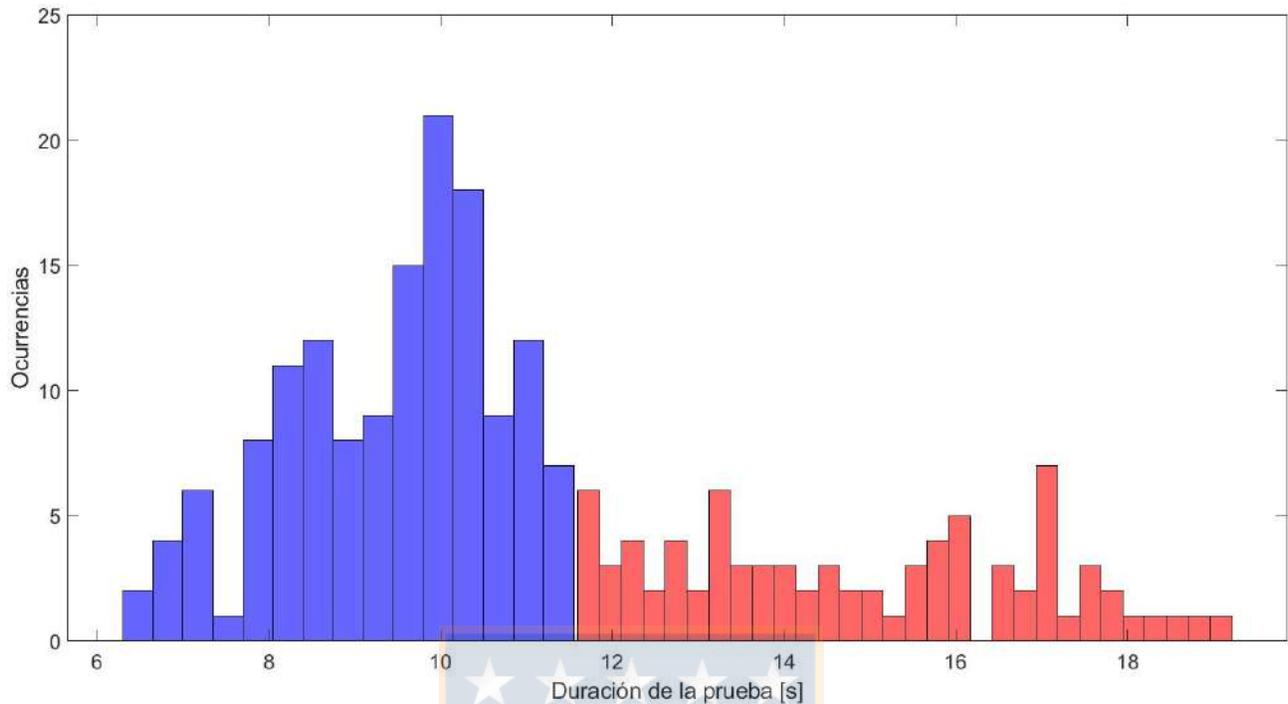


Fig. 6.1: Histograma de los tiempos totales de la prueba instrumentalizada. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

De acuerdo a las características extraídas para la transferencia sedente-bípedo, en la figura 6.2 se observa que los datos tienden a concentrarse alrededor de 1.73 ± 0.63 segundos para la duración de la transferencia, 41.26 ± 11.29 grados para la flexión máxima de tronco y 82.08 ± 26.11 grados por segundo para la velocidad máxima de flexión de tronco. Por otra parte, se puede observar que las características que mejor separación tienen entre sí al considerar sujetos con riesgo de caída versus sujetos sin riesgo de caída son las variables asociadas a la duración y a la velocidad de flexión de tronco.

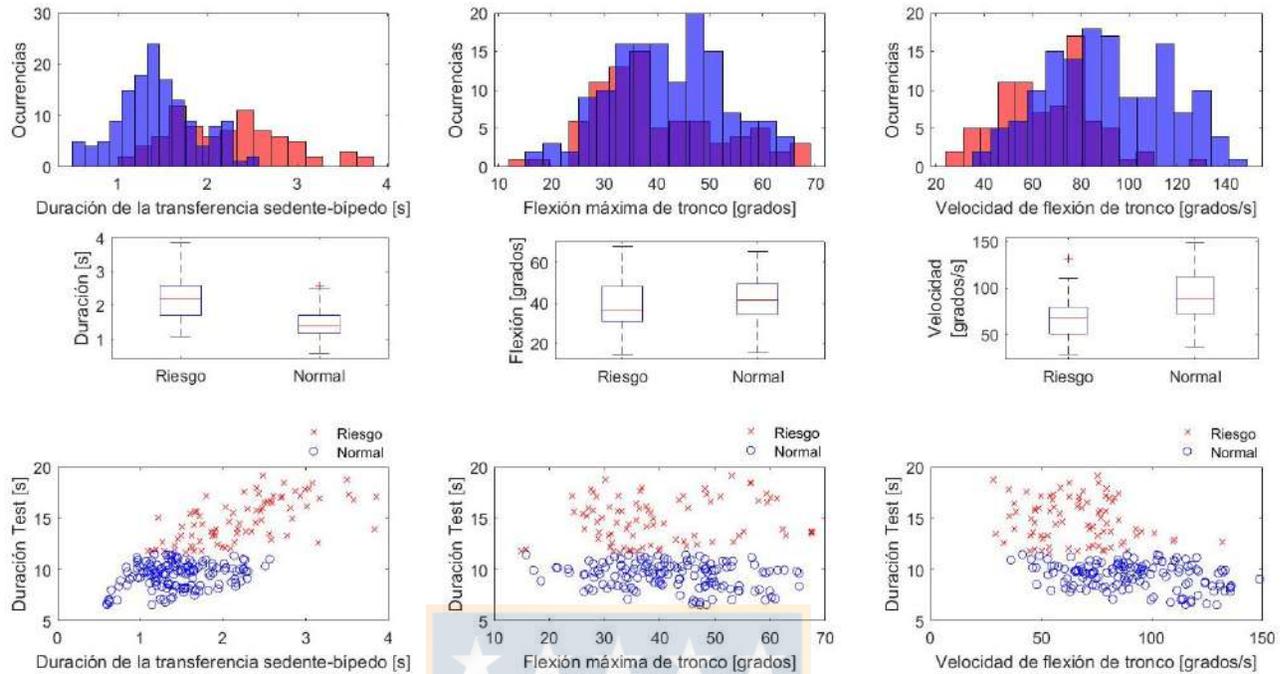


Fig. 6.2: Histograma, gráfico de caja y scatter-plot de las características extraídas de las pruebas de TU&Go en la fase de transferencia sedente-bípida. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

Para la fase de marcha de ida y de regreso se extrajeron solo las características asociadas a la duración. Para extraer características asociadas al ciclo de la marcha es necesario un recorrido representativo, por lo que del TU&Go no extendido no es posible su medición de manera confiable. De la figura 6.3 se observa que los sujetos tienden a demorarse 2.18 ± 0.88 segundos en la marcha de ida y 1.81 ± 0.71 segundos en la marcha de regreso. Además, ambas fases tienen una distribución y separabilidad similar entre sujetos con y sin riesgo de caídas.

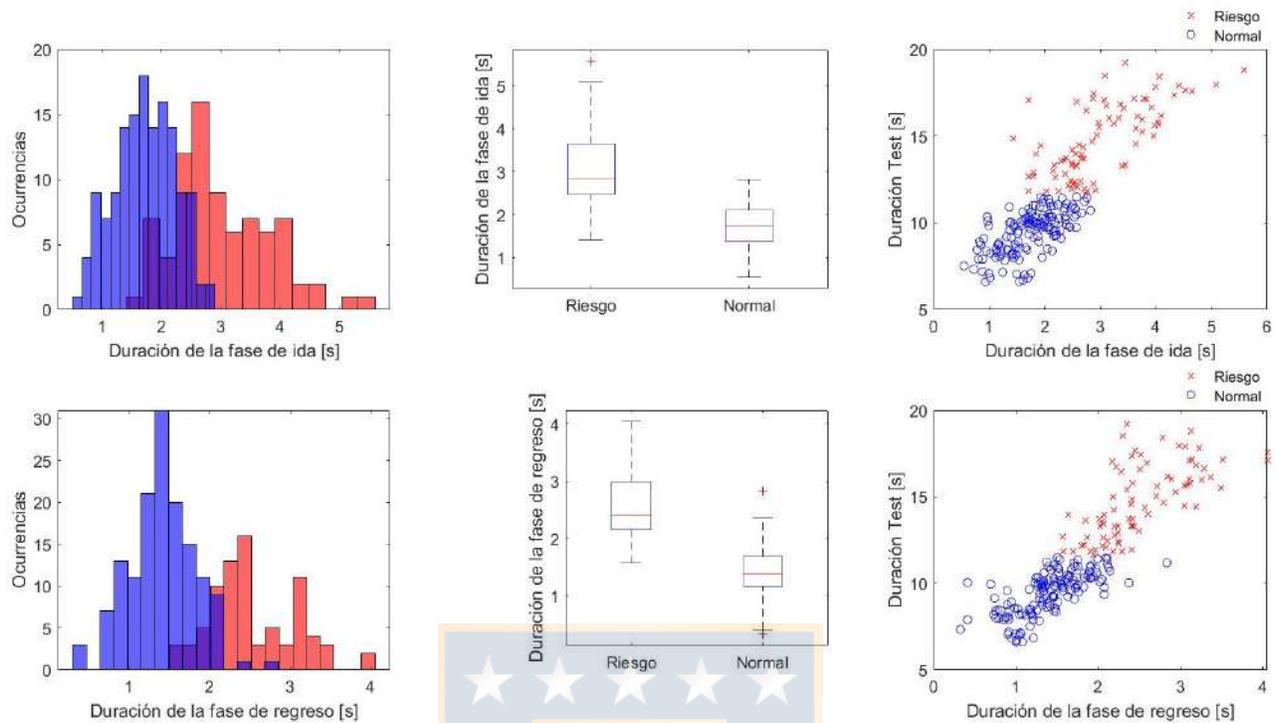


Fig. 6.3: Histograma , gráfico de caja y scatter-plot de la duración en segundos de las fases de ida y de regreso del TU&Go. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

Respecto al primer giro en la marca de tres metros, de la figura 6.4 se observa que los sujetos se demoran en promedio 2.65 ± 0.61 segundos en girar alrededor de la marca de 3 metros con una velocidad máxima de 136.59 ± 42.74 grados por segundo. Además, se observa que si bien los sujetos con riesgo de caídas tienden a demorarse más en realizar esta etapa, no siempre lo hacen a mayor velocidad implicando que los datos se encuentren mayormente mezclados, es decir, presentan una pobre discriminación entre sujetos con y sin riesgo de caídas.

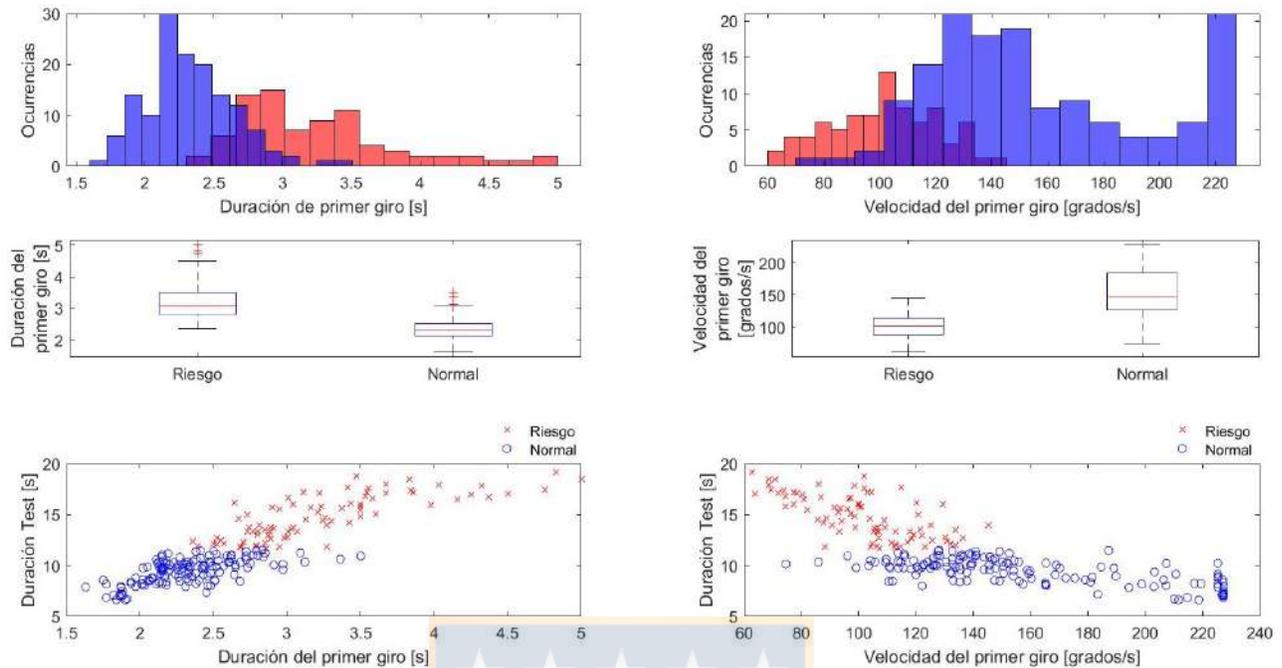


Fig. 6.4: Histograma , gráfico de caja y scatter-plot de la duración en segundos del primer giro y de la velocidad angular máxima alcanzada en esta etapa del TU&Go. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

Para el segundo giro antes de sentarse, de la figura 6.5 se observa que los sujetos se demoran en promedio 2.33 ± 0.52 segundos en girar antes de sentarse con una velocidad máxima de 142.26 ± 41.95 grados por segundo. Al igual que para el primer giro, se observa que los sujetos con riesgo de caídas tienden a demorarse más en realizar esta etapa. Sin embargo, esta etapa presenta una mejor separación de los datos entre sujetos con y sin riesgo de caídas.

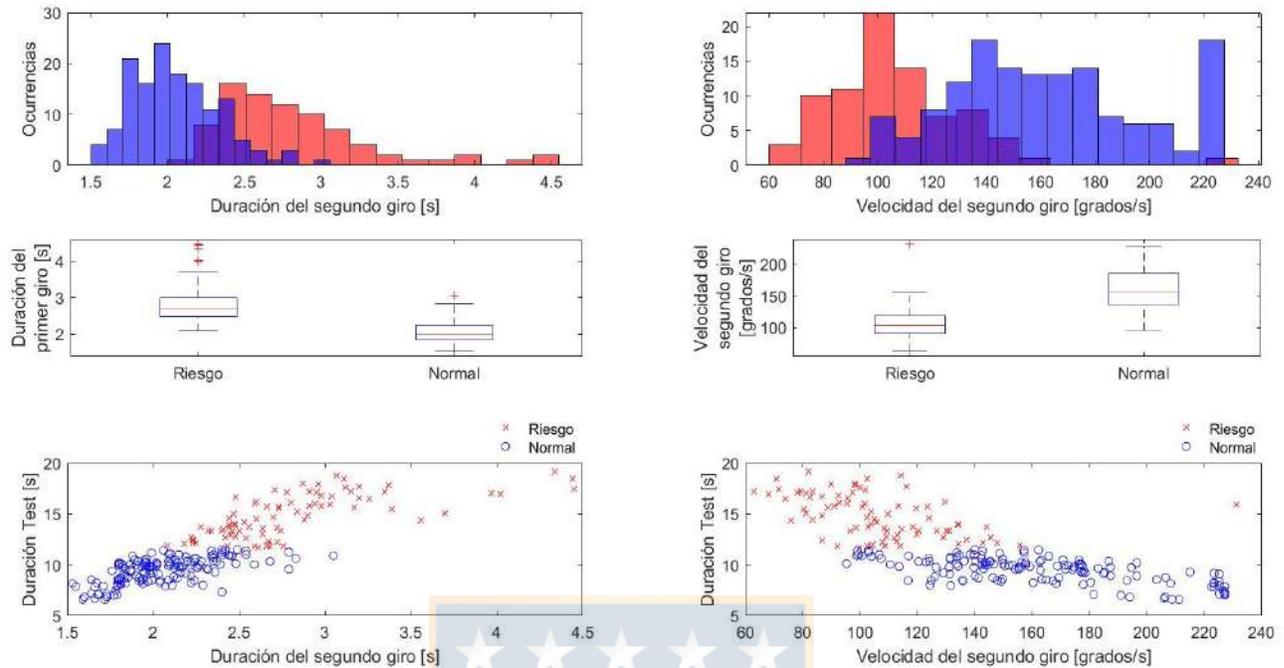


Fig. 6.5: Histograma , gráfico de caja y scatter-plot de la duración en segundos del giro antes de sentarse y de la velocidad angular máxima alcanzada en esta etapa del TU&Go. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

Finalmente, la transferencia bipeda-sedente entregó los resultados observados en la figura 6.6 en la que los datos tienden a concentrarse alrededor de 2.00 ± 0.65 segundos para la duración de la transferencia, 18.89 ± 9.35 grados para la flexión máxima de tronco y 33.28 ± 14.58 grados por segundo para la velocidad máxima de flexión de tronco. Se puede observar que, al igual que para la transferencia sedente-bípedo, las características que mejor separación tienen entre sí al considerar sujetos con riesgo de caída versus sujetos sin riesgo de caída son las variables asociadas a la duración y a la velocidad de flexión de tronco. Sin embargo, también se observa en el histograma de la flexión máxima de tronco y en el de la velocidad de máxima de flexión de tronco un dato atípico que tiene valor negativo, lo que físicamente no es posible, pues indicaría que el sujeto flectó su espalda hacia atrás respecto a la posición inicial, por lo que para los análisis posteriores, se omitirá esta muestra.

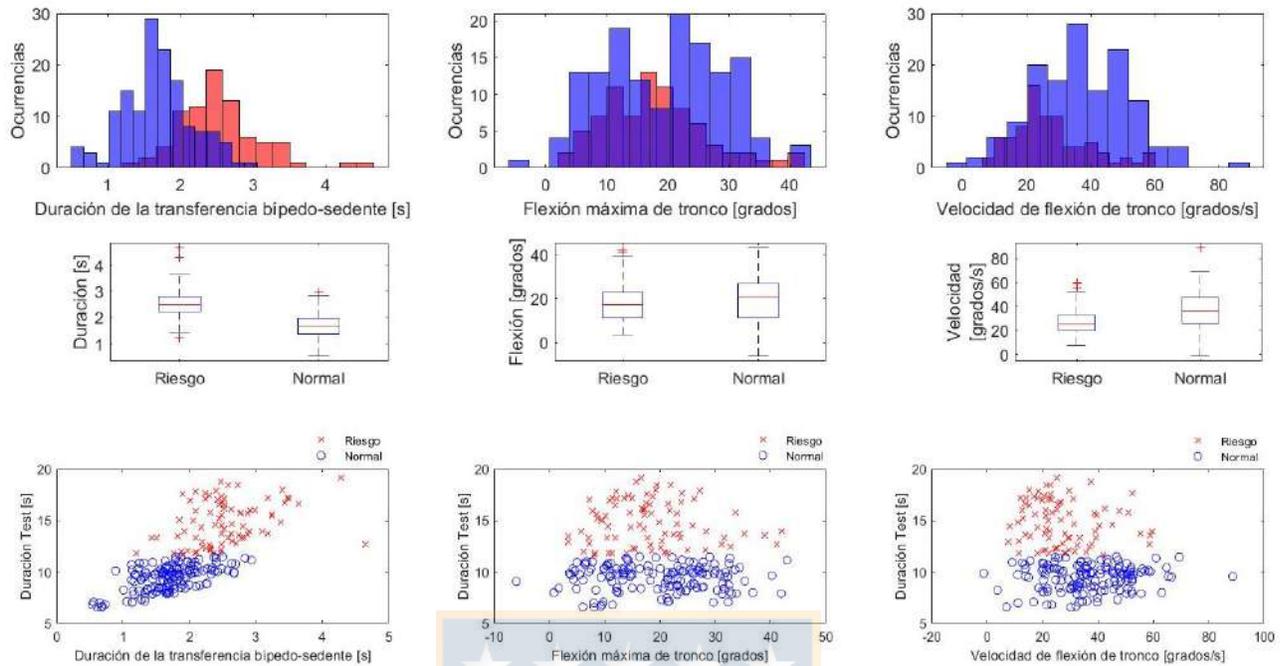


Fig. 6.6: Histograma, gráfico de caja y scatter-plot de las características extraídas de las pruebas de TU&Go en la fase de transferencia bípido-sedente. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

6.2. Análisis de características de la marcha

Para el análisis de los índices del ciclo de la marcha de sujetos con y sin riesgo de caídas en la versión extendida del TU&Go se decidió usar la base de datos disponible en Physionet “Long Term Movement Monitoring Database” [83], que contiene los datos de movilidad de 71 personas mayores (edad media = 78.36 ± 4.71 años; rango de edad de 65 a 87 años) durante sus actividades de la vida diaria. Dentro de este repositorio, existen mediciones de acelerometría de espalda baja usando un cinturón con sensores inerciales (acelerómetro de tres ejes y giroscopio de tres ejes) mientras realizan una marcha en una superficie plana y sin obstáculos durante 1 minuto, separados en un grupo de control y un grupo con riesgo de caída. Dichos grupos fueron clasificados según el historial de caídas de cada voluntario en los últimos 12 meses. De la totalidad de sujetos de prueba, 69 fueron evaluados con el algoritmo para el análisis de marcha descrito en esta investigación. Dos sujetos no presentaban la calidad de datos necesaria para calcular correctamente los índices del ciclo de la marcha por lo que no fueron incorporadas en

este análisis.

Los índices del ciclo de la marcha que se pudieron calcular de esta base de datos utilizando el algoritmos propuesto y validado en esta tesis fueron:

- Índices temporales:

- Tiempo instantáneo y promedio de paso izquierdo y derecho en segundos.
- Tiempo instantáneo y promedio de zancada izquierdo y derecho en segundos.
- Tiempo instantáneo y promedio de soporte simple izquierdo y derecho en segundos.
- Tiempo instantáneo y promedio de soporte doble izquierdo y derecho en segundos.

- Índices espaciales:

- Cadencia instantáneo y promedio izquierda y derecha en pasos por minuto.
- Porcentaje de soporte instantáneo y promedio izquierdo y derecho en porcentaje.
- Procentaje de balanceo instantáneo y promedio izquierdo y derecho en porcentaje.
- Índice de simetría de la marcha.

La velocidad de marcha, velocidad de paso y largo de paso no pudieron ser estimados usando la base de datos al no contener información demográfica relacionada a la altura o longitud de pierna de cada sujeto.

Para cada señal sólo se usaron los primeros 10 segundos de cada medición para evitar las acciones de giro que alteran el ciclo de la marcha al igual que los eventos de inicio (aceleración) y final (desaceleración) de la marcha.

A diferencia de las muestras de TU&Go, la base de datos de marcha contiene una distribución equilibrada entre sujetos con riesgo de caída (31 sujetos) y sin riesgo de caída (38 sujetos). La distribución general de los índices espacio-temporales del ciclo de la marcha se presentan en la figura 6.7, en la que tienden estar distribuidas en torno a 112.24 ± 14.65 [pasos/min] para la cadencia, 1.09 ± 0.11 segundos para tiempo de zancada, 0.54 ± 0.07 segundos para tiempo de paso, 0.42 ± 0.05 segundos para soporte simple, 0.12 ± 0.04 segundos para soporte doble, 61.62 ± 3.81 % para la fase de apoyo, 38.83 ± 3.32 % para la fase de balanceo y 0.92 ± 0.03 para el factor de simetría.

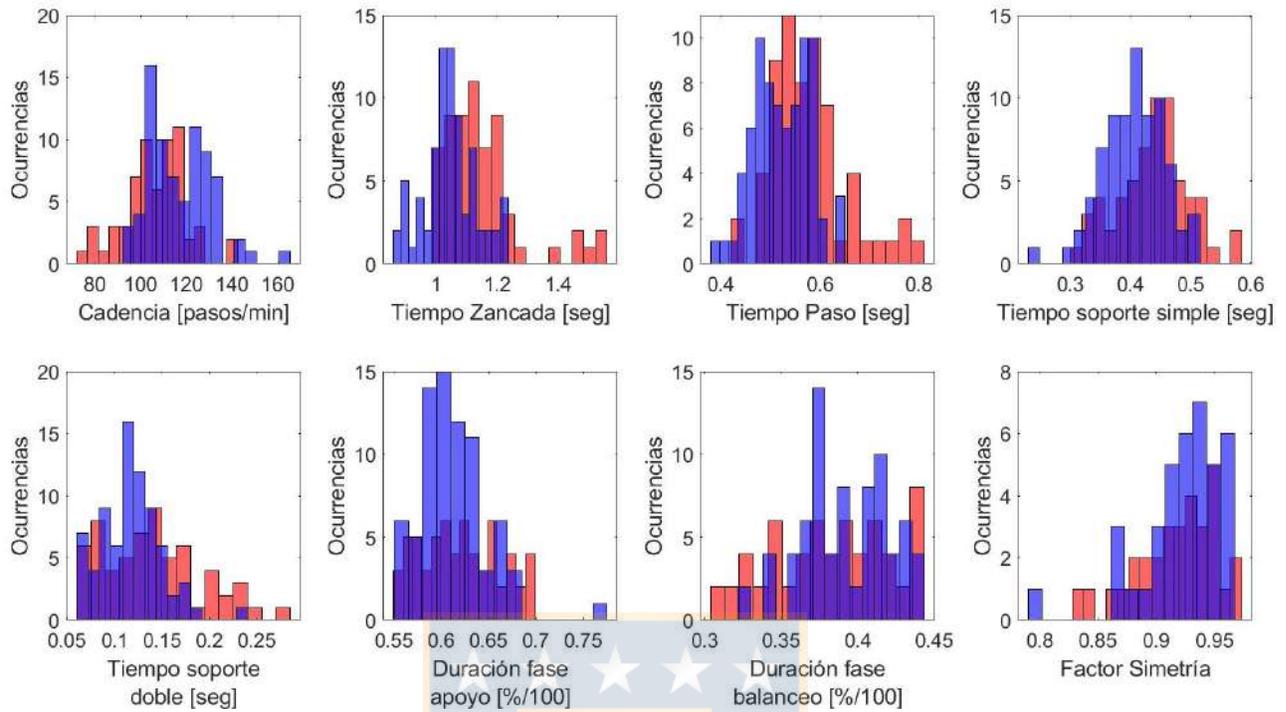


Fig. 6.7: Distribución de los índices estimados del ciclo de la marcha. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

En la figura 6.8 se ilustran los índices estimados por extremidad inferior, observando que no existen diferencias claras entre sujetos con y sin riesgo de caídas al comparar extremidades del mismo lado de manera independiente.

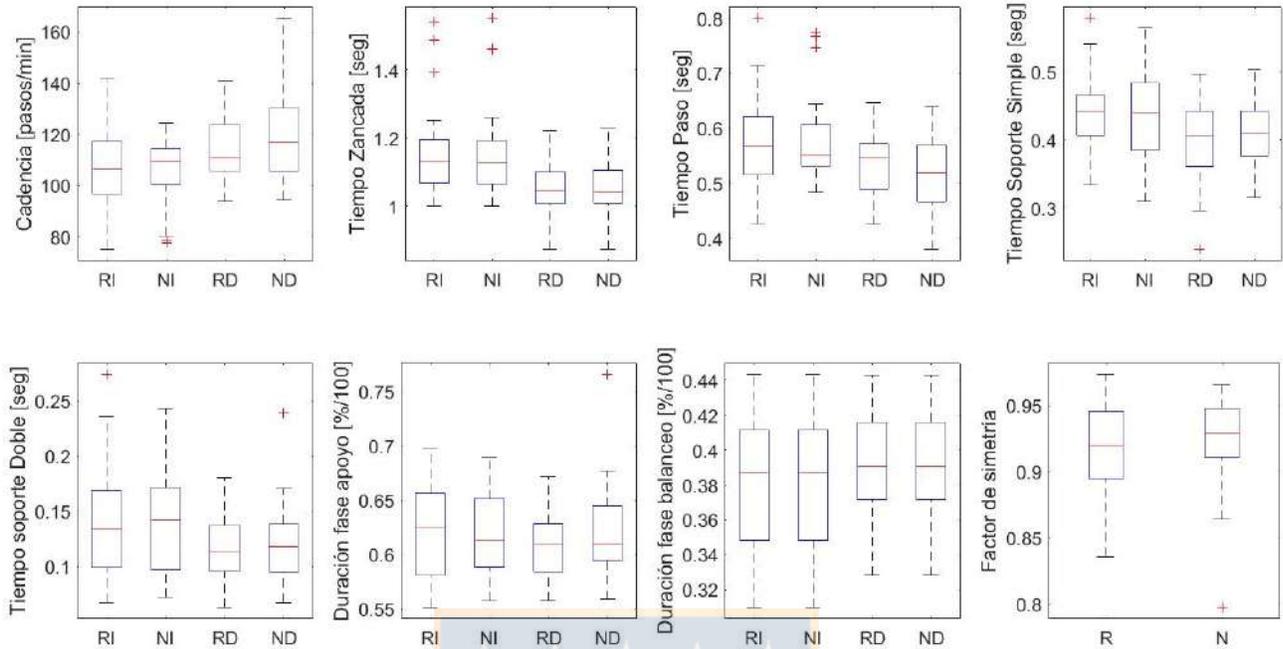


Fig. 6.8: Gráficos de caja de los índices del ciclo de la marcha estimados por extremidad con R = Riesgo, N = Normal, I = Izquierdo, D = Derecho.

Sin embargo, al estimar los índices en conjunto como la media entre el resultante de cada extremidad, se obtienen diferencias mas notorias (ver figuras 6.9 y 6.10). Aunque varios datos se superponen entre sí, esto simplificará el análisis posterior.

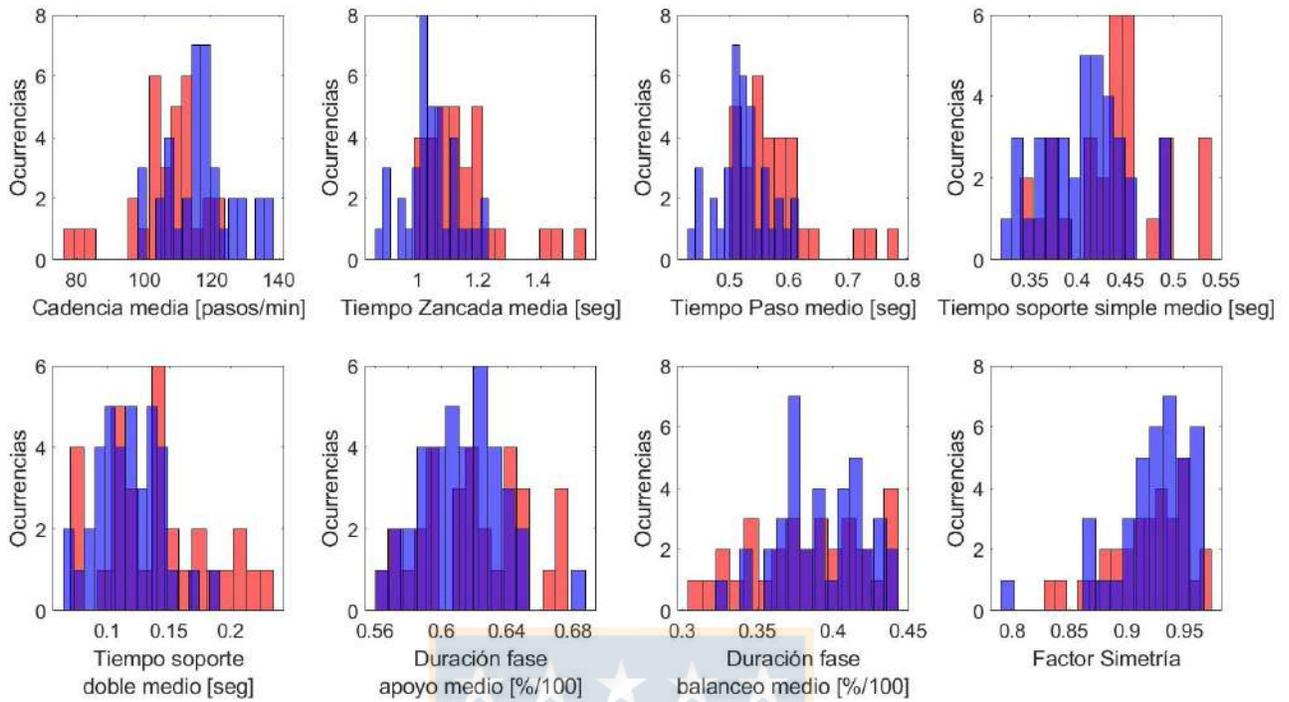


Fig. 6.9: Distribución de los índices estimados del ciclo de la marcha usando el promedio de los índices por extremidad. Las ocurrencias representadas con color rojo corresponden a sujetos con riesgo de caída y las ocurrencias representadas con color azul corresponden a sujetos sin riesgo de caídas.

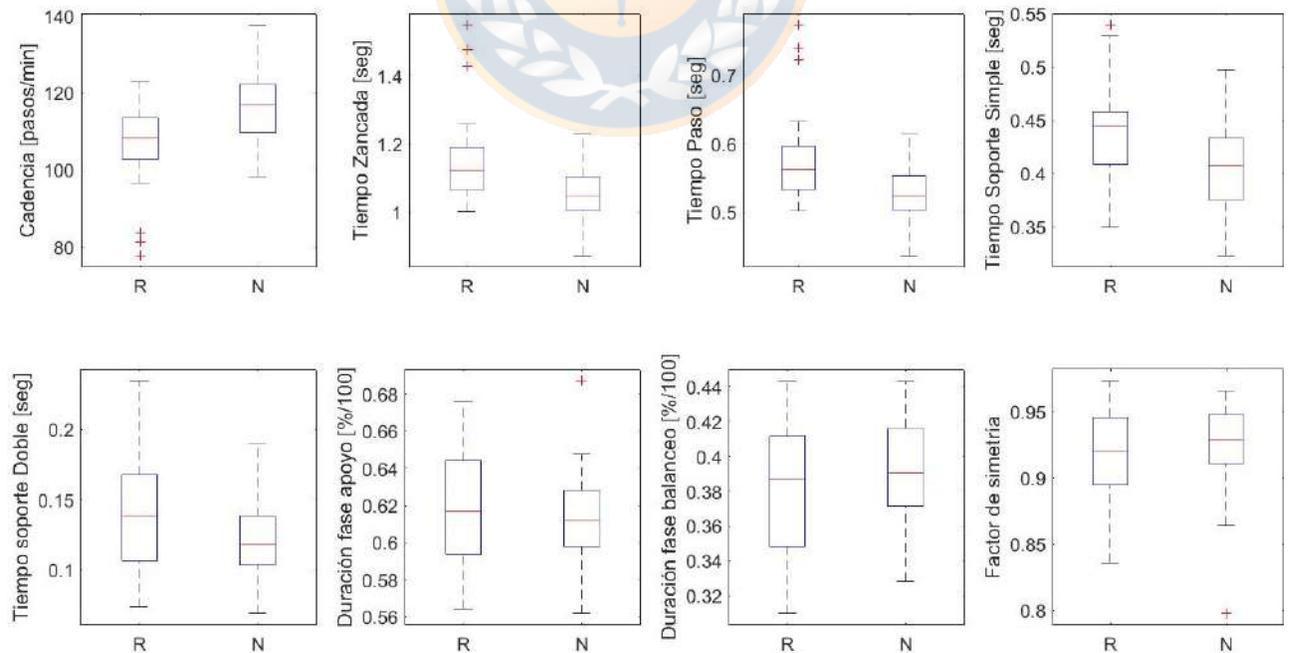


Fig. 6.10: Gráficos de caja de los índices del ciclo de la marcha estimados como la media de cada extremidad con R = Riesgo, N = Normal

7. Selección de modelos y características para estimación específica del riesgo de caída

Al estar usando bases de datos externas, no se pudo conocer a priori de manera específica en que sub-fase del TU&Go los voluntarios tenían mayor riesgo de caída, pero sí el puntaje final del TU&Go (en el caso de la base de datos de Parkinson) o la valoración según el historial de caídas (en el caso de la base de datos de marcha), se asume para el etiquetado:

“El sujeto sin riesgo de caídas no tiene riesgo en ninguna sub-fase del TU&Go.”

Lo anterior permitió establecer las etiquetas de una sub-fase normal y dejar las demás muestras como si tuviera una afección. Entendiendo que no es lo óptimo, ya que al definir el riesgo a partir de la totalidad de la prueba existirá una alta correlación con el riesgo de cada una de las sub-fases del test entregando una alta predominancia a las variables temporales, se permite establecer un precedente del comportamiento de las características extraídas a lo largo de la muestra utilizada.

Las máquinas de aprendizaje automático o clasificadores a evaluar en esta oportunidad corresponden a: [84]

- Clasificador por Regresión Logística (RL): es un modelo estadístico que usa una función logística para establecer la relación entre las variables de entrada (índices de movilidad de e índices espacio-temporales de la marcha) y las variables de salida (riesgo de caída), asumiendo que las entradas como variables independientes y las salidas como variables dependientes (riesgo o normal), asignando una probabilidad de 0 a 1 dependiendo de las entradas o combinación lineal de ellas. La función logística usada en este caso es una curva sigmoidea.
- Clasificador Naïve Bayes con kernel Gaussiano (del inglés *Gaussian Naïve Bayes*, GNB): es un clasificador que, mediante el teorema de Bayes, describe la probabilidad de que un evento ocurra (riesgo o normal) a partir de diferentes condiciones o variables de entrada (índices de movilidad de e índices espacio-temporales de la marcha) que son independientes

entre sí. Si bien las distribuciones obtenidas en el capítulo anterior no eran Gaussianas, en la bibliografía se ha demostrado que las características extraídas si las tienen o son asumidas como tales ([85, 86]).

- Máquina de Soporte Vectorial (del inglés *Support Vector Machine*, SVM): es un clasificador que usa un hiperplano para establecer la separación entre diferentes clases (con y sin riesgo de caída). Este hiperplano es N-dimensional y va a estar determinado por la cantidad de características de entrada (N) y el kernel de separación usado para establecer el hiperplano de clasificación. En este caso, se evaluarán kernels polinómicos, además de un kernel Gaussiano, asumiendo distribución Normal.
- Clasificador por K-vecinos más cercanos (del inglés *K-nearest Neighbors*, KNN): es un modelo de clasificación que se apoya de los vecinos más cercanos para clasificar un punto en el espacio N-dimensional, con N igual a la cantidad de características de entrada. El algoritmo busca los K puntos previamente etiquetados más cercanos y si hay más puntos de una clase que de otra, se establece que el punto a clasificar pertenece a esa clase. El valor de K depende de cada problema y el método usado para el cálculo de la distancia en este caso corresponde a la distancia euclidiana.

En esta investigación se usará una metodología de ensayo y error para cada una de las sub-fases del TU&Go, en el que se irán descartando las características y los modelos a utilizar de manera simultánea para cada sub-fase al evaluar todas las combinaciones posibles de las entradas para cada uno de los modelos mencionados. Esto es válido ya que las características para cada una de las sub-fases de la prueba no tienen más de 3 características.

Todos los modelos serán entrenados y evaluados en Python 3.0 usando la librería scikit-learn.

El comportamiento de todos los modelos serán evaluados mediante la obtención de las siguientes métricas:

- Exactitud: representa la cantidad de sujetos bien clasificados respecto al total de la muestra.
- Precisión: representa la cantidad de sujetos con riesgo de caídas bien clasificados respecto al total de sujetos clasificados con riesgo de caídas.
- Recall: representa la cantidad de sujetos con riesgo de caída bien clasificados respecto a la muestra total de sujetos con riesgo de caída.

- Especificidad: representa la cantidad de sujetos sin riesgo de caídas bien clasificados respecto a la muestra total de sujetos sin riesgo de caídas.
- Media armónica de precisión y recall (F1-Score): representa el rendimiento del modelo para clasificar correctamente a los sujetos con riesgo de caídas. Mientras mayor sea su valor, mayor es la confiabilidad del algoritmo para identificar a sujetos con riesgo de caídas.

7.1. TU&Go de 3-metros

Tras la revisión de las distribuciones de los datos a utilizar (recordar que la base de datos encontrada sólo corresponde a sujetos con enfermedad de Parkinson (EP)) se obtuvieron 222 mediciones válidas, las cuales 141 corresponden a sujetos sin riesgo de caídas y 81 a sujetos con riesgo de caídas, lo que indica un set de datos altamente desbalanceado. Para corregir lo anterior, los modelos fueron entrenados y validados con 110 mediciones, de las que 55 corresponden a sujetos con riesgo de caídas y 55 a datos de sujetos sin riesgo de caídas. El resto será reservado como set de prueba (86 mediciones sin riesgo de caídas y 26 con riesgo de caídas) para evaluar la capacidad de generalización de los modelos.

Los set de entrenamiento y validación para definir cuál máquina de aprendizaje automático tiene el mejor rendimiento, se usaron según el procedimiento descrito en la técnica de validación cruzada, iterando el procedimiento de entrenamiento y validación en 3 grupos distintos, usando uno de los grupos como entrenamiento y los dos restantes como set de validación. Una vez seleccionada la máquina de aprendizaje automático a usar, se usó el mismo set de datos mediante validación cruzada para ajustar los hiperparámetros del modelo.

7.1.1. Fase de transición a sedestación

Los resultados obtenidos tras el entrenamiento y validación se presentan en la figura 7.1.

De la figura 7.1 se observa que la característica que más aporta en el funcionamiento de la mayoría de los modelos es la que corresponde al tiempo o duración de la fase de pararse, mientras que el método de clasificación que mejor funcionó fue el umbral establecido por el método de clasificación por regresión logística con un F1-score = 74.77%. El umbral establecido para definir riesgo en esta sub-fase corresponde a 1.97 segundos.

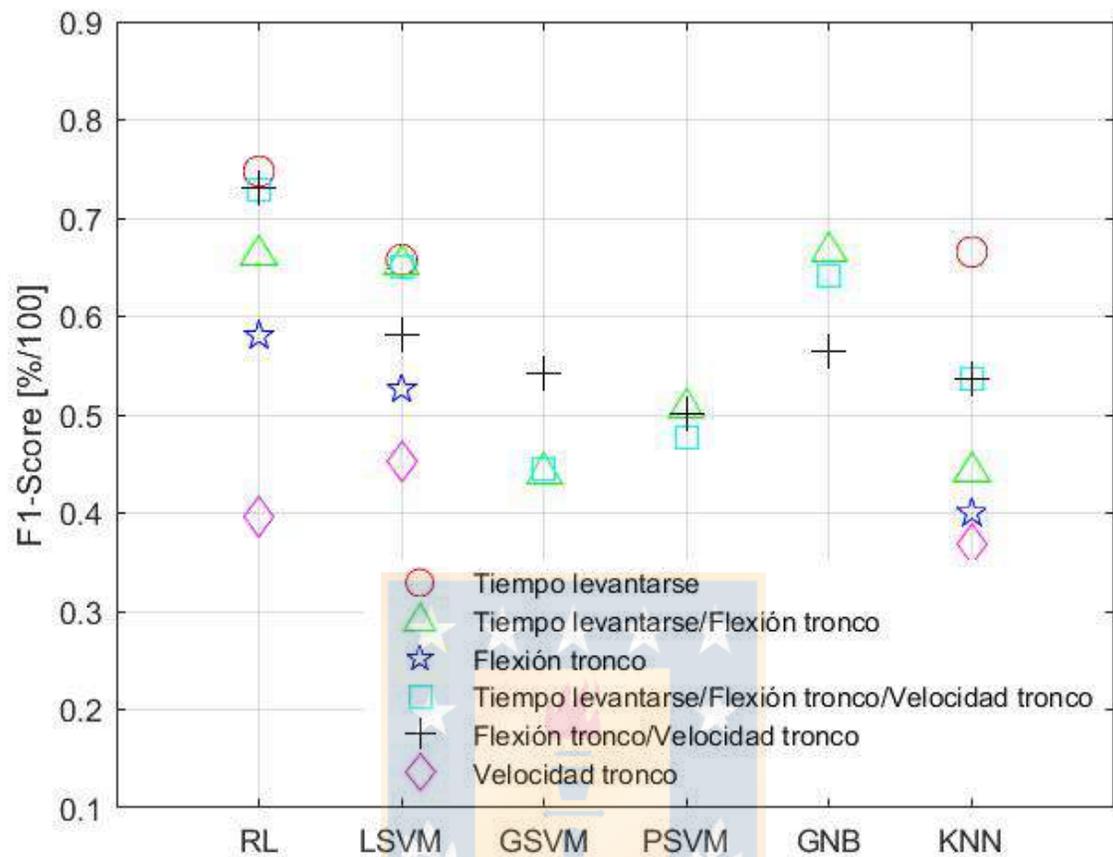


Fig. 7.1: Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa de pararse del TU&Go mediante validación cruzada. Para el caso de KNN $K = 3$.

Por otra parte, usando el set de prueba reservado para evaluar la generalización del método de clasificación, se encontró que el umbral definido es capaz de establecer el riesgo de caída en la sub-fase de pararse con una precisión = 60.52 %, un Recall = 88.46 % y F1-Score = 72.87 %.

7.1.2. Fase de transición bípeda a sedente

Los resultados obtenidos tras el entrenamiento y validación se presentan en la figura 7.2.

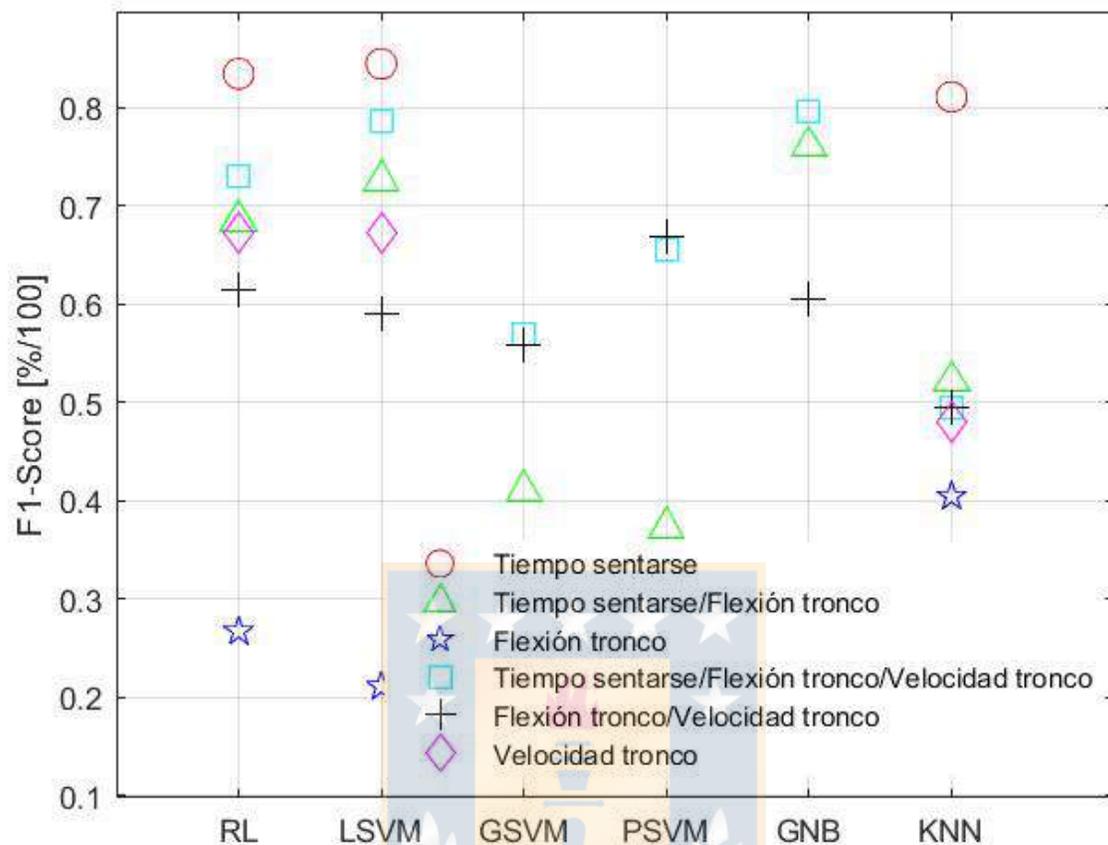


Fig. 7.2: Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa de sentarse del TU&Go mediante validación cruzada. Para el caso de KNN $K = 3$.

De la figura 7.2 se observa que la característica que más aporta en el funcionamiento de la mayoría de los modelos, nuevamente, es la que corresponde al tiempo o duración de la fase de sentarse. El método de clasificación que mejor funcionó fue el umbral establecido por el método de clasificación por regresión logística con un F1-score = 84.5%. El umbral establecido para definir riesgo en esta sub-fase corresponde a 1.66 segundos.

Usando el set de prueba reservado para evaluar la generalización del método de clasificación, se encontró que el umbral definido es capaz de establecer el riesgo de caída en la sub-fase de sentarse con una precisión = 49.01%, un Recall = 96.15% y F1-Score = 64.93%.

7.1.3. Fase de giro de los 3-metros

Los resultados obtenidos tras el entrenamiento y validación se presentan en la figura 7.3.

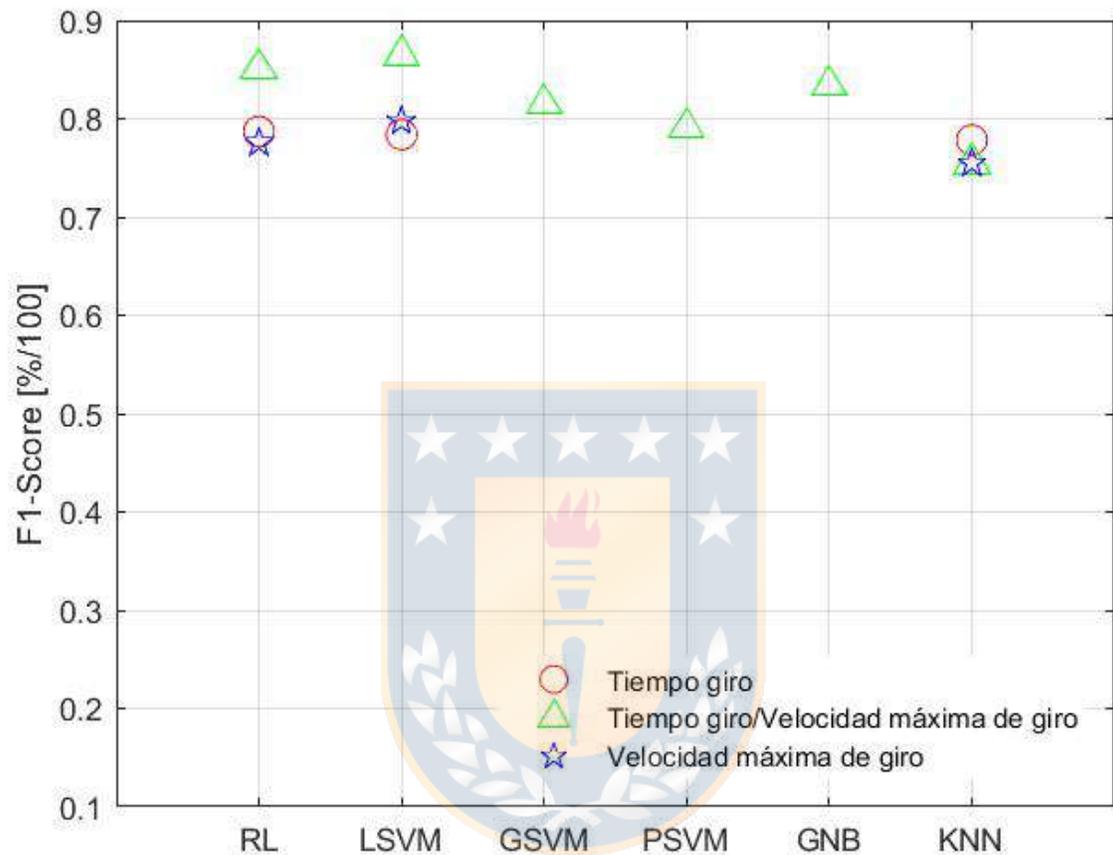


Fig. 7.3: Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa del primer giro del TU&Go mediante validación cruzada. Para el caso de KNN $K = 3$.

De la figura 7.3 se observa que las características que más peso tienen en el funcionamiento de los modelos de clasificación es la variable temporal asociada a la duración de la fase de giro y la velocidad máxima de giro, obteniendo el mejor rendimiento de clasificación usando el modelo SVM con kernel lineal con un F1-score = 86.55 %.

Ajustando la función de costo (C) del clasificador con $C = 2$ usando el paquete scikit-learn de Python se mejoró el rendimiento del clasificador con un F1-score = 87.33 %.

Usando el set de prueba reservado para evaluar la generalización del método de clasificación, se encontró que el clasificador es capaz de establecer el riesgo de caída en la sub-fase del primer giro con una precisión = 60.45 %, un Recall = 100 % y F1-Score = 75.36 %.

7.1.4. Fase de giro antes de sentarse

Los resultados obtenidos tras el entrenamiento y validación se presentan en la figura 7.4.

De la figura 7.4 se observa una diferenciación menos clara respecto al rendimiento entre los clasificadores. Nuevamente, se observa que las características que más peso tienen en el funcionamiento de los modelos de clasificación es la variable temporal asociada a la duración de la fase de giro y la velocidad máxima de giro, obteniendo el mejor rendimiento de clasificación usando el modelo SVM con kernel lineal con un F1-score = 79.49 %, el cual no se mejoró al aumentar la función de costo del clasificador ($C=1$).



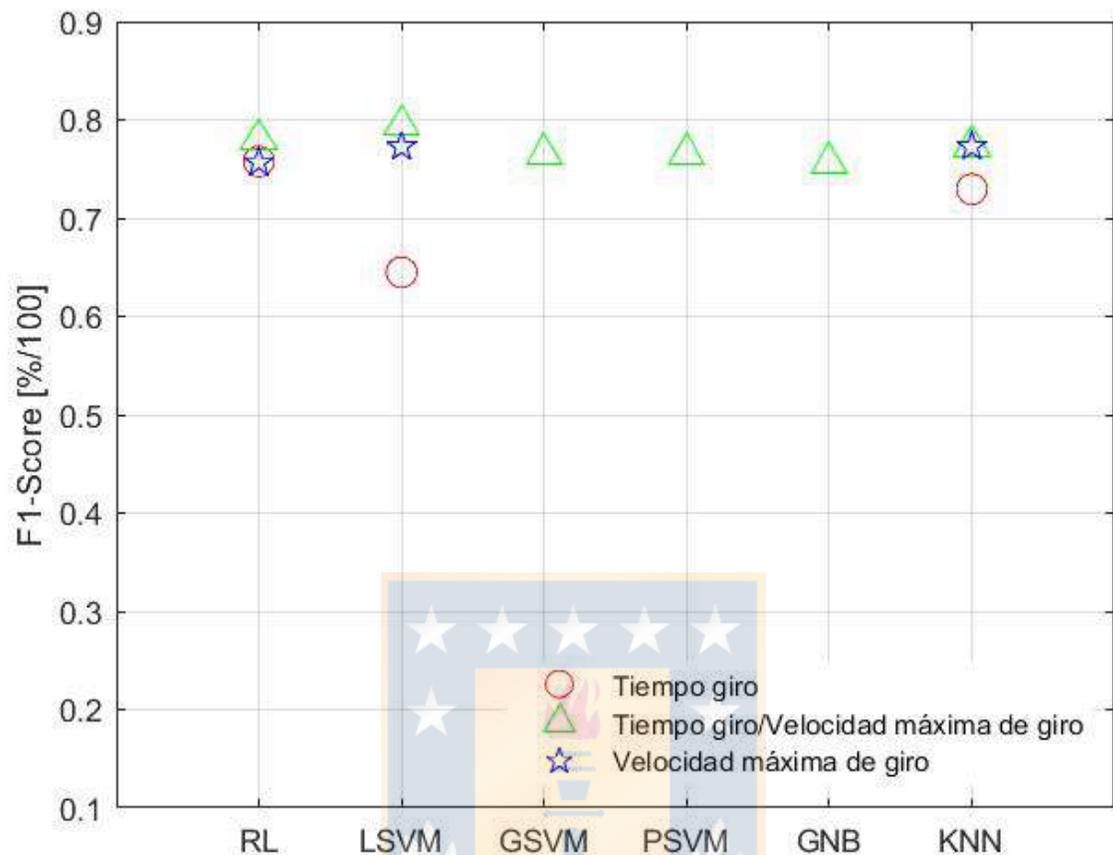


Fig. 7.4: Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos en la etapa del segundo giro del TU&Go mediante validación cruzada. Para el caso de KNN $K = 3$.

Usando el set de prueba reservado para evaluar la generalización del método de clasificación, se encontró que el clasificador es capaz de establecer el riesgo de caída en la sub-fase del segundo giro con una precisión = 77.67%, un Recall = 88.46% y F1-Score = 82.14%.

7.1.5. Fase de marcha

Los resultados obtenidos tras el entrenamiento y validación se presentan en la figura 7.5. Se comenta que, si bien el TU&Go está conformada por dos fases de marcha, se considerará como una sola en el análisis de la actividad a evaluar, ya que corresponden a la misma acción motora.

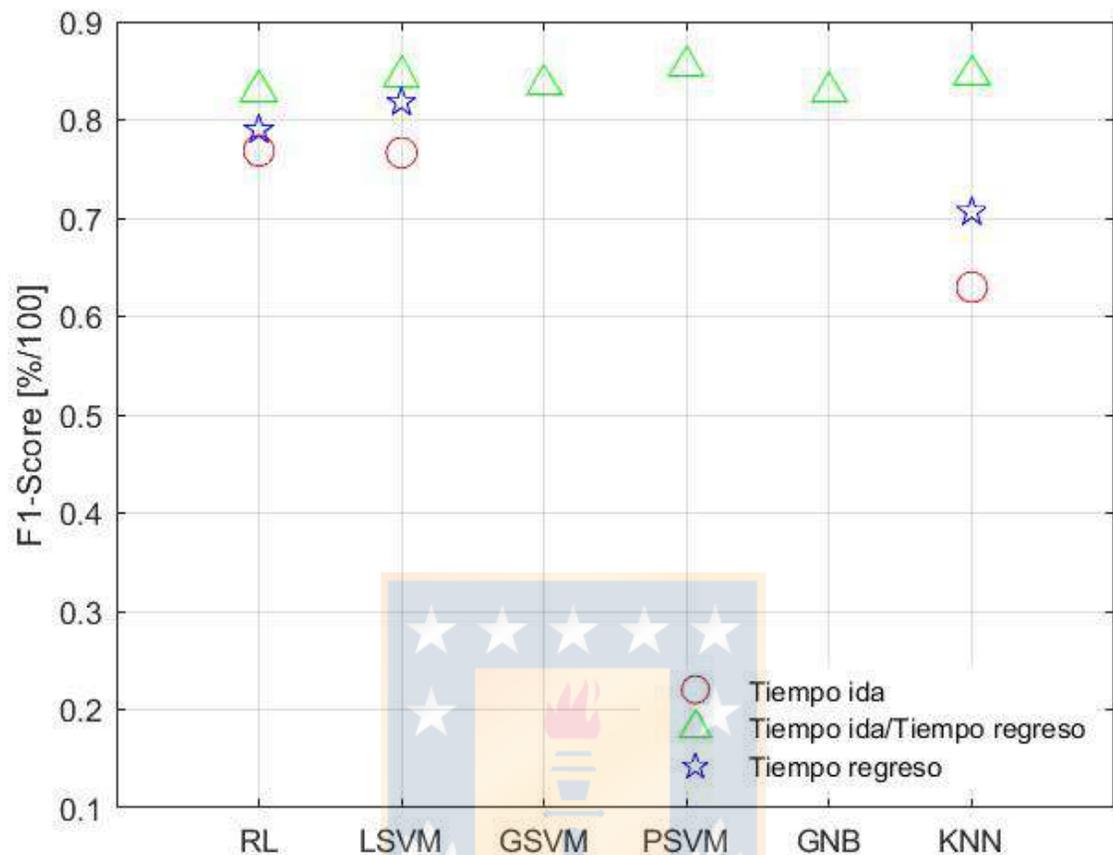


Fig. 7.5: Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos. Para el caso de KNN $K = 3$.

De la figura 7.5 se observa que las características que más peso tienen en el funcionamiento de los modelos de clasificación son las variables temporales asociadas a la ida y regreso de ambas fases de la marcha, obteniendo el mejor rendimiento usando el modelo SVM con kernel polinomial, con un F1-score = 85.45 %, el cual no se mejoró al aumentar la función de costo del clasificador ($C=1$) ni el grado del polinomio ($d = 2$) usando scikit-learn de Python.

Usando el set de prueba reservado para evaluar la generalización del método de clasificación, se encontró que el clasificador es capaz de establecer el riesgo de caída en la sub-fase de la marcha del TU&Go con una precisión = 78.78 %, un Recall = 100 % y F1-Score = 88.13 %.

7.2. TU&Go extendido

Como para el caso del TU&Go de 3-metros no es posible evaluar elementos relacionados a la marcha mas allá de variables temporales (duración de las fases), el uso de una versión extendida de la prueba clínica permite extraer características asociadas al ciclo de la marcha al ser realizada en una mayor distancia (6 a 10 metros), en una superficie plana sin obstáculos y en línea recta.

Tras la revisión de las distribuciones de los datos de AM del repositorio a utilizar se obtuvieron 69 mediciones válidas, las cuales 31 corresponden a sujetos sin riesgo de caídas y 38 a sujetos con riesgo de caídas.

Al igual que para cada una de las sub-fases del TU&Go, los set de entrenamiento y validación para definir cuál máquina de aprendizaje automático tiene el mejor rendimiento, los que corresponden a 40 muestras (20 con riesgo de caída y 20 sin riesgo de caída) son utilizados según el procedimiento descrito en la técnica de validación cruzada, iterando el procedimiento de entrenamiento y validación en 3 grupos distintos, usando uno de los grupos como entrenamiento y los dos restantes como set de validación. Una vez seleccionada la máquina de aprendizaje automático a usar, se usó el mismo set de datos mediante validación cruzada para ajustar los hiperparámetros del modelo.

El resto de los datos serán reservados como set de prueba para evaluar la generalización del clasificador entrenado (11 mediciones sin riesgo de caídas y 18 con riesgo de caídas).

7.2.1. Fase de marcha

Recordando que a partir del set de datos usado, sólo fué posible extraer 8 índices espacio-temporales del ciclo de la marcha, lo que corresponden a 36 posibles combinaciones de variables de entrada para cada uno de los clasificadores propuestos. Sin embargo, para disminuir la dimensionalidad del problema de clasificación, se realizó una serie de evaluaciones y análisis de cada una de las características para verificar la calidad de la información. Los análisis realizados fueron la ganancia de la información, la verificación de ganancia y la evaluación de significancia o separabilidad del conjunto de características mediante el valor F. Los resultados se ilustran en la figura 7.6.

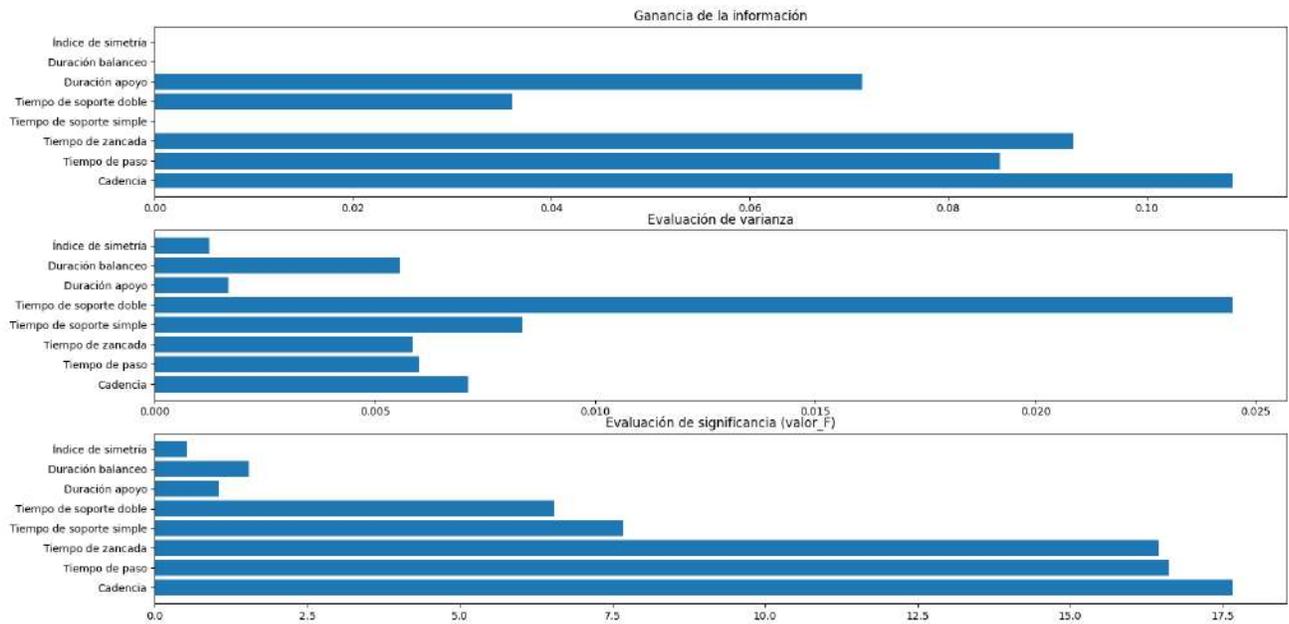


Fig. 7.6: Resultados obtenidos al evaluar el aporte de las características respecto a las clases a clasificar.

De la figura 7.6, se observa que las características que aportan mayor información y que tienen mayor mayor separabilidad respecto a las otras son la cadencia, tiempo de paso y tiempo de zancada. Del análisis de varianza se observa una mínima diferenciación de las características, siendo la que mayor dispersión posee el tiempo de soporte doble.

Con este análisis se puede repetir el procedimiento de la sección anterior evaluando los modelos con sólo 3 características (cadencia, tiempo de paso y tiempo de zancada), probando sólo 6 posibles combinaciones en lugar de 36.

Los resultados obtenidos tras el entrenamiento y validación se presentan en la figura 7.7.

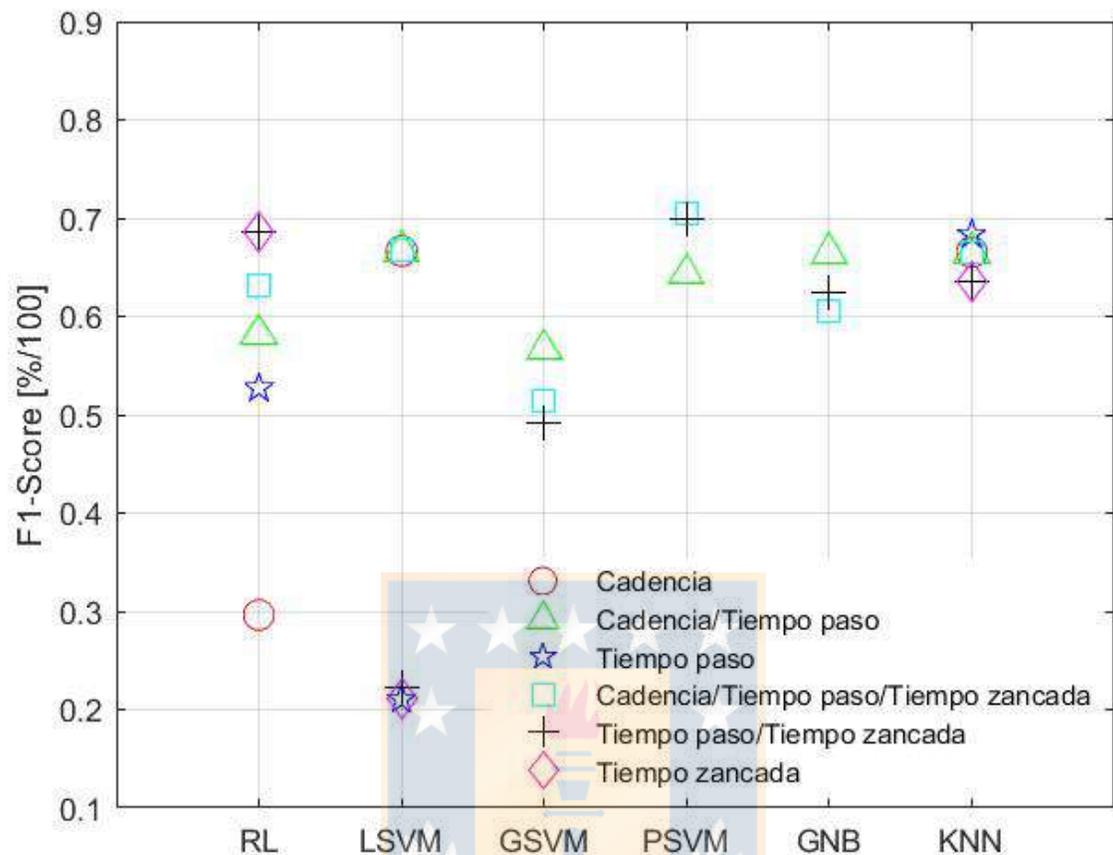


Fig. 7.7: Resultados obtenidos al entrenar cada uno de los modelos con el mismo set de datos del ciclo de la marcha. Los resultados fueron calculados usando el set de prueba. Para el caso de KNN $K = 3$.

A partir de los resultados obtenidos, se observa que tanto la cadencia, el tiempo de paso y el tiempo de zancada aportan el mejor rendimiento de clasificación en conjunto a un SVM con kernel polinomial (F1-score = 70.51 %).

Ajustando la función de costo (C) del clasificador con $C = 2$ y el polinomio $d = 3$ usando el paquete scikit-learn de Python se mejoró el rendimiento del clasificador con un F1-score = 72.1 %.

Usando el set de prueba reservado para evaluar la generalización del método de clasificación, se encontró que el clasificador es capaz de establecer el riesgo de caída en la sub-fase de marcha con una precisión = 59 %, un Recall = 91 % y F1-Score = 71 %.

7.3. Discusión

Con los resultados obtenidos, es posible proponer el algoritmo que se ilustra en la figura 7.8.

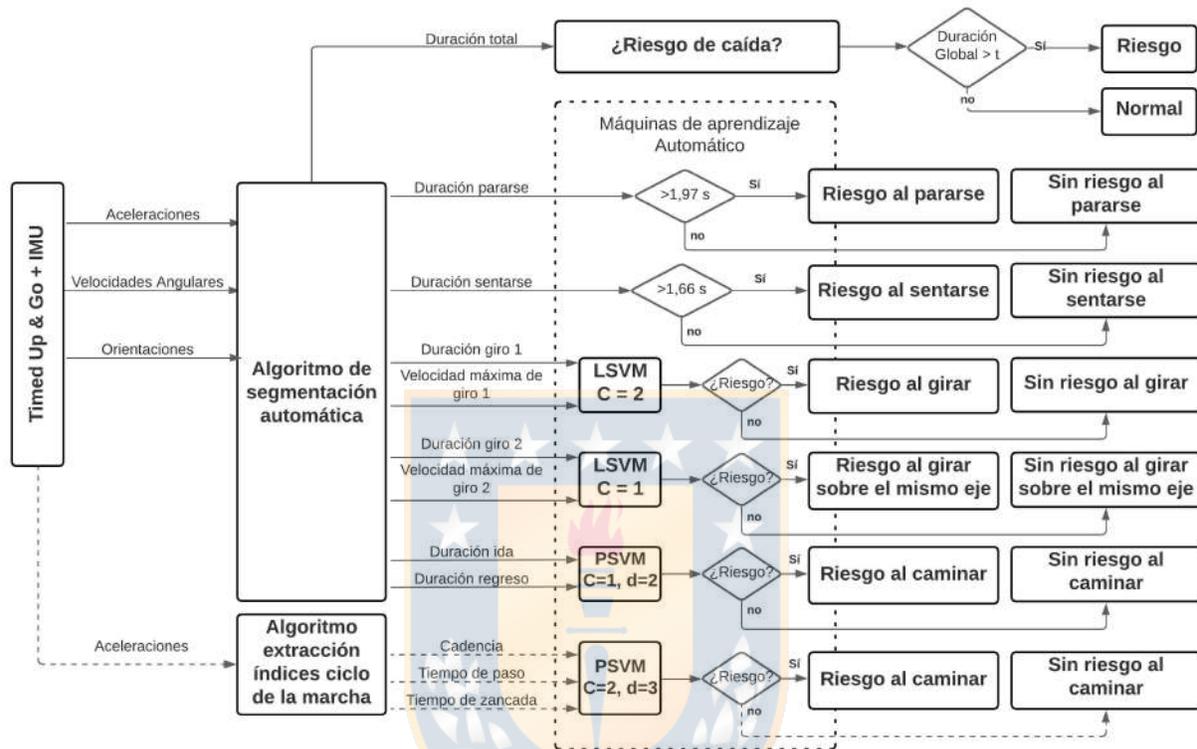


Fig. 7.8: Algoritmo final propuesto para el análisis específico del riesgo de caídas en población objetivo. Flechas segmentadas indican características obtenidas sólo en la versión extendida del TU&Go.

Si bien en esta investigación no se contaba con las etiquetas específicas sobre el estado de cada una de las actividades motoras realizadas durante la ejecución de la prueba al utilizar bases de datos externas a esta investigación debido al contexto sanitario, si se pudo establecer las etiquetas asociadas al estado de un sujeto que no tiene riesgo de caídas en ninguna de las sub-fases de la prueba clínica, permitiendo entrenar y validar a modo conceptual clasificadores comúnmente usados en el campo del aprendizaje automático.

El desempeño de los clasificadores que mejor F1-score obtuvieron para cada una de las actividades realizadas durante el TU&Go usando los set de prueba (no usados para la selección del modelo ni para el ajuste de hiperparámetros del clasificador), se ilustran en la tabla 7.1.

Tabla 7.1: Desempeño de los modelos o clasificadores propuestos para la identificación del riesgo de caídas en cada una de las sub-fases del TU&Go.

TU&Go	Fase	Variable	Clasificador	% Exactitud	% Precisión	% Recall	% Especificidad	% F1-Score
3-metros/Extendido	Pararse	Tiempo para pararse [s].	Umbral >1.97 segundos.	83.92	60.52	88.46	82.55	71.87
3-metros/Extendido	Sentarse	Tiempo para sentarse [s]	Umbral >1.66 segundos.	75.89	49.01	96.15	69.76	64.93
3-metros/Extendido	Giro 3-metros	Tiempo de giro [s] y Velocidad de giro [grados/s]	SVM con kernel lineal, C = 2.	85.21	60.46	100	80.89	75.36
3-metros/Extendido	Giro antes de sentarse	Tiempo de giro [s] y Velocidad de giro [grados/s]	SVM con kernel lineal, C = 1.	91.07	76.66	88.46	91.86	82.14
3-metros	Marcha	Tiempo ida [s] y Tiempo regreso [s]	SVM con kernel polinómico de segundo grado y C = 1.	93.75	78.78	100	91.86	88.13
Extendido	Marcha	Cadencia [paso/min], Tiempo de paso medio [s] y Tiempo de zancada medio [s]	SVM con kernel polinómico de segundo grado y C = 2.	72.41	58.82	90.90	61.11	71.42

Además del F1-score obtenido de cada uno de los clasificadores, se puso principal atención en la variable Recall, ya que en este tipo de aplicaciones, es mucho más importante identificar a los sujetos con riesgo de caídas que a los sujetos sanos. De la tabla 7.1 se observa que el desempeño de los clasificadores es regular a bueno en la detección de sujetos con riesgo de caídas. Sin embargo, existe una clara disminución en el rendimiento de los clasificadores propuestos en la identificación de los sujetos sin riesgo, cuya precisión va desde un 49% en la fase de sentarse, a un 78.78% en la fase de marcha no extendida, siendo este último el mejor. Esto se debe a la clara superposición que existe entre las variables usadas debido, a su vez, de un etiquetado basado sólo en el historial de los pacientes de la base de datos y no basados en pruebas clínicas.

Por otro lado, respecto a las variables usadas en las sub-fases del TU&Go no extendido, se observa una clara predominancia de las variables temporales. Esto se debe a que el sistema de etiquetado de riesgo o sin riesgo en la base de datos usada sólo estaba basada en la totalidad

de la prueba, por lo que resulta evidente que mientras más se demore en una actividad de la prueba clínica, más riesgo existe en esa sub-fase.



8. Conclusiones

Este trabajo de tesis buscó resolver la pregunta de investigación relacionada a la sensorización del TU&Go usando una sólo IMU ubicada en la espalda para la evaluación específica y objetiva del riesgo de caídas en población objetivo.

Debido al contexto sanitario que afecta al país, sólo se pudieron evaluar sujetos jóvenes y AM sanos para establecer el set de datos de normalidad. Además, ante la imposibilidad de medir a sujetos por ser población de riesgo, se utilizaron bases de datos que contaban con sujetos con y sin riesgo de dos poblaciones: AM para validar el análisis de marcha como herramienta para identificar el riesgo de caídas según variables espacio-temporales de la marcha en el TU&Go extendido y a sujetos con enfermedad de Parkinson para establecer los lineamientos iniciales para la evaluación automática y específica del riesgo de caídas a partir de la sensorización del TU&Go.

Se estudiaron metodologías para la identificación de las actividades del TU&Go pudiendo proponer un algoritmo de segmentación automático que permite extraer variables temporales (duración de cada sub-fase de la prueba) como la transferencia sedente a bípeda con un error medio de -0.02 [s], la transición entre el final de la marcha de ida y el comienzo del primer giro con un error medio de 0.36 [s], la transición entre el final del primer giro y la marcha de regreso con un error medio de 0.11 [s], la transición entre el final de la marcha de regreso y el comienzo del giro previo a sentarse con un error medio de 0.25 [s], la actividad del giro previo a sentarse con un error medio de 0.16 [s] y la actividad de sentarse con un error medio de 0.18 [s], constituyendo una estrategia válida de segmentación respecto a la observación visual de expertos en el tratamiento de riesgo de caídas en adultos mayores.

Por otro lado, el tiempo total de la prueba que corresponde al predictor diagnóstico del riesgo de caídas es estimado de manera automática con una correlación lineal respecto a la practica clínica convencional de un 98.78% , un error medio de 0.20 ± 0.22 [s] y una capacidad predictiva respecto al riesgo de caída general (predictor global) en adultos mayores de un 92% . Así, se validó que el algoritmo implementado es capaz de identificar las sub-fases de la prueba clínica en sujetos sanos jóvenes y adultos mayores sanos con al menos el mismo desempeño que la examinación visual, pudiendo no sólo determinar de manera automática si el usuario o paciente tiene riesgo de caída, sino que de extraer características temporales y de movilidad útiles para

la caracterización del movimiento y para la generación de estrategias de rehabilitación.

Respecto al algoritmo para el análisis de marcha, los mejores resultados obtenidos fueron las estimaciones del tiempo de soporte simple con un error de $\pm 0,05$ [s] y el tiempo de soporte doble con un error de $\pm 0,07$ [s]. Los peores resultados obtenidos corresponden a las estimaciones de cadencia, con errores de ± 10 [pasos/min] y el largo de paso con un error entre los 0.05 [m] y 0.15 [m]. A pesar de que estos resultados corresponden a sujetos jóvenes sanos, se destaca que el algoritmo utilizado entrega mediciones con poca diferencia respecto al laboratorio de análisis de movimiento usando un sólo IMU ubicado en la espalda baja, considerado el instrumento patrón para este tipo de aplicaciones, ofreciendo una herramienta útil para la medición de la marcha en ambiente controlado y comunitario en sujetos sanos con un desempeño similar a los laboratorios optoelectrónicos para el análisis de movimiento.

Usando herramientas para el análisis automático de datos se pudo proponer un algoritmos cuyo comportamiento para la clasificación de sujetos con riesgo y en qué sub-fase del TU&Go tiene mayor riesgo va de bien a excelente, con un “Recall” (sujetos con riesgo de caídas respecto al total de sujetos con riesgo) de un 88.46 % en las fases de pararse y del primer giro, hasta un 100 % en las fases del primer giro y en la marcha del TU&Go no extendido. Si bien, el algoritmo tiene precisiones (sujetos sin riesgo de caídas correctamente clasificados) que van de un 49 % en la fase de sentarse, a un 78.78 % en la fase de marcha no extendida, esto se debe a que en el límite clasificación que corresponde a un umbral temporal fijo (10 segundos para adultos mayores y 11.5 segundos para sujetos con EP) en donde sujetos sanos tienden a estar muy cerca de ese límite, pudiendo llegar a tener características similares a sujetos que superen ese umbral, pero que se podría mejorar usando técnicas de normalización de los datos u otras estrategias para el pre-procesamiento de los datos, mejorando el rendimiento de los algoritmos propuestos. Aún así, el algoritmo permite identificar automáticamente mediante el uso de un sólo sensor inercial, en que sub-fase del TU&Go el paciente o sujeto tiene mayor riesgo de caer, entendiendo que no se pudieron evaluar todas las características que a partir del algoritmo de segmentación implementado era posible extraer, como aquellas relacionadas a la aceleración de los movimientos y a parámetros demográficos de los sujetos de prueba, que no estaban disponibles en las bases de datos utilizadas.

Aunque no se pudo evaluar el desempeño de esta herramienta en población chilena con accidente cerebro-vascular, enfermedad de Parkinson, entre otras poblaciones objetivo, debido al contexto sanitario de la pandemia covid-19, este trabajo de investigación propone un sistema útil para la evaluación del riesgo de caídas, dándole un enfoque novedoso que no se ha tratado con

el enfoque de aplicación y usabilidad indicado, pues las investigaciones se centran principalmente en la caracterización de diferentes o determinadas poblaciones objetivo según los parámetros de movilidad obtenidos.

Tras los resultados presentados en esta investigación se ha podido proponer una herramienta automática de evaluación que, bajo ciertas consideraciones, permite identificar a partir de una prueba clínicamente validada, de fácil aplicación y junto a clasificadores comúnmente usados en aprendizaje automático en qué actividad motora (pararse, sentarse, girar para esquivar un objeto, girar sobre un mismo eje y/o caminar) un sujeto tiene riesgo de caer, entregando información complementaria y objetiva que comúnmente los profesionales del área de la salud no tienen tras la aplicación de esta prueba, comprobando la pregunta de validación presentada en este trabajo.



Bibliografía

- [1] “Shirley ryan - abilitylab,” <https://www.sralab.org/>, visitado: 19-07-2021.
- [2] R. López, E. Mancilla, A. Villalobos, and P. Herrera, “Manual de prevención de caída del adulto mayor programa de salud del adulto mayor,” 2010.
- [3] J. K. Aggarwal and Q. Cai, “Human motion analysis: A review,” *Computer vision and image understanding*, vol. 73, no. 3, pp. 428–440, 1999.
- [4] M. M. Lusardi, S. Fritz, A. Middleton, L. Allison, M. Wingood, E. Phillips, M. Criss, S. Verma, J. Osborne, and K. K. Chui, “Determining risk of falls in community dwelling older adults: a systematic review and meta-analysis using posttest probability,” *Journal of geriatric physical therapy (2001)*, vol. 40, no. 1, p. 1, 2017.
- [5] C. Albala, “El envejecimiento de la población chilena y los desafíos para la salud y el bienestar de las personas mayores,” *Revista Médica Clínica Las Condes*, vol. 31, no. 1, pp. 7–12, 2020.
- [6] R. E. Mayagoitia, A. V. Nene, and P. H. Veltink, “Accelerometer and rate gyroscope measurement of kinematics: an inexpensive alternative to optical motion analysis systems,” *Journal of biomechanics*, vol. 35, no. 4, pp. 537–542, 2002.
- [7] R. Zhu and Z. Zhou, “A real-time articulated human motion tracking using tri-axis inertial/magnetic sensors package,” *IEEE Transactions on Neural systems and rehabilitation engineering*, vol. 12, no. 2, pp. 295–302, 2004.
- [8] M. C. Boonstra, R. M. Van Der Slikke, N. L. Keijsers, R. C. Van Lummel, M. C. de Waal Malefijt, and N. Verdonshot, “The accuracy of measuring the kinematics of rising from a chair with accelerometers and gyroscopes,” *Journal of Biomechanics*, vol. 39, no. 2, pp. 354–358, 2006.
- [9] M. Y. Jeon, H. Jeong, J. Petrofsky, H. Lee, and J. Yim, “Effects of a randomized controlled recurrent fall prevention program on risk factors for falls in frail elderly living at home in rural communities,” *Medical science monitor: international medical journal of experimental and clinical research*, vol. 20, p. 2283, 2014.

- [10] E. Beghi, E. Gervasoni, E. Pupillo, E. Bianchi, A. Montesano, I. Aprile, M. Agostini, M. Rovaris, D. Cattaneo, G. Iacobone *et al.*, “Prediction of falls in subjects suffering from parkinson disease, multiple sclerosis, and stroke,” *Archives of physical medicine and rehabilitation*, vol. 99, no. 4, pp. 641–651, 2018.
- [11] A. Kingston, P. Wohland, R. Wittenberg, L. Robinson, C. Brayne, F. E. Matthews, C. Jagger, E. Green, L. Gao, R. Barnes *et al.*, “Is late-life dependency increasing or not? a comparison of the cognitive function and ageing studies (cfas),” *The Lancet*, vol. 390, no. 10103, pp. 1676–1684, 2017.
- [12] S. Hellmers, B. Izadpanah, L. Dasenbrock, R. Diekmann, J. M. Bauer, A. Hein, and S. Fudickar, “Towards an automated unsupervised mobility assessment for older people based on inertial tug measurements,” *Sensors*, vol. 18, no. 10, p. 3310, 2018.
- [13] H.-T. Goh, M. Nadarajah, N. B. Hamzah, P. Varadan, and M. P. Tan, “Falls and fear of falling after stroke: a case-control study,” *PM&R*, vol. 8, no. 12, pp. 1173–1180, 2016.
- [14] T. Siragy and J. Nantel, “Quantifying dynamic balance in young, elderly and parkinson’s individuals: a systematic review,” *Frontiers in aging neuroscience*, vol. 10, p. 387, 2018.
- [15] S. I. Sharif, A. B. Al-Harbi, A. M. Al-Shihabi, D. S. Al-Daour, and R. S. Sharif, “Falls in the elderly: assessment of prevalence and risk factors,” *Pharmacy Practice (Granada)*, vol. 16, no. 3, 2018.
- [16] D. Talarska, M. Strugała, M. Szewczyk, S. Tobis, M. Michalak, I. Wróblewska, and K. Wieczorowska-Tobis, “Is independence of older adults safe considering the risk of falls?” *BMC geriatrics*, vol. 17, no. 1, p. 66, 2017.
- [17] H. Qiu, R. Z. U. Rehman, X. Yu, and S. Xiong, “Application of wearable inertial sensors and a new test battery for distinguishing retrospective fallers from non-fallers among community-dwelling older people,” *Scientific reports*, vol. 8, no. 1, pp. 1–10, 2018.
- [18] D. Q. Sun, J. Huang, R. Varadhan, and Y. Agrawal, “Race and fall risk: data from the national health and aging trends study (nhats),” *Age and ageing*, vol. 45, no. 1, pp. 120–127, 2016.
- [19] H.-j. Kim, I. Park, H. joo Lee, and O. Lee, “The reliability and validity of gait speed with different walking pace and distances against general health, physical function, and chronic disease in aged adults,” *Journal of exercise nutrition & biochemistry*, vol. 20, no. 3, p. 46, 2016.

- [20] T. M. Steffen, T. A. Hacker, and L. Mollinger, "Age-and gender-related test performance in community-dwelling elderly people: Six-minute walk test, berg balance scale, timed up & go test, and gait speeds," *Physical therapy*, vol. 82, no. 2, pp. 128–137, 2002.
- [21] D. Podsiadlo and S. Richardson, "The timed "up & go": a test of basic functional mobility for frail elderly persons," *Journal of the American geriatrics Society*, vol. 39, no. 2, pp. 142–148, 1991.
- [22] T. Evans, A. Jefferson, M. Byrnes, S. Walters, S. Ghosh, F. L. Mastaglia, B. Power, and R. S. Anderton, "Extended "timed up and go" assessment as a clinical indicator of cognitive state in parkinson's disease," *Journal of the Neurological Sciences*, vol. 375, pp. 86–91, 2017.
- [23] E. Zasadzka, A. M. Borowicz, M. Roszak, and M. Pawlaczyk, "Assessment of the risk of falling with the use of timed up and go test in the elderly with lower extremity osteoarthritis," *Clinical interventions in aging*, vol. 10, p. 1289, 2015.
- [24] C. U. Persson, A. Danielsson, K. S. Sunnerhagen, A. Grimby-Ekman, and P.-O. Hansson, "Timed up & go as a measure for longitudinal change in mobility after stroke—postural stroke study in gothenburg (postgot)," *Journal of neuroengineering and rehabilitation*, vol. 11, no. 1, pp. 1–7, 2014.
- [25] H. Nguyen, K. Lebel, P. Boissy, S. Bogard, E. Goubault, and 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," *Journal of neuroengineering and rehabilitation*, vol. 14, no. 1, p. 26, 2017.
- [26] E. Barry, R. Galvin, C. Keogh, F. Horgan, and T. Fahey, "Is the timed up and go test a useful predictor of risk of falls in community dwelling older adults: a systematic review and meta-analysis," *BMC geriatrics*, vol. 14, no. 1, p. 14, 2014.
- [27] J. Perry, M. Garrett, J. K. Gronley, and S. J. Mulroy, "Classification of walking handicap in the stroke population," *Stroke*, vol. 26, no. 6, pp. 982–989, 1995.
- [28] A. Middleton, S. L. Fritz, and M. Lusardi, "Walking speed: the functional vital sign," *Journal of aging and physical activity*, vol. 23, no. 2, pp. 314–322, 2015.
- [29] P. D. Neuls, T. L. Clark, N. C. Van Heuklon, J. E. Proctor, B. J. Kilker, M. E. Bieber, A. V. Donlan, S. A. Carr-Jules, W. H. Neidel, and R. A. Newton, "Usefulness of the berg balance scale to predict falls in the elderly," *Journal of geriatric physical therapy*, vol. 34, no. 1, pp. 3–10, 2011.

- [30] M. Mathie, B. G. Celler, N. H. Lovell, and A. Coster, "Classification of basic daily movements using a triaxial accelerometer," *Medical and Biological Engineering and Computing*, vol. 42, no. 5, pp. 679–687, 2004.
- [31] U. Lindemann, A. Hock, M. Stuber, W. Keck, and C. Becker, "Evaluation of a fall detector based on accelerometers: A pilot study," *Medical and Biological engineering and computing*, vol. 43, no. 5, pp. 548–551, 2005.
- [32] M. Kangas, A. Konttila, P. Lindgren, I. Winblad, and T. Jämsä, "Comparison of low-complexity fall detection algorithms for body attached accelerometers," *Gait & posture*, vol. 28, no. 2, pp. 285–291, 2008.
- [33] W. H. Wu, A. A. Bui, M. A. Batalin, D. Liu, and W. J. Kaiser, "Incremental diagnosis method for intelligent wearable sensor systems," *IEEE Transactions on Information Technology in Biomedicine*, vol. 11, no. 5, pp. 553–562, 2007.
- [34] E. Jovanov, A. Milenkovic, C. Otto, and P. C. De Groen, "A wireless body area network of intelligent motion sensors for computer assisted physical rehabilitation," *Journal of NeuroEngineering and rehabilitation*, vol. 2, no. 1, pp. 1–10, 2005.
- [35] A. M. Sabatini, "Inertial sensing in biomechanics: a survey of computational techniques bridging motion analysis and personal navigation," in *Computational intelligence for movement sciences: Neural networks and other emerging techniques*. IGI Global, 2006, pp. 70–100.
- [36] J. Parkka, M. Ermes, P. Korpipaa, J. Mantyjarvi, J. Peltola, and I. Korhonen, "Activity classification using realistic data from wearable sensors," *IEEE Transactions on information technology in biomedicine*, vol. 10, no. 1, pp. 119–128, 2006.
- [37] R. Aylward and J. A. Paradiso, "Senseble: a wireless, compact, multi-user sensor system for interactive dance," in *Proceedings of the 2006 conference on New interfaces for musical expression*. Citeseer, 2006, pp. 134–139.
- [38] T. Shiratori and J. K. Hodgins, "Accelerometer-based user interfaces for the control of a physically simulated character," *ACM Transactions on Graphics (TOG)*, vol. 27, no. 5, pp. 1–9, 2008.
- [39] K. Aminian, P. Robert, E. Buchser, B. Rutschmann, D. Hayoz, and M. Depairon, "Physical activity monitoring based on accelerometry: validation and comparison with video

- observation,” *Medical & biological engineering & computing*, vol. 37, no. 3, pp. 304–308, 1999.
- [40] D. M. Karantonis, M. R. Narayanan, M. Mathie, N. H. Lovell, and B. G. Celler, “Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring,” *IEEE transactions on information technology in biomedicine*, vol. 10, no. 1, pp. 156–167, 2006.
- [41] L. Bao and S. S. Intille, “Activity recognition from user-annotated acceleration data,” in *International conference on pervasive computing*. Springer, 2004, pp. 1–17.
- [42] H. Lau and K. Tong, “The reliability of using accelerometer and gyroscope for gait event identification on persons with dropped foot,” *Gait & posture*, vol. 27, no. 2, pp. 248–257, 2008.
- [43] A. King, “Inertial navigation-forty years of evolution,” *GEC review*, vol. 13, no. 3, pp. 140–149, 1998.
- [44] T. Seel and S. Ruppel, “Eliminating the effect of magnetic disturbances on the inclination estimates of inertial sensors,” *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 8798–8803, 2017.
- [45] S.-H. Park, “Tools for assessing fall risk in the elderly: a systematic review and meta-analysis,” *Aging clinical and experimental research*, vol. 30, no. 1, pp. 1–16, 2018.
- [46] H. Nguyen, K. Lebel, S. Bogard, E. Goubault, P. Boissy, and C. Duval, “Using inertial sensors to automatically detect and segment activities of daily living in people with parkinson’s disease,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 1, pp. 197–204, 2017.
- [47] A. Galán-Mercant, F. J. Barón-López, M. T. Labajos-Manzanares, and A. I. Cuesta-Vargas, “Reliability and criterion-related validity with a smartphone used in timed-up-and-go test,” *Biomedical engineering online*, vol. 13, no. 1, p. 156, 2014.
- [48] T. Bright, S. Wallace, and H. Kuper, “A systematic review of access to rehabilitation for people with disabilities in low-and middle-income countries,” *International journal of environmental research and public health*, vol. 15, no. 10, p. 2165, 2018.
- [49] S. Flory, “The prospects and challenges of bringing physical therapy to the physically disabled population in developing countries,” 2009.

- [50] L. L. G. Echeverry, A. M. J. Henao, M. A. R. Molina, S. M. V. Restrepo, C. A. P. Velásquez, and G. J. S. Bolívar, “Human motion capture and analysis systems: a systematic review/sistemas de captura y análisis de movimiento cinemático humano: una revisión sistemática,” *Prospectiva*, vol. 16, no. 2, pp. 24–34, 2018.
- [51] A. Weiss, A. Mirelman, A. S. Buchman, D. A. Bennett, and J. M. Hausdorff, “Using a body-fixed sensor to identify subclinical gait difficulties in older adults with iadl disability: maximizing the output of the timed up and go,” *PLoS one*, vol. 8, no. 7, p. e68885, 2013.
- [52] N. Tanaka, N. A. Zakaria, N. K. Kibinge, S. Kanaya, T. Tamura, and M. Yoshida, “Fall-risk classification of the timed up-and-go test with principle component analysis,” *Int. J. Neurorehabilit*, vol. 1, p. 106, 2014.
- [53] R. Soangra, T. E. Lockhart, and N. Van de Berge, “An approach for identifying gait events using wavelet denoising technique and single wireless imu,” in *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, vol. 55, no. 1. SAGE Publications Sage CA: Los Angeles, CA, 2011, pp. 1990–1994.
- [54] K. Lebel, H. Nguyen, C. Duval, R. Plamondon, and P. Boissy, “Capturing the cranio-caudal signature of a turn with inertial measurement systems: methods, parameters robustness and reliability,” *Frontiers in bioengineering and biotechnology*, vol. 5, p. 51, 2017.
- [55] D. Vervoort, N. Vuillerme, N. Kosse, T. Hortobágyi, and C. J. Lamoth, “Multivariate analyses and classification of inertial sensor data to identify aging effects on the timed-up-and-go test,” *PLoS One*, vol. 11, no. 6, p. e0155984, 2016.
- [56] A. Salarian, F. B. Horak, C. Zampieri, P. Carlson-Kuhta, J. G. Nutt, and K. Aminian, “itug, a sensitive and reliable measure of mobility,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 18, no. 3, pp. 303–310, 2010.
- [57] C.-C. Yang and Y.-L. Hsu, “A review of accelerometry-based wearable motion detectors for physical activity monitoring,” *Sensors*, vol. 10, no. 8, pp. 7772–7788, 2010.
- [58] L. Carcreff, C. Gerber, A. Paraschiv-Ionescu, G. De Coulon, C. Newman, S. Armand, and K. Aminian, “What is the best configuration of wearable sensors to measure spatiotemporal gait parameters in children with cerebral palsy?” *Sensors*, vol. 18, no. 2, p. 394, 2018.
- [59] T. Sayeed, A. Samà, A. Català, and J. Cabestany, “Comparison and adaptation of step length and gait speed estimators from single belt worn accelerometer positioned on lateral

- side of the body,” in *Intelligent Signal Processing (WISP), 2013 IEEE 8th International Symposium on*. IEEE, 2013, pp. 14–20.
- [60] A. Salarian, P. R. Burkhard, F. J. Vingerhoets, B. M. Jolles, and K. Aminian, “A novel approach to reducing number of sensing units for wearable gait analysis systems,” *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 1, pp. 72–77, 2013.
- [61] E. Sejdić, K. A. Lowry, J. Bellanca, S. Perera, M. S. Redfern, and J. S. Brach, “Extraction of stride events from gait accelerometry during treadmill walking,” *IEEE journal of translational engineering in health and medicine*, vol. 4, pp. 1–11, 2016.
- [62] R. C. González, A. M. López, J. Rodríguez-Uría, D. Alvarez, and J. C. Alvarez, “Real-time gait event detection for normal subjects from lower trunk accelerations,” *Gait & posture*, vol. 31, no. 3, pp. 322–325, 2010.
- [63] A. Kose, A. Peruzzi, A. Cereatti, L. Laudani, and U. Della Croce, “Detection of heel strikes and toe-offs during gait using a single inertial measurement unit attached to the waist,” in *Proc Second National Congress of Biongingering, Turin, Italy*, vol. 233, 2010.
- [64] J. McCamley, M. Donati, E. Grimpampi, and C. Mazza, “An enhanced estimate of initial contact and final contact instants of time using lower trunk inertial sensor data,” *Gait & posture*, vol. 36, no. 2, pp. 316–318, 2012.
- [65] K. Aminian, K. Rezakhanlou, E. De Andres, C. Fritsch, P.-F. Leyvraz, and P. Robert, “Temporal feature estimation during walking using miniature accelerometers: an analysis of gait improvement after hip arthroplasty,” *Medical & biological engineering & computing*, vol. 37, no. 6, pp. 686–691, 1999.
- [66] J. M. Jasiewicz, J. H. Allum, J. W. Middleton, A. Barriskill, P. Condie, B. Purcell, and R. C. T. Li, “Gait event detection using linear accelerometers or angular velocity transducers in able-bodied and spinal-cord injured individuals,” *Gait & posture*, vol. 24, no. 4, pp. 502–509, 2006.
- [67] A. M. Sabatini, C. Martelloni, S. Scapellato, and F. Cavallo, “Assessment of walking features from foot inertial sensing,” *IEEE Transactions on Biomedical Engineering*, vol. 52, no. 3, pp. 486–494, March 2005.
- [68] K. Aminian, B. Najafi, C. Büla, P.-F. Leyvraz, and P. Robert, “Spatio-temporal parameters of gait measured by an ambulatory system using miniature gyroscopes,” *Journal of biomechanics*, vol. 35, no. 5, pp. 689–699, 2002.

- [69] R. C. Gonzalez, D. Alvarez, A. M. Lopez, and J. C. Alvarez, "Modified pendulum model for mean step length estimation," in *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE*. IEEE, 2007, pp. 1371–1374.
- [70] E. P. Doheny, T. G. Foran, and B. R. Greene, "A single gyroscope method for spatial gait analysis," in *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*. IEEE, 2010, pp. 1300–1303.
- [71] W. Zijlstra and A. L. Hof, "Assessment of spatio-temporal gait parameters from trunk accelerations during human walking," *Gait & posture*, vol. 18, no. 2, pp. 1–10, 2003.
- [72] J. C. Alvarez, D. Alvarez, A. López, and R. C. González, "Pedestrian navigation based on a waist-worn inertial sensor," *Sensors*, vol. 12, no. 8, pp. 10 536–10 549, 2012.
- [73] A. Godfrey, S. Del Din, G. Barry, J. Mathers, and L. Rochester, "Instrumenting gait with an accelerometer: a system and algorithm examination," *Medical engineering & physics*, vol. 37, no. 4, pp. 400–407, 2015.
- [74] B. Sensortec, "Intelligent 9-axis absolute orientation sensor," *BNO055 datasheet*, November, 2014.
- [75] S. Cheshire and M. Baker, "Consistent overhead byte stuffing," *IEEE/ACM Transactions on networking*, vol. 7, no. 2, pp. 159–172, 1999.
- [76] m. romanov, p. berghold, m. frank, d. rudrich, m. zaunschirm, and f. zotter, "implementation and evaluation of a low-cost headtracker for binaural synthesis," *journal of the audio engineering society*, may 2017.
- [77] Z. Lin, Y. Xiong, H. Dai, and X. Xia, "An experimental performance evaluation of the orientation accuracy of four nine-axis mems motion sensors," in *2017 5th International Conference on Enterprise Systems (ES)*, 2017, pp. 185–189.
- [78] M. H. Pham, E. Warmerdam, M. Elshehabi, C. Schlenstedt, L.-M. Bergeest, M. Heller, L. Haertner, J. Ferreira, D. Berg, G. Schmidt *et al.*, "Validation of a lower back "wearable"-based sit-to-stand and stand-to-sit algorithm for patients with parkinson's disease and older adults in a home-like environment," *Frontiers in neurology*, vol. 9, p. 652, 2018.
- [79] H. Weinberg, "Using the adxl202 in pedometer and personal navigation applications," *Analog Devices AN-602 application note*, vol. 2, no. 2, pp. 1–6, 2002.

- [80] R. B. Davis III, S. Ounpuu, D. Tyburski, and J. R. Gage, "A gait analysis data collection and reduction technique," *Human movement science*, vol. 10, no. 5, pp. 575–587, 1991.
- [81] R. C. Van Lummel, S. Walgaard, M. A. Hobert, W. Maetzler, J. H. Van Dieën, F. Galindo-Garre, and C. B. Terwee, "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, no. 3, p. e0151881, 2016.
- [82] J. Rabey and A. Korczyn, "The hoehn and yahr rating scale for parkinson's disease," in *Instrumental Methods and Scoring in Extrapyrarnidal Disorders*. Springer, 1995, pp. 7–17.
- [83] A. Weiss, M. Brozgol, M. Dorfman, T. Herman, S. Shema, N. Giladi, and J. M. Hausdorff, "Does the evaluation of gait quality during daily life provide insight into fall risk? a novel approach using 3-day accelerometer recordings," *Neurorehabilitation and neural repair*, vol. 27, no. 8, pp. 742–752, 2013.
- [84] P. Joshi, *Artificial intelligence with python*. Packt Publishing Ltd, 2017.
- [85] R. Senden, B. Grimm, I. Heyligers, H. Savelberg, and K. Meijer, "Acceleration-based gait test for healthy subjects: reliability and reference data," *Gait & posture*, vol. 30, no. 2, pp. 192–196, 2009.
- [86] O. Beauchet, C. Annweiler, F. Assal, S. Bridenbaugh, F. R. Herrmann, R. W. Kressig, and G. Allali, "Imagined timed up & go test: a new tool to assess higher-level gait and balance disorders in older adults?" *Journal of the neurological sciences*, vol. 294, no. 1-2, pp. 102–106, 2010.

A. Esquemáticos

A.1. Esquemático sensor IMU

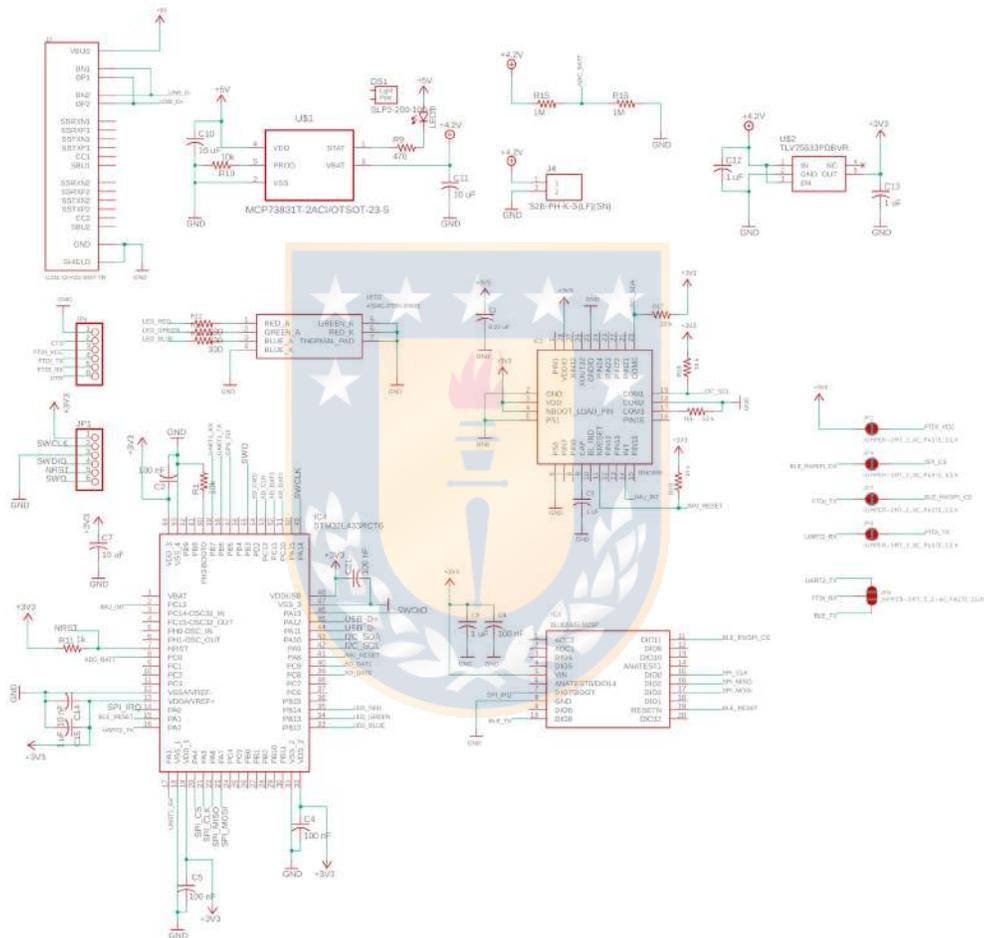


Fig. A.1: Esquemático sensor implementado. [Elaboración Propia]