



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**  
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA  
ELÉCTRICA  
PROCESAMIENTO DE SEÑALES

**ESTUDIO DE LA VARIABILIDAD DEL CENTRO DE MASA DURANTE LA  
CAMINATA EN ANCIANOS MEDIANTE ANÁLISIS EN TIEMPO-FRECUENCIA DE  
SEÑALES DE ACCELEROMETRÍA**

TESIS  
QUE PARA OPTAR POR EL GRADO DE:  
MAESTRA EN INGENIERÍA

PRESENTA:  
ELNAZ ARAGHIZADEH

TUTOR  
DR. MIGUEL ÁNGEL PADILLA CASTAÑEDA, ICAT

CIUDAD UNIVERSITARIA, CD. MX.

NOVIEMBRE 2020



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

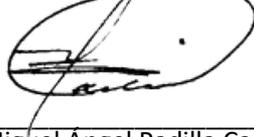
El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

**JURADO ASIGNADO:**

Presidenta: Dra. Lucia Medina Gómez  
Secretario: Dr. Miguel Moctezuma Flores  
1<sup>er</sup> Vocal: Dr. Miguel Ángel Padilla Castañeda  
2<sup>do</sup> Vocal : Dr. Jesús Savage Carmona  
3<sup>er</sup> Vocal : Dra. Fátima Moumtadi

Ciudad Universitaria, Instituto de Ciencias Aplicadas y Tecnología, Programa de Maestría y Doctorado en Ingeniería Eléctrica, UNAM

**TUTOR DE LA TESIS**



---

Dr. Miguel Ángel Padilla Castañeda

*El presente trabajo de tesis fue desarrollado  
en el Instituto de Ciencias Aplicadas y  
Tecnología  
de la Universidad Nacional Autónoma  
de México, bajo la tutoría del  
Dr. Miguel Ángel Padilla Castañeda  
con beca CONACYT PNPIC*

## Dedicatoria

*Dedico este trabajo de tesis a mi esposo:*

*Hamidreza Maymandi*

*Por tu aliento y apoyo para completar este enorme logro en mi vida.*

*te le agradezco desde el fondo de mi alma.*

# Agradecimientos

Agradezco sinceramente a:

Al Dr. Miguel Ángel Padilla por invitarme a participar en este proyecto, guiándome y apoyándome durante todo el proceso, esta investigación no hubiera sido posible sin la inestimable ayuda de mi tutor de tesis, quien fue capaz de encauzarme y dirigirme en la consecución de la misma, argumentando todos los puntos que la componen de forma correcta y a la vez concisa. Le agradezco la confianza depositada en mí ya que me ha servido para lograr una gran motivación, ayudándome a continuar en los momentos más difíciles, enriqueciéndome con conocimientos a lo largo de este emocionante periodo.

A mis padres quienes me dieron vida, educación, apoyo y consejos, a pesar de nuestra distancia física.

La Universidad Nacional Autónoma de México por brindarme la posibilidad de realizar mis estudios de posgrado.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) y a la Secretaría de Educación, Ciencia, Tecnología e Innovación de la Cd. México (proyecto SECTEI 219/2019) por el apoyo económico que me brindaron durante mis estudios de maestría.

Agradezco también el apoyo del proyecto PAPIIT T100920 para la realización de este trabajo de tesis.

A los sinodales por su tiempo para revisar este trabajo y lo aprobaron.

A mis compañeros de estudio que me ayudaron.

A todos aquellos que me apoyaron moral y económicamente.

## Resumen

La incidencia de caídas accidentales entre los adultos mayores, junto con su impacto en términos de morbilidad y mortalidad, los ha convertido en un problema de salud pública en todo el mundo. Se estima que el 28% al 45% de las personas de 65 años o más caen cada año. Estos eventos representan del 18% al 40% de la asistencia al departamento de emergencias y más del 80% de todas las admisiones por lesiones a hospitales del mismo grupo de edad. Entre las lesiones más graves causadas por caídas se encuentran la fractura de cadera y lesión cerebral traumática; este último representa el 46% de las caídas fatales entre adultos mayores. Las caídas accidentales también tienen un gran impacto en costos para los sistemas de salud y para la sociedad.

Esta tesis tiene el propósito de investigar y desarrollar una metodología de análisis de señales mediante sensores inerciales (IMUS) para poderse utilizar en estudios de riesgo de caídas, para a futuro detectarlas e incluso prevenir si se administran los medios adecuados al paciente. Estos incidentes requieren intervenciones tanto humanas como técnicas.

Por este motivo, desarrollamos unos algoritmos de análisis de patrones mediante técnicas basadas en análisis tiempo-frecuencia, para descomponer las señales de entrada de acelerometría obtenidas por un IMU, en una serie de secuencias de datos llamados funciones de modo intrínseco (FMIs), con las cuáles caracterizar los patrones de caminata. Esta técnica, llamada descomposición empírica de modos (EMD por sus siglas en inglés), es adecuada para el análisis de señales no estacionarias y no lineales como las señales de acelerometría del movimiento de cuerpo humano. Cada componente pasa por una etapa de extracción de características tiempo-frecuencia, empleando características temporales útiles para describir la forma de onda, así como, la transformada de Hilbert-Huang, para obtener las frecuencias instantáneas de cada componente, para sacar características en los dominios tiempo frecuencia, que son datos valiosos para entender la caminata en ancianos con respecto a adultos jóvenes. Se utilizó una base de datos con registros de acelerometría, obtenidos con un IMU colocado en el centro de masa de 30 sujetos (15 adultos jóvenes, 15 ancianos) para tres tipos de pruebas (caminata lenta, caminata rápida, trotando), seguida de una fase de selección de características con ayuda de análisis estadístico MANOVA (análisis multivariado de varianza) con lo que se observaron diferentes patrones entre los adultos jóvenes y los ancianos.

La metodología descrita en este trabajo muestra resultados prometedores para entender los riesgos de caída. Estos resultados infieren que la metodología propuesta sería de gran utilidad para estudiar los movimientos irregulares en los ancianos, resaltando la descomposición de la señal de acelerometría usando la EMD como una técnica de descomposición automatizada y efectiva para señales biológicas, en este caso de caminata.

# Índice general

<b>Agradecimientos</b> .....	1
<b>Resumen</b> .....	2
<b>Introducción</b> .....	8
1.1. Problemática .....	8
1.2. Justificación.....	9
1.3. Objetivos .....	10
1.3.1. Objetivo General .....	10
1.3.2. Objetivos Específicos.....	10
1.4. Método .....	10
1.5. Estructura de la tesis.....	11
<b>Capítulo 2.</b> .....	12
<b>Estado del arte.</b> .....	12
2.1. El problema de la detección de caídas.....	12
2.2. Trabajos previos.....	15
2.3. Clasificación de sistemas.....	15
2.3.1. Tipos de mediciones .....	16
2.3.2. Sistemas no vestibles .....	16
2.3.2.1. Basados en infrarrojos .....	17
2.3.2.2. Basados en cámaras.....	17
2.3.3. Sensores instalados en el entorno .....	18
2.3.4. Sistemas portátiles.....	19
2.3.4.1. Sistemas basados en acelerómetros.....	19
2.4.4.2. Sistemas basados en acelerómetros y otros tipos de sensores.....	19
2.4. Colocación de los sensores .....	20
2.5. Algoritmos para la detección de caídas mediante el uso de acelerómetros.....	22
2.5.1. Detección del pico de aceleración .....	22
2.5.2. Detección de la colisión .....	22
2.5.3. Detección de las etapas de la caída .....	22
2.6. Parámetros de detección .....	23
2.7. Técnicas de procesamiento de señales.....	25
2.7.1. Métodos analíticos.....	25
2.7.2. Métodos de aprendizaje automático.....	26

2.8. Resumen del estado del arte .....	26
<b>Capítulo 3.</b> .....	<b>28</b>
<b>Metodología</b> .....	<b>28</b>
3.1. Metodología de Transformada Hilbert Huang (THH).....	28
3.1.1. Función de Modo Intrínseco .....	28
3.1.2. Método Empírico de Descomposición .....	29
3.1.3. Transformada de Hilbert.....	31
3.2. El espectro de Hilbert.....	32
3.3.1. Descripción de los Pruebas .....	33
3.3.2. Descripción de los Participantes .....	34
3.4. Descripción de dispositivo .....	35
3.4.1. Sensores inerciales.....	35
3.4.2. Configuración experimental.....	36
3.5. Descripción del análisis .....	37
3.5.1. Descomposición de las señales y extracción de características por Transformada Hilbert-Huang .....	38
3.6. Extracción de características tiempo-frecuencia .....	40
3.6.1. Media Cuadrática (RMS) .....	40
3.6.2. Frecuencia instantánea media (MIF) .....	41
3.7. Selección de características y la prueba “t” .....	41
3.7.1. Test de hipótesis .....	42
1. Establecer las hipótesis.....	42
2. Calcular el estadístico (parámetro estimado).....	43
3. Determinar el tipo de prueba, una o dos colas.....	43
4. Determinar el nivel de significancia $\alpha$ .....	43
5. Cálculo de valor de p y comparación con el nivel de significancia .....	43
6. Tamaño del efecto .....	44
7. Interpretación de los resultados.....	44
3.8. Descripción ANOVA (para n niveles de un solo factor).....	44
3.9. Descripción MANOVA (para n niveles de un solo m factores).....	45
<b>Capítulo 4.</b> .....	<b>46</b>
<b>Resultados</b> .....	<b>46</b>
4.1. Aplicación de la transformada de Hilbert-Huang .....	47

4.2. Patrones de caminata observados.....	49
4.2.1. Amplitud de la aceleración en eje Y (RMS Y) .....	50
4.2.2. Frecuencia media instantánea en el eje X (MIF X).....	51
4.2.3. Frecuencia media instantánea en el eje Y (MIF Y) .....	52
4.3.4. Frecuencia media instantánea en el eje Z .....	53
4.3.5. Comparación entre grupos para RMS y MIF de aceleración .....	55
4.3 Análisis estadístico comparativo.....	56
<b>Capítulo 5.....</b>	<b>60</b>
<b>Conclusiones y trabajo futuro.....</b>	<b>60</b>
<b>Referencias .....</b>	<b>62</b>

## Índice de figuras

2.1. Localización de caídas - Gráfico de sectores .....	13
2.2. Porcentaje de caídas en interiores y la edad .....	14
2.3. Etapas de la caída y cambios en la aceleración propuestas .....	23
3.1. Algoritmo del Método de Descomposición Empírica en Modos .....	31
3.2. Sensor ADXL345 con referencia de la orientación de sus ejes y sentido de giro.....	35
3.3. Dispositivo utilizado para la adquisición. ....	36
4.1. Señales de acelerometría en el eje de gravedad de un sujeto adulto y un sujeto anciano .....	46
4.2. Descomposición de modo empírico de señales de acelerometría en el eje de gravedad de un sujeto adulto y un sujeto anciano .....	48
4.3. Fases de la marcha humana, dividida en fase de apoyo y fase de balanceo.....	49
4.4. Diagrama de caja en característica de RMS en eje Y entre grupos. ....	50
4.5. Amplitud RMS en el eje Y de las 225 señales, tanto para adultos y ancianos .....	50
4.6. Diagrama de caja en característica de MIF en eje X entre grupos .....	51
4.7. Frecuencia MIF en el eje X de las 225 señales, tanto para adultos y ancianos .....	52
4.8. Diagrama de caja en característica de MIF en eje Y entre grupos.....	53
4.9. Frecuencia MIF en el eje Y de las 225 señales, tanto para adultos y ancianos .....	53
4.10. Diagrama de caja en característica de MIF en eje Z entre grupos.....	54
4.11. Frecuencia MIF en el eje Z de las 225 señales, tanto para adultos y ancianos .....	54
4.12. Diagramas de caja en característica RMS y MIF .....	55

## Índice de tablas

2.1. Clasificación de sistemas .....	15
2.2. Mediciones .....	16
2.3. Ubicación de los sensores .....	21
2.4. Resumen y breve descripción de los principales parámetros de balance .....	24
2.5. Técnicas de procesamiento de datos.....	25
3.1. Tipos de actividades de la vida diaria seleccionadas para este trabajo. ....	34
3.2: Perfil de los participantes .....	35
4.1. Análisis estadístico comparativo para 6 características de tiempo y frecuencia .....	57

## Acrónimos

<b>ADL</b>	Actividades de la vida diaria
<b>ANN</b>	Redes neuronales artificiales
<b>ANOVA</b>	Análisis de la varianza
<b>AP</b>	Dirección anteroposterior
<b>CF</b>	Frecuencia centroidal
<b>COM</b>	Centro de masa
<b>DTW</b>	Transformada de wavelet discreta
<b>EMD</b>	Descomposición emperica de modos
<b>EMG</b>	Electromiografía
<b>FD</b>	Dispersión de frecuencia
<b>FFT</b>	Transformada de Fourier
<b>FMI</b>	Frecuencia de modo intrínseco
<b>HHT</b>	Transformada de Hilbert-Huang
<b>HMM</b>	Modelo ocultado de Márkov
<b>JL</b>	Índice de sacudidas
<b>KNN</b>	K-vecino más cercano
<b>MANOVA</b>	Análisis multivariante de la varianza
<b>MEMS</b>	Sistemas microelectrónicas
<b>MIF</b>	Media de la frecuencia instantánea
<b>ML</b>	Dirección medio lateral
<b>MLM</b>	Métodos de aprendizaje de maquina
<b>NP</b>	No valor significativa de P
<b>OMS</b>	Organización mundial de la salud
<b>RMS</b>	Raíz media cuadrática
<b>STFT</b>	Transformada corta de Fourier
<b>SVM</b>	Maquinas de vectores soportes
<b>TH</b>	Umbralización
<b>WT</b>	Transformada de wavelet
<b>WPT</b>	Transformada de paquetes de wavelet

# Capítulo 1.

## Introducción

### 1.1. Problemática

Las caídas constituyen un importante problema de salud pública. Se estima que entre un 28% y un 35% de los mayores de 65 años se caen cada año. Este porcentaje se incrementa con la edad, por ejemplo, hasta un rango de 32 – 42 % para los que están por encima de 70 años[1]. Las caídas pueden tener consecuencias desde leves, como hematomas o golpes, hasta más graves, como fracturas de cadera. Cada año, más de un 10 % de la población europea mayor de 65 años será tratada por un médico de una herida relacionada con una caída y cien mil personas morirán como consecuencia de las heridas de una caída. Existe una relación entre el tiempo que pasa el anciano en el suelo y la gravedad de las consecuencias de las caídas. Además, el miedo a las caídas supone una importante merma de la calidad de vida de los ancianos, reduciendo sus salidas, su vida social, su independencia e incluso aumentando el propio riesgo de caídas. Por tanto, la detección y evaluación de riesgo de caídas, avisando a los cuidadores en el momento oportuno, constituye un importante tema de investigación.

Estos hechos son la razón del desarrollo de varias soluciones de detección de caídas o de prevención, para asegurar una respuesta rápida en caso de que tal evento ocurra. Sin embargo, hoy día se utilizan pocos sistemas comerciales, debido a problemas de fiabilidad, facilidad de instalación y uso, o bien porque las personas no aceptan el dispositivo, por diversos motivos, como rechazo tecnológico o simplemente por su coste.

En los últimos años, han aparecido numerosos sistemas basados en tecnologías de la información y las comunicaciones para detectar caídas. Sin embargo, su uso no está extendido. En trabajos anteriores en la literatura se han realizado revisiones sistemáticas de estudios sobre la percepción de los mayores de la tecnología orientada a la prevención y detección de caídas [2][3][4][5], donde en resumen se concluye que hay una serie de factores intrínsecos y extrínsecos para la motivación del uso de tecnologías y su adopción permanente. Entre los factores intrínsecos, citamos:

- La independencia que se gana con el sistema para moverse sin miedo.
- La usabilidad.
- Coste (en menor medida).

En los estudios entendemos las inquietudes comunes que surgían. Las caídas se perciben como el efecto de la edad o de una enfermedad. El riesgo de caídas es visto como una vulnerabilidad. La posibilidad de detección automática, sin necesidad de presionar un botón, y de que el sistema

funcione en cualquier lugar es una gran ventaja para los mayores y sus cuidadores, lo que repercute en un incremento de la predisposición a llevar el dispositivo y no “olvidarse” de colocarlo todos los días. Se citan algunos factores en contra, como la pérdida de privacidad, la sensación de estar controlado, falsas alarmas, falta de comodidad o el miedo a ser llevado a una residencia en caso de detectarse caídas habituales.

Como resultado de estas reflexiones, la motivación principal de este proyecto será estudiar las soluciones existentes, diseñar e implementar un sistema basado en la monitorización mediante acelerómetros que detecte caídas simuladas en entornos similares a uno doméstico y posteriormente realizar un prototipo del dispositivo real.

## 1.2. Justificación

Dentro de nuestra agitada sociedad, la mayoría de los ancianos viven una situación de abandono, soledad y maltrato sumados a sus limitaciones físicas y mentales propias de la edad. El estilo de vida actual obliga a que estas personas pasen largas horas solas con el grave riesgo de sufrir accidentes y no ser atendidos. Se trata, indudablemente, de un problema social muy complejo que afecta a un grupo humano sumamente vulnerable y desprotegido. Dentro de este contexto ocurren las caídas siendo actualmente un problema de salud importante debido a su gran incidencia, morbilidad, mortalidad y la seria afectación que puede tener en la calidad de vida de los afectados [6].

En los sistemas públicos de salud las caídas de pacientes adultos mayores implican altos costos asociados a la asignación de recurso de personal, infraestructura, tratamientos y medicamentos [1].

Por lo tanto, consideramos que es necesario investigar y estudiar las limitantes de los métodos actuales, así como contar con métricas menos subjetivas, con mayor repetitividad y sensibilidad. El sistema propuesto es factible de uso dada sus características de portabilidad, robustez, confiabilidad, mínima incomodidad, inocuidad, ausencia de cables, no interferencia con otros equipos y especialmente no ser invasivo. La tecnología disponible en la actualidad en electrónica, telecomunicaciones, informática y en micromecánica permite la construcción de dispositivos biomédicos portátiles a costos reducidos. El presente trabajo contribuye, a ir proporcionar una metodología de análisis de patrones de movilidad en ancianos durante actividades de locomoción, basada en análisis de series de tiempo en tiempo-frecuencia, que pueda servir de base para el estudio de detección y riesgos de caídas en ancianos. Además, desde el punto de vista de instrumentación biomédica, este trabajo pretende brindar herramientas de análisis que permitan el diseño de mejores métodos y algoritmos capaces de hacer el procesamiento, análisis y detección de una gran cantidad de señales fisiológicas que contengan información significativa de patrones del movimiento.

## 1.3. Objetivos

### 1.3.1. Objetivo General

El objetivo principal de este trabajo consiste en desarrollar un esquema de evaluación de movilidad en ancianos que pueda ser utilizado como herramienta para el análisis de riesgo de caídas mediante el uso de sensores inerciales basado en acelerómetros, capaz de detectar los tipos de caídas más comunes en personas mayores, intentando lograr una precisión aceptable.

### 1.3.2. Objetivos Específicos

- Adquisición de señales de movimiento por acelerometría obtenidas por sensores inerciales colocados en el cuerpo humano, durante tareas de tres tipos de caminata.
- Desarrollar algoritmos de detección de patrones en series de tiempo de acelerometría mediante análisis tiempo-frecuencia.
- Realizar un estudio comparativo entre un grupo de ancianos y adultos jóvenes que demuestre la viabilidad del método propuesto para detectar cambios.

## 1.4. Método

Para abordar estos objetivos, se enfocará el trabajo de manera progresiva en las siguientes etapas:

- Estudio del estado del arte:

Se analizarán los distintos métodos y sistemas que existen actualmente para evaluación de la movilidad y la detección de caídas, comparando las propiedades que presentan bajo diversas condiciones y eligiendo, finalmente, una de las aproximaciones para desarrollar la propia implementación.

- Análisis el método seleccionado:

Una vez seleccionada la técnica de detección de caídas que se considere más conveniente tanto por sus resultados como por su posibilidad en el desarrollo, se analizará en detalle dicho método y posibles mejoras al mismo.

- Desarrollo del sistema:

1. Implementar una red de sensores inerciales IMUs para colocarse en el cuerpo del paciente
2. Adquisición de las señales de acelerometría y movimiento mediante una aplicación celular.
3. Transmisión de las señales por vía inalámbrica a la computadora mediante Bluetooth.

4. Capturar las señales de acelerometría de diferentes partes del cuerpo (espalda, muslos y pantorrillas).
5. Emplear algoritmos de tiempo frecuencia (HHT, por sus siglas en inglés) para detectar características de acelerometría y de los ángulos de movimiento.
6. Investigar diferencias entre las características de las señales entre los ancianos y los adultos.
7. Establecer métricas en tiempo-frecuencia que muestren diferencias entre los dos grupos y que sirvan de base para estudios futuros.

## 1.5. Estructura de la tesis

Inicialmente, en el capítulo 1 (Introducción) se procede a definir el problema que se desea resolver, explicando su motivación y objetivos planteados a alcanzar, así como la metodología empleada para realizar todo el proceso.

El capítulo 2 (Estado del arte) contiene la revisión bibliográfica de los trabajos de investigación anteriores. Es importante para centrar la tesis y conocer los tipos de clasificadores y características que se han propuesto, en especial los basados en acelerómetros. Se ha intentado resumir la información relevante en las tablas, el que resumimos los estudios previos y justificamos la necesidad de esta tesis y sus objetivos, destacando sus aportaciones originales.

A continuación, en el capítulo 3 (Metodología), se incluye información sobre cómo se realizó la aproximación al problema, tanto en un entorno simulado como en un entorno real, definiendo los entornos empleados para la experimentación y las pruebas. presentamos los materiales y métodos utilizados en la tesis. Explicamos la base de datos de caídas utilizada y actividades de la vida diaria, fundamental para evaluar los algoritmos. En el capítulo 4 (Resultados) se presentan los detalles de los resultados experimentales obtenidos tanto de las pruebas iniciales, que nos permitió hacer nuestra propuesta de solución del problema, así como los valores estadísticos tras realizar diversas pruebas, sometiendo al sistema a los casos de uso definidos en la sección diseño del sistema.

Finalmente, en el capítulo 5 (Conclusiones y trabajo futuro), se realiza una breve discusión sobre los resultados obtenidos, resumiendo qué se ha hecho en este trabajo, el grado de aproximación a los objetivos iniciales y los puntos que han quedado pendientes de resolver, realizando una evaluación crítica del desarrollo una vez terminado.

En el apéndice al final de la tesis se presenta una profundización sobre las tecnologías hardware utilizadas.

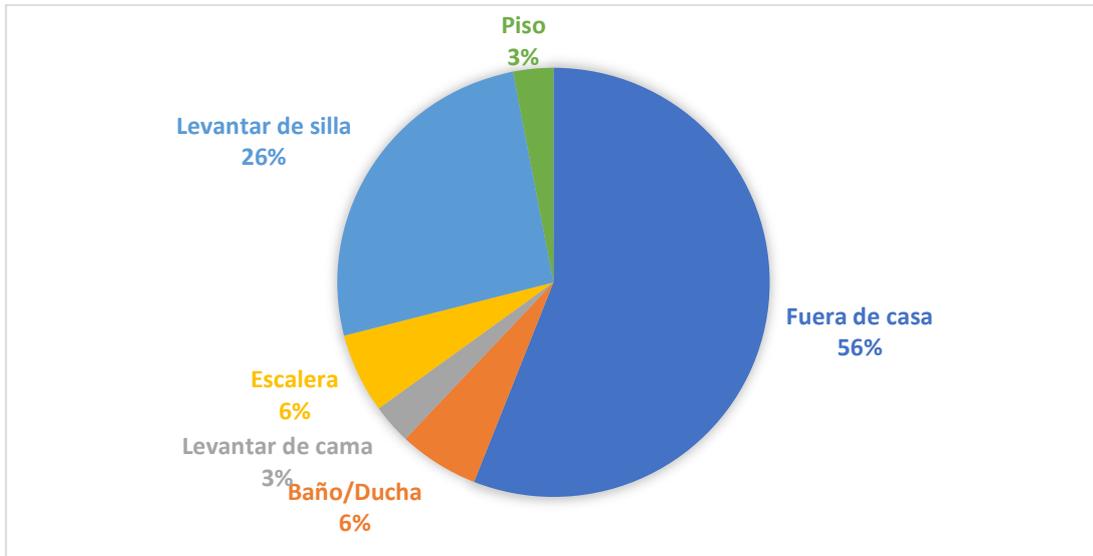
## Capítulo 2.

### Estado del arte.

En los últimos años ha habido un creciente interés en investigación y desarrollo de nuevos métodos de evaluación del movimiento, en mayor medida para el análisis de caminata. Desafortunadamente, debido a sus elevados costos y especificaciones técnicas de espacio, son inviables fuera de los laboratorios experimentales de análisis de caminata y detección de caídas en ancianos. En este estado del arte se revisan los sistemas existentes en este ámbito, detectando sus carencias y sirviendo estas de justificación para las herramientas finalmente utilizadas en nuestra propuesta de solución. De esta manera, se revisan las diferentes técnicas de detección de caídas, como por ejemplo la monitorización del entorno o vía dispositivos portátiles llevados por el individuo. Este estudio servirá para realizar la propuesta de solución.

#### 2.1. El problema de la detección de caídas

La Organización Mundial de la Salud (OMS) define las caídas como “acontecimientos involuntarios que hacen perder el equilibrio y dar con el cuerpo en tierra u otra superficie firme que lo detenga”. [6] Las caídas son un importante problema mundial de salud pública. Según los datos de la OMS se calcula que anualmente se producen 424.000 caídas mortales, convirtiendo las caídas en la segunda causa mundial de muerte por lesiones no intencionales, solo superado traumatismos causados por el tránsito. También indican que más del 80 % de las muertes relacionadas con caídas se registran en países de bajos y medianos ingresos, y más de dos terceras partes de esas muertes se producen en las Regiones del Pacífico Occidental y Asia Sudoriental. De igual manera, los mayores de 60 años presentan las mayores tasas de mortalidad por caídas en todas las regiones del mundo [1]. Junto con la inestabilidad, constituye uno de los grandes síndromes geriátricos. Es una patología muy frecuente en la población anciana, con consecuencias muy importantes y, sin embargo, a menudo se trata de una entidad que pasa inadvertida a los profesionales de la salud. Las razones por las que a menudo no se estudian son: el paciente no suele mencionar que se ha caído, no se pregunta acerca de caídas en la historia clínica, no se producen lesiones directas tras la caída y por qué se atribuye la caída al proceso normal de envejecimiento. Son una de las principales causas de lesiones, incapacidad, institucionalización e incluso de muerte en este grupo de población, y por este motivo se consideran un factor de fragilidad en el anciano.



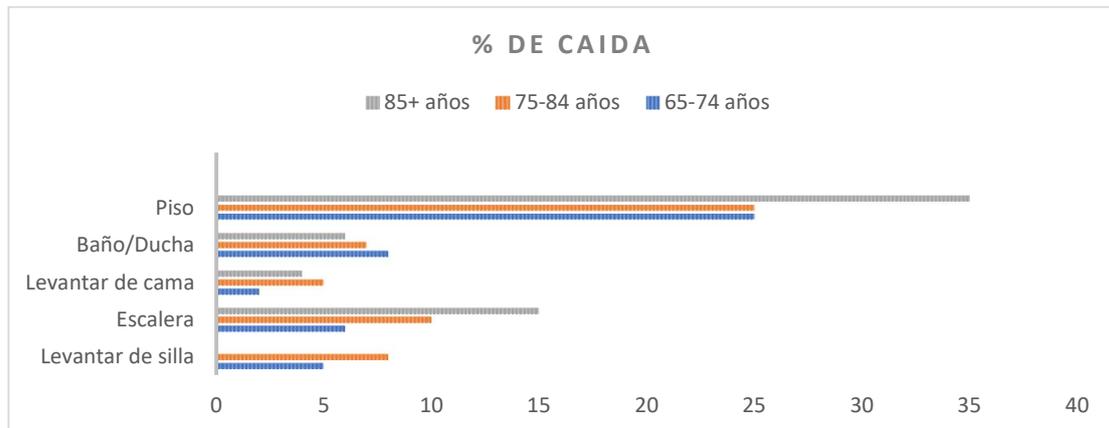
**Figura 2.1:** Localización de caídas - Gráfico de sectores [2]

Las caídas son más frecuentes en las mujeres, aunque conforme avanzan los años, la tendencia es a igualarse con la tasa de caídas en hombres. Es interesante conocer, además, que dos tercios de los ancianos que se caen sufrirán una nueva caída en los siguientes seis meses. Es decir, la caída es un factor de riesgo per sé de sufrir nuevas caídas [7].

La mayoría de las caídas se producen en lugares cerrados, sin encontrar relación con algún momento concreto del día ni época del año. Los lugares más frecuentes de caída son el baño, el dormitorio y la cocina. La actividad que más favorece la caída es caminar. Aproximadamente el 10 % de las caídas se producen en las escaleras, siendo más peligroso el descenso que el ascenso; los primeros y últimos escalones son los más peligrosos, como se hace notable en las figuras 2.1 y 2.2 [2][3].

La magnitud del riesgo puede deberse, al menos en parte, a los trastornos físicos, sensoriales y cognitivos relacionados con el envejecimiento, así como a la falta de adaptación del entorno a las necesidades de la población de edad avanzada.

En algunos estudios también han demostrado que ciertas enfermedades incrementan de manera significativa el número de caídas sufridas por la población anciana, encontrándose entre ellas la diabetes, el Parkinson o el Alzheimer. Por una parte, el padecimiento de diabetes, según este estudio estadístico indica que aumenta en un factor de 1.6 la probabilidad de haber sufrido una caída en el año anterior [8].



**Figura 2.2:** Porcentaje de caídas en interiores y la edad [2]

Por otro lado, la enfermedad del Párkinson provoca que aproximadamente el 38-68 % de los pacientes caiga como una complicación grave de las alteraciones de la marcha, siendo los pacientes avanzados más propensos a caer. Esto viene causado por temblores, rigidez muscular y movimientos lentos, característicos de las personas que sufren esta enfermedad [4].

Respecto al Alzheimer, las personas con esta enfermedad tienen el doble de riesgo de caídas en comparación con los de la misma edad sin ella, pudiendo afectar en ello defectos en la atención y en las habilidades visuales-espaciales. El riesgo también se ve aumentado por la necesidad de deambulación provocada por el Alzheimer, causada por la desorientación, que les provoca inquietud y hace que deambulen a menudo [4].

Las caídas accidentales también tienen un gran impacto en términos de costes para los sistemas sanitarios y para la sociedad. Solo en el Reino Unido, su coste anual para el Sistema Nacional de Salud se ha estimado en £2.300 al año, la aplicación de estrategias preventivas eficaces y la consiguiente reducción de las caídas supondría un ahorro importante anual para Sistema Nacional de Salud y la sociedad.

Los sistemas de detección de caídas existentes abordan esta problemática de distintas maneras, como por ejemplo los basados en entorno que sitúan sensores ambientales que monitorizan el entorno del paciente o los dispositivos portátiles que supervisan la actividad del paciente, detectando variaciones de movimiento y posición.

En este trabajo de tesis la investigación se centrará en los sistemas basados en acelerómetros, como se ha decidido implementar en la propuesta de solución, estudiando también diferentes algoritmos propuestos para la evaluación de la caminata que pudieran emplearse en futuro para el análisis de riesgo y detección de caídas [9].

## 2.2. Trabajos previos

En este trabajo se hace un listado de los primeros estudios de detección de caídas, desde dispositivos que se colocan en forma de cinturón que permiten detectar un impacto, junto con un nivel para detectar la postura, hasta los trabajos que incorporan ya acelerómetros y giroscopos. También se citan varios trabajos basados en técnicas de procesamiento de imagen.

Entre las técnicas para detectar caídas, las más sencillas se basan simplemente en detectar una postura horizontal, siendo esta regla más apropiada para detectar caídas de trabajadores. Con sensores en el suelo se puede determinar además que esa posición horizontal no ocurre en otro sitio, por ejemplo, en la cama. Se señala como distintivo de la caída la inversión del sentido de la aceleración en el momento del impacto. También se nombra brevemente la posibilidad de uso de métodos de reconocimiento de patrones, tales como redes neuronales, entre otros.

Entre los métodos de visión, se citan los que detectan la postura o los que detectan un cambio abrupto. Se destaca también el problema de privacidad asociado al uso de cámaras [10].

## 2.3. Clasificación de sistemas

Tras el estudio de distintos sistemas, se ha considerado que una clasificación correcta que permite una mejor comprensión de los sistemas relacionados con las caídas se basa en el tipo de sensor de los detectores: sensores portátiles, sensores de ambiente y cámaras.

Esta clasificación ha sido repetida por muchos autores. Los dispositivos portátiles pueden capturar la postura o el movimiento durante la caminata; los dispositivos de ambiente pueden detectar la presencia o la postura; mientras que los métodos de visión pueden tratar la detección de inactividad, el cambio de la postura o el seguimiento de la cabeza. Según este esquema, los sistemas emergentes relacionados con las caídas se pueden identificar y clasificar fácilmente. El esquema propuesto es una clasificación basada en tres categorías que se muestra en la tabla 2.1 para revisar, por tanto, todas las ventajas e inconvenientes que tienen.

Clasificación de sistemas	Tipo de dispositivo			
	Sistemas Portátiles	acelerómetro	giroscopio	magnetómetro
Sistemas no vestibles	infrarrojo	Cámara	presión	ultrasónico
Sistema fusión	Smartphone + Acelerómetro			Sensores entorno

**Tabla 2.1:** Clasificación de sistemas [5]

Por tanto, existe una gran variedad de sistemas de detección de caídas, diferenciados por su situación respecto al paciente y el enfoque de la detección de la situación de caída.

### 2.3.1. Tipos de mediciones

Basado en los problemas de clasificación anteriores, se pueden categorizar los dispositivos de acuerdo con las características que miden. El objetivo de esa clasificación es entender mejor el desempeño de varios sensores. En la categoría de sistemas portátiles tenemos acelerómetros, giroscopos y manómetros, que miden aceleración lineal, velocidad angular y variaciones en el campo magnético. También barómetros que nos ayuda a entender cambio de presión debido a los movimientos.

Para la categoría de los sistemas que nos son vestibles como sensores infrarrojos o cámaras y sensores ultrasónico, estos nos miden algunos cambios que necesitan mucho procesamiento para entender y observar los movimientos irregulares.

Tipo de sensores	Mediciones
Acelerómetro	Aceleración, posición, velocidad
Giroscopio	Velocidad angular
Magnetómetro	Orientación
Barómetro	Cambio de presión
Infrarrojo	Movimiento
Cámara	Actividades
Presión	Fuerza, peso
Ultrasónico	Distancia

**Tabla 2.2:** Mediciones [4]

### 2.3.2. Sistemas no vestibles

En este grupo se engloban aquellos sensores que son instalados en el entorno del usuario y monitorizan varios aspectos de su actividad diaria. Se puede establecer una subdivisión según el tipo de sensores que utilizan [11]. Vamos a distinguir, por tanto, tres tipos principales: los que utilizan infrarrojos, piso inteligente y cámaras.

#### 2.3.2.1. Basados en infrarrojos

Este tipo de sistemas de detección de caídas basan su actividad en sensores de infrarrojos. Esta clase de sensores recogen la radiación electromagnética infrarroja que emiten los cuerpos de los seres vivos. Con ello, pretenden conseguir reconocer una imagen del individuo, y según diferentes algoritmos (inactividad, variación de posición, etc.) detectar si la persona ha sufrido una caída o se encuentra realizando su vida normal [12].

Son sistemas fijos, ya que necesitan una lectura de la figura del sujeto para poder reaccionar en consecuencia. Suelen estar dispuestos en puntos de la habitación que ofrezcan una mejor visión del entorno.

Estos sistemas tienen algunos inconvenientes como la detección se basa solo en el movimiento. Podrían no detectarse varios tipos de caídas y generalmente son susceptibles de detectar falsos positivos [13].

#### 2.3.2.2. Basados en cámaras

Se trata de sistemas que utilizan cámaras de video para recopilar la información necesaria para la detección de la caída. Las cámaras proporcionan datos basados en nubes de puntos que delimitan la figura del paciente. Según la información recopilada, tratan el problema de diversas maneras. Hay dos sistemas de este tipo:

##### *Sistema inteligente de detección de caídas basado en visión*

Este tipo de sistema automático utiliza un modelado visual del entorno, el cual separa la silueta del paciente de cualesquiera otras regiones de la estancia. Al analizar las regiones, se obtienen datos de velocidad, área y momento [14].

##### *Sistema de detección de caídas visual basado en el reconocimiento de posturas*

Es utilizado para monitorear las actividades en el hogar de una persona anciana. Usando prácticamente el mismo sistema de antes, se obtiene la diferencia entre el entorno y el sujeto para un proceso posterior de inferencia de caídas. Este tipo de sistemas normalmente construyen gráficas e histogramas con los datos recogidos y se distinguen distintas posturas del paciente. Estos datos se guardan en un grafo dirigido no cíclico para realizar correctamente la clasificación de las posturas. Estos datos combinados con información recogida del suelo son los que marcan si se ha producido o no una caída [15].

Estos sistemas también tienen inconvenientes como los siguientes. Los obstáculos pueden impedir la correcta detección de la caída, se requieren varios sensores en cada estancia de la vivienda para evitar puntos ciegos y pueden poner en riesgo la privacidad de los ancianos que observados constantemente.

El uso de sensores de ambiente evita que el usuario tenga que llevar un dispositivo, lo cual no siempre es cómodo. En particular, los sistemas basados en cámaras permiten detectar con precisión la postura actual del cuerpo humano. Su precio además ha ido decreciendo con los años. Por contra la privacidad es un aspecto muy importante para los usuarios. Además, no se ha establecido todavía un algoritmo válido para la detección confiable de caídas, como lo demuestra el hecho de la constante investigación en este campo. Muchos trabajos necesitan una calibración de las cámaras y la sustracción del fondo es problemática debido a cambios de iluminación, oclusiones de objetos, presencia de múltiples personas, entre otros aspectos, lo que puede impedir su despliegue en un entorno cualquiera. Otra desventaja es que la detección está limitada a un espacio específico dado [16].

### 2.3.3. Sensores instalados en el entorno

Las técnicas de visión por computadora son muy populares en los trabajos de investigación. Los algoritmos de detección de caídas basados en imágenes suelen tener un esquema con varios pasos. En primer lugar, es necesario segmentar a la persona y distinguirla del fondo. Para ello será necesario tener en cuenta algoritmos adaptativos que puedan gestionar cambios de iluminación, oclusiones y sombras. En un segundo paso se ajusta un modelo a la imagen segmentada, que puede ir desde una simple elipse a un modelo de esqueleto. En ocasiones, se incorpora un seguimiento del objeto (persona). Finalmente se extraen una serie de características, como la altura y la anchura del objeto, su orientación, el número de píxeles, la silueta, etc. Muchos son los algoritmos que se utilizan posteriormente para detectar el estado del individuo y determinar la posible caída: entre estos se encuentran los modelos ocultos de Márkov (Hidden Márkov Model, HMM, por sus siglas en inglés) [17], filtros Bayesianos [18], Lógica Difusa [19], Mezclas de Gaussianas [20] en el espacio de las siluetas, etc.

Pero las cámaras no son los únicos sensores que se pueden colocar en un entorno. También se utilizan sensores de vibración instalados en el suelo, junto con sensores infrarrojos pasivos para detectar el movimiento. A menudo se utilizan características en frecuencia, por ejemplo aplicando una transformada wavelet a las señales de los sensores de vibración y posteriormente una fase de clasificación utilizando técnicas de aprendizaje de máquina, como máquinas de soporte vectorial (SVM, por sus siglas en inglés), entre otras. Este conjunto de características-clasificador es superior a otras combinaciones de la transformada de Fourier. Los sensores infrarrojos permiten reducir las falsas alarmas por medio de la detección de inactividad posterior a la caída. Hay una extensión del uso de este tipo de sensores a situaciones en las que hay muchas personas [21].

Además, también se han reportado el uso de señales de radar [22]. Sus características tiempo frecuencia se hacen discretas para luego utilizar un HMM (Hidden Márkov Model, por sus siglas en inglés) en el reconocimiento. También ha habido intentos por utilizar micrófonos para detectar las

caídas. Los problemas asociados más importantes son la detección de la fuente correcta del sonido y la eliminación del ruido.

También en este tipo de sistemas la privacidad es un aspecto importante que en estos tipos de esquemas de detección no se considera. Además, implica maneras de detección que funcionan solo para interiores en ambientes cerrados. Por otro lado, tiene costo elevado y requiere de adecuaciones de infraestructura a las habitaciones.

#### 2.3.4. Sistemas portátiles

En este apartado analizamos los trabajos que reportan el uso de sistemas portátiles. Se engloban todos aquellos en los que el usuario lleva encima el dispositivo de detección. Se ha hecho una distinción en dos grandes grupos: los que usan exclusivamente acelerómetros y en los que hay implicados además otro tipo de sensores. Revisamos varias características que comparten.

##### 2.3.4.1. Sistemas basados en acelerómetros

Los acelerómetros registran el valor de la aceleración, medida en  $g_s$  (1g equivale a  $9.8 \text{ m/s}^2$ , la medida del valor de la gravedad en la Tierra) o directamente en  $\text{m/s}^2$ , proporcionando una señal eléctrica para esta variación física.

Existen dos tipos principales de acelerómetros: mecánicos o piezoeléctricos, según la tecnología empleada para detectar esta variación.

En el mercado se pueden encontrar acelerómetros de diferentes rangos de medida, desde 1g hasta 20000g, dependiendo del máximo valor absoluto que se quiera medir.

También hay diferente oferta según la resolución de la salida, siendo bastante común un valor de 10-13 bits y la sensibilidad de medida, entendida como la precisión o valor mínimo a partir del cual se aprecia variación en la medida.

Otro factor para tener en cuenta es la frecuencia de muestreo, determinante a la hora de monitorizar situaciones complicadas como puede ser en el caso la detección de una caída.

##### 2.4.4.2. Sistemas basados en acelerómetros y otros tipos de sensores

El sistema utiliza un microcontrolador encargado de procesar los datos obtenidos a través de la conexión de los acelerómetros, giroscopios y magnetómetros.

Su funcionamiento se basa en la detección de las variaciones de inclinación detectadas en los tres tipos de sensores.

Estos tipos de sistemas tienen algunas ventajas como, recogida de gran cantidad de datos de diferentes modalidades, generalmente, utilizan un único dispositivo y monitorización constante, además, menor coste que los de monitorización del entorno; por estas ventajas decidimos para usar

estos tipos dispositivos para monitorear y evaluar en la caminata y los movimientos de ancianos [23] [24].

Por otro lado, los trabajos anteriores tienen algunos inconvenientes que en el nuestro propuesto intentamos mejorarlos. Como, el tamaño reducido de los sensores y usar muchos alambres, tamaños. El sistema que trabajamos consta con varios sensores de tamaño reducida (1 cm<sup>2</sup>), que permite colocarlos en varios puntos de cuerpo humano y cuenta con transmisión de datos con conexión inalámbrica.

Los dispositivos portátiles tienen la ventaja de que pueden ser cómodos y fáciles de montar en el cuerpo, pero sobre todo permiten monitoreo continuo y detectar las caídas en cualquier momento y lugar, evitando gran parte de los problemas de privacidad. El precio, en caso de producción masiva, es también bastante asequible. Además, es un sistema más fácilmente desplegable en un caso real, cuyas prestaciones son bastante buenas, normalmente en una posición fija en el cuerpo. Hay incluso estudios que hablan de una o ninguna falsa alarma en periodos de días [25]. En su contra, podemos citar la posibilidad de que la persona olvide o no quiera llevar el dispositivo (o justo en un momento no lo coja, como para ir al baño por la noche) o la limitada capacidad de cálculo de algunos sistemas empotrados.

En los estudios basados en acelerómetros hay varias cuestiones relevantes que merece la pena destacar en cada trabajo: las características técnicas del sensor, rango y frecuencia de muestreo; el sitio en donde se coloca el sensor; los tipos de caídas y el tipo de actividades de la vida diaria (ADL, por sus siglas en inglés) a monitorear, así como el número de ejemplos de cada tipo; el número de voluntarios y si se dispone de datos de mayores o no; y por supuesto la extracción de características y el algoritmo de detección utilizado.

## 2.4. Colocación de los sensores

Los sensores portátiles incluyen sensores de movimiento inercial compactos basados en tecnología MEMS (micro electromechanical systems, por sus siglas en inglés), equipados con acelerómetros, giroscopios y magnetómetros; acelerómetros multiaxiales autónomos. Algunos trabajos han descrito varias ubicaciones óptimas en el cuerpo de los sensores portátiles en diferentes protocolos experimentales, dependiendo de la tarea postural [26].

La tabla 2.3 representa todas las ubicaciones de sensores utilizadas en los trabajos que se han revisado. Todos los sensores portátiles estaban conectados a los sujetos en su cuerpo. Más detalles sobre el tipo y la ubicación de los sensores portátiles utilizados en diferentes artículos, según la revisión presentada en se resumen a continuación [26].

Ubicaciones de sensores	Porcentaje%
Frente	2.1
Pecho	14.9
Espalda superior	4.3
Abdomen	10.6
Pierna	25.5
Espalda baja	42.6

**Tabla 2.3:** Ubicación de los sensores [26]

Diversos estudios, resumidos en [26], han identificado, mediante métodos estadísticos aplicados para el análisis de datos categóricos (grupos y condiciones experimentales) y métricas (temporales y en frecuencia), las combinaciones óptimas de ubicaciones de los sensores según las tareas y categorías de métricas características obtenidas. De forma que:

En general, la métrica característica más eficaz para evaluar el riesgo de caída fue la velocidad con el sensor colocado en las espinillas. Por otro lado, para pararse, la aceleración lineal medida en la zona lumbar fue la combinación más eficaz de colocación de características. De manera similar, durante las pruebas de sentarse y levantarse, la aceleración lineal medida en la parte inferior de la espalda parece ser la combinación de función y ubicación más efectiva.

En uso de sensores inerciales portátiles para la detección y sobre todo la evaluación y predicción del riesgo de caída, presenta por tanto el reto de diseñar y caracterizar nuevas métricas con sensibilidad adecuada, dependiendo de la ubicación del sensor, la tarea a realizar por el individuo y la categoría de características en tiempo-frecuencia a utilizar.

Diversos estudios han explorado las combinaciones óptimas de ubicación del sensor, la tarea y la categoría de características [27]. Los análisis estadísticos de las características reportadas en los estudios preseleccionados revelaron asociaciones positivas significativas, muy fuertes en 3 tríadas diferentes de categoría de característica, tarea y ubicación del sensor:

- Aceleración lineal - Pararse- espalda baja
- Aceleración lineal -levantarse y sentarse- espalda baja
- Velocidad angular - Caminar – Espinillas

Por otro lado, entre las combinaciones óptimas al utilizar sensores inerciales para discriminar entre sujetos caídos y no caídos se encuentran:

- Frecuencia - Caminar - Espalda baja

- Frecuencia - Caminar – espalda superior

## 2.5. Algoritmos para la detección de caídas mediante el uso de acelerómetros

Dentro de los sistemas basados en acelerómetros existen diferentes enfoques a la hora de detectar la caída. La mayoría de las métricas que se proponen en la literatura están basados en medidas globales en tiempo o frecuencias. Las más comunes son:

### 2.5.1. Detección del pico de aceleración

Dentro de los parámetros más comúnmente utilizados en la mayoría de los trabajos reportados en la literatura se encuentran los vectores de la media y el valor máximo de la aceleración. Todo movimiento brusco, entre ellos las caídas, producen cambios transitorios de magnitud pronunciada del orden de doce veces la aceleración de la gravedad (12g) que pueden ser detectadas, justamente, con la magnitud pico del vector de aceleración.

El umbral de la aceleración pico puede ser configurado basado en datos empíricos.

El valor de aceleración más pequeño medido en una caída es de alrededor de 3g, pero usualmente es varios g superior. Las actividades de la vida diaria usualmente no exceden los 3g, pero ocasionalmente puede ser mayor durante algunos movimientos bruscos como saltar, correr y sentarse rápidamente. Ya que existe algún solapamiento para los rangos de aceleración de caídas y ADLs, se requiere otra forma de distinguir las caídas de las actividades de la vida diaria para conseguir un algoritmo más robusto.

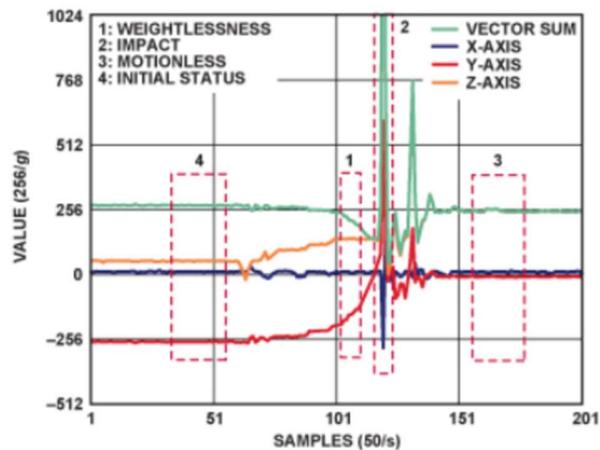
Dado que los eventos de caída son breves, la duración del pico de aceleración también es un parámetro determinante para distinguir una caída de otros eventos. La duración de un pico de aceleración en una caída es del orden de los 30 milisegundos [28].

### 2.5.2. Detección de la colisión

Se puede implementar un sistema de detección de caídas basándose en la colisión, midiendo el valor relativo del incremento de aceleración. Si en un cierto intervalo de tiempo la aceleración aumenta más de una cantidad, se considera colisión. Estos algoritmos lo que hacen es: para los últimos valores (los 20 últimos, por ejemplo) comprueba si el incremento de aceleración es mayor que cierto valor, considerado el umbral de incremento de aceleración [29].

### 2.5.3. Detección de las etapas de la caída

Toma en cuenta los distintos estados de la persona antes, durante y luego de una caída [30]. Estos estados son los que a continuación se describen y que son representados en la figura 2.3:



**Figura2.3:** Etapas de la caída y cambios en la aceleración propuestas [30]

**1. Caída Libre:** Se le ha nombrado caída libre a esta etapa a pesar de que el paciente no tiene un movimiento idéntico al de un cuerpo en caída libre, debido a su dinámica justo antes de caerse o a la resistencia que pueda presentarse contra paredes o suelo durante la caída. Esta etapa hace referencia al momento inicial de toda caída, donde el cuerpo se dirige hacia el suelo experimentando una aceleración vertical semejante a la gravedad. En esta etapa la suma vectorial de las aceleraciones disminuye de 1g hasta 0 g.

**2. Impacto:** Después de la etapa de Caída Libre, el cuerpo choca con el suelo u otros objetos, dando como respuesta un elevado pico entre 2g y 12g en la suma de los tres ejes debido a la elevada desaceleración del cuerpo.

**3. Reposo:** Tras un impacto, un cuerpo se mantiene en reposo durante un tiempo. Este tiempo puede ser muy elevado si el paciente se encuentra inconsciente, pero normalmente es menor a 10s.

**4. Posición Horizontal:** Tras una caída, el cuerpo queda en una posición diferente a la inicial.

## 2.6. Parámetros de detección

Hay varios parámetros para evaluar el equilibrio a partir de las señales adquiridas a través de los sensores portátiles.

En la tabla 2.4 se proporciona un resumen y una breve descripción de los parámetros de la balanza utilizados en al menos dos artículos.

Medida de equilibrio (Aceleración, velocidad, desplazamiento)	Dominio	definición de medida
Rango	Tiempo	Rango de señales de aceleración en direcciones AP y / o ML y/o COM ( $m / s^2$ )
Media cuadrática (RMS)	Tiempo	RMS de las aceleraciones y desplazamientos en AP y / o ML direcciones ( $m / s^2$ )
Distancia media	Tiempo	Distancia media desde el centro de la trayectoria de aceleración normalizada con respecto a la duración de la medición ( $m / s^2$ ) y Distancia media desde el centro de COM (mm)
Índice de sacudidas (JI)	Tiempo	Función de la derivada temporal de la aceleración: es un índice de suavidad de balanceo ( $m^2 / s^5$ ).
F95	Frecuencia	Frecuencia que contiene el 95% de la potencia total (Hz)
Dispersión de frecuencia (FD)	Frecuencia	Medida de la variabilidad del contenido de frecuencia de la densidad espectral de potencia
Frecuencia centroidal (CF)	Frecuencia	Frecuencia a la que se concentra la masa espectral: la potencia de las señales de aceleración por encima y por debajo de CF están exactamente equilibradas (Hz).

AP: dirección anteroposterior; COM: Centro de masa; ML: Dirección medio lateral.

**Tabla 2.4:** Resumen y breve descripción de los principales parámetros de balance [26]

De acuerdo con los trabajos que revisamos, hicimos una estimación de la frecuencia con la que los diferentes parámetros se reportan. Calculamos que de los trabajos que reportan técnicas de detección de caídas, el 42% utiliza el valor de la media cuadrática (RMS) de la señal de aceleración como parámetro discriminante para detección o no de la caída, el 18% el rango de amplitud de la señal, el 17% la distancia del paso, el 11% la dispersión de la frecuencia observada (FD, por sus siglas en inglés), el 10% la frecuencia media o centroide (CF, por sus siglas en inglés), 2% el otros parámetros.

Por eso entendemos que la mayoría de estos trabajos se enfocan más en los parámetros de tiempo, mientras tanto que hay podría haber muchas más informaciones valiosa en parámetros de la frecuencia, pudiendo estos dar mejor mejores características para nuestra análisis [26].

Por lo tanto, en nuestro trabajo intentamos analizar en el dominio de frecuencia para aprovechar las informaciones valiosas que un enfoque de análisis en frecuencia podría proporcionar.

## 2.7. Técnicas de procesamiento de señales

Las técnicas de procesamiento de datos de caída dependen de los parámetros extraídos de los sensores. Los sistemas vestibles, no vestibles y de fusión pueden beneficiarse de las técnicas que utilizan métodos analíticos combinados con redes neuronales artificiales (ANN, por sus siglas en inglés) o métodos de aprendizaje de máquina (ML, por sus siglas en inglés), como se resume en la siguiente tabla.

Clasificaciones de Técnicas	Técnicas de procesamiento de datos	Sistema vestible	Sistema no vestible	Sistema de fusión
<b>ANN</b>	Umbralización ( Thresholding o TH)	✓	✓	✓
	Lógica difusa		✓	✓
	Transformada de Wavelet (WT)	✓	✓	✓
	Transformada de Fourier (FFT)	✓	✓	✓
	Modelo oculta de Márkov (Hidden Márkov Models o HMM)		✓	✓
<b>ML</b>	Máquinas de soporte vectorial (SVM)	✓	✓	✓
	Redes neuronales	✓	✓	✓
	K vecinos más cercanos (KNN)	✓	✓	

**Tabla 2.5:** Técnicas de procesamiento de datos

### 2.7.1. Métodos analíticos

Los métodos analíticos se basan en técnicas tradicionales que utilizan modelos estadísticos para obtener interpretaciones de los datos para la predicción (por ejemplo, regresión lineal, análisis de series de tiempo, transformaciones, etc.). Entre estos métodos se encuentran las técnicas de Umbralización (TH, por sus siglas en inglés), es decir, si se informa una caída cuando se detectan picos (impacto de caída), valles u otras características de forma en las señales de datos. Tales métodos se utilizan comúnmente en detectores de caídas portátiles con sensores inerciales para distinguir entre la postura quieta (inactividad) y los patrones de movimiento básicos (actividad). Los sistemas basados en el ambiente utilizan técnicas de detección de eventos a través de datos vibratorios que pueden ser útiles para la monitorización, seguimiento y localización.

Los sistemas basados en cámaras utilizan técnicas de procesamiento de imágenes que extraen características espaciotemporales (por ejemplo, relación entre la altura de la silueta, el peso, la orientación del eje principal del cuerpo, el ancho, el color de la piel) para identificar la postura acostada o de pie en la escena. Otras técnicas de procesamiento de imágenes utilizan el análisis vectorial para detectar movimientos bruscos. Por lo tanto, se pueden adoptar varias estrategias analíticas para clasificar la caída de los eventos que no lo son [31].

### 2.7.2. Métodos de aprendizaje automático

Los métodos de aprendizaje de máquina o automático se basan en algoritmos complejos para obtener información detallada sobre los datos para predecir las decisiones de salida. A partir de la observación y luego la clasificación, los detectores de caídas portátiles, ambientales y de cámara pueden beneficiarse de técnicas como máquinas de soporte vectorial o Support Vector Machines (SVM, por sus siglas en inglés), Reagrupación de optimización del enjambre de partículas, Distribución gaussiana de conocimientos agrupados, Perceptrón multicapa, Bayes ingenuo, Árboles de decisión, ZeroR y OneR para obtener información sobre los datos para detectar caídas [31].

Se puede ver claramente que en parte, la mayoría de las técnicas para analizar caídas y riesgo de caídas, hay una ausencia de técnicas de análisis en el dominio tiempo-frecuencia en los trabajos anteriores. Con esa motivación, en este trabajo de tesis elegimos explorar el uso de la transformada Hilbert-Huang (HHT, por sus siglas en inglés). Principalmente porque las señales de acelerometría generadas por los sensores inerciales, son bio-señales que con el pasar de tiempo se cambia el carácter de las señales a no-estacionarias, debido a la complejidad de los movimientos humanos durante la caminata y el equilibrio en posición erguida, que es muy importante estudiar.

## 2.8. Resumen del estado del arte

La detección de caídas ha atraído el interés de muchos investigadores, interés que todavía existe con numerosos estudios publicados en los últimos años. Si bien es cierto que existen numerosos trabajos en el campo de la Visión por Computador, no parece que se haya dado con la solución definitiva y las pruebas realizadas suelen ser con menos ejemplos y menos reproducibles en comparación con los trabajos basados en sistemas portátiles, que han recibido un nuevo impulso con la llegada de las nuevas tecnologías. Centrándonos en trabajos que utilizan al menos un acelerómetro, hemos visto que los primeros estudios se basaban en detección de umbrales, tras los cuales muchos otros autores han seguido este camino. En algunos casos se tiene en cuenta también la orientación, bien directamente, bien midiendo su cambio. En otros casos, se detecta un periodo de inactividad para confirmar la caída. Otras características que se han utilizado han sido la velocidad, o la distancia recorrida.

Con el tiempo han ido apareciendo otros trabajos que utilizan técnicas de Reconocimiento de Patrones más sofisticadas: redes neuronales, SVM, o k-vecino más cercano, entre otras. En estos casos los umbrales se utilizan sobre todo como una condición a priori, que desencadena el paso de información a un clasificador de alto nivel. En se compara de redes neuronales con varios algoritmos de umbrales, quedando claramente las redes neuronales como vencedoras.

Las caídas son casi siempre simuladas por personas jóvenes o maduras. Algunos estudios tienen unas pocas personas mayores de 65 años, pero no se hace un estudio específico. En cuanto a las actividades de la vida diaria (ADL, por sus siglas en inglés), la mayoría son simuladas, pero es más importante algunos datos obtenidos en movimiento libre.

En definitiva, y al margen de que los trabajos citados en los párrafos anteriores son posteriores al inicio de nuestra investigación, podemos concluir que todavía es necesario hacer un esfuerzo hacia el objetivo final: a largo plazo sería desarrollar un detector de caídas robusto, fiable, aceptado y probado con usuarios reales, en primera instancia, y en segunda, un predictor de riesgo de caída antes de que esta suceda. Nos hemos centrado en dispositivos portátiles. Obteniendo unas prestaciones igualmente buenas en diferentes condiciones, probando con datos de caídas reales, si es posible de población mayor, mejorando la reproducibilidad de las investigaciones, además enfocará en las características en el dominio tiempo-frecuencia.

## Capítulo 3.

### Metodología

#### 3.1. Metodología de Transformada Hilbert Huang (THH)

En 1998, N. E Huang presentó una metodología que combina el Método Empírico de Descomposición (EMD por sus siglas en inglés) con la transformada de Hilbert para analizar señales no periódicas y no lineales. Básicamente, el método consiste en descomponer la señal original en varias FMI, más un residuo. A cada una de estas FMI se le aplica la transformada de Hilbert y se obtiene el espectro de Hilbert. En investigaciones posteriores, a esta metodología se le llamó Transformada Hilbert Huang (THH, por sus siglas en inglés). Dicha técnica ha sido utilizada ampliamente para analizar señales sísmicas, voz, oscilaciones en sistemas eléctricos de potencia.

En las secciones siguientes se define la función intrínseca, se detalla el método empírico de descomposición y se presenta la transformada Hilbert.

##### 3.1.1. Función de Modo Intrínseco

Huang presentó la siguiente definición de IMF (por sus siglas en inglés): Una función de modo intrínseco es una función que satisface las siguientes dos condiciones:

1. en un conjunto completo de datos, el número de valores extremos y de cruces por cero son iguales o cuando mucho difieren por uno;
2. en cualquier punto, el valor medio de la envolvente definida por los máximos locales y la envolvente definida por los mínimos es cero [32];

El nombre de “**función de modo intrínseco**” se debe a que cada función representa un modo de oscilación contenido en los datos. En consecuencia, idóneamente, una señal tendrá tantas IMF como modos de oscilación tenga. Para extraer las IMF de una señal se utiliza el método empírico de descomposición.

### 3.1.2. Método Empírico de Descomposición

El método empírico de descomposición es una técnica intuitiva, directa y adaptiva que se utiliza para analizar series de datos no lineales y no estacionarios. Esta descomposición asume que cualquier serie de datos está compuesta de diferentes modos de oscilaciones simples, es decir IMF. Esto es muy parecido a la descomposición de armónicos de Fourier. Sin embargo, la diferencia radica en que una IMF puede tener amplitud variable y su frecuencia puede estar en función del tiempo [33].

Para extraer las IMF de una señal se sigue un proceso iterativo, el cual consistente en los siguientes seis pasos:

1. Identificar los valores máximos y mínimos de la señal  $x_k(t)$ .
2. Construir la envolvente superior  $x_{up,k}(t)$  e inferior  $x_{low,k}(t)$  mediante ajuste de curvas cúbico, utilizando, respectivamente, como base los valores máximos y mínimos de la señal.
3. Calcular el promedio punto a punto de las envolventes.

$$m_k(t) = \frac{x_{up,k}(t) + x_{low,k}(t)}{2} \quad (3.1)$$

4. Restar a los datos originales el promedio de las envolventes.

$$d_k(t) = x_k(t) - m_k(t) \quad (3.2)$$

5. Verificar el cumplimiento del criterio de paro.

$$SC = \frac{\sum_{t=0}^T |d_{k-1}(t) - d_k(t)|^2}{\sum_{t=0}^T d_{k-1}^2(t)} \leq 0.3 \quad (3.3)$$

- Si el criterio de paro se cumple, entonces  $d_k(t)$  cumple con las dos condiciones que definen una FMI. Se toma  $d_k(t)$  como una IMF y se sustituye  $x_{k+1}(t)$  por el residuo  $r_k(t)$  calculado como:

$$r_k(t) = x_k(t) - d_k(t) \quad (3.4)$$

- Si el criterio de paro no se cumple, entonces  $d_k(t)$  no cumple con las condiciones que define una IMF. Se reemplaza  $x_k(t)$  por  $d_k(t)$ .

6. Repetir los pasos del 1 al 5 hasta que se cumpla con el criterio de paro. Cuando el residuo es una función monótona o tiene un solo valor extremo se detiene el algoritmo, el último residuo es la tendencia global de la señal analizada. Con las IMF y el residuo se puede reconstruir la señal como:

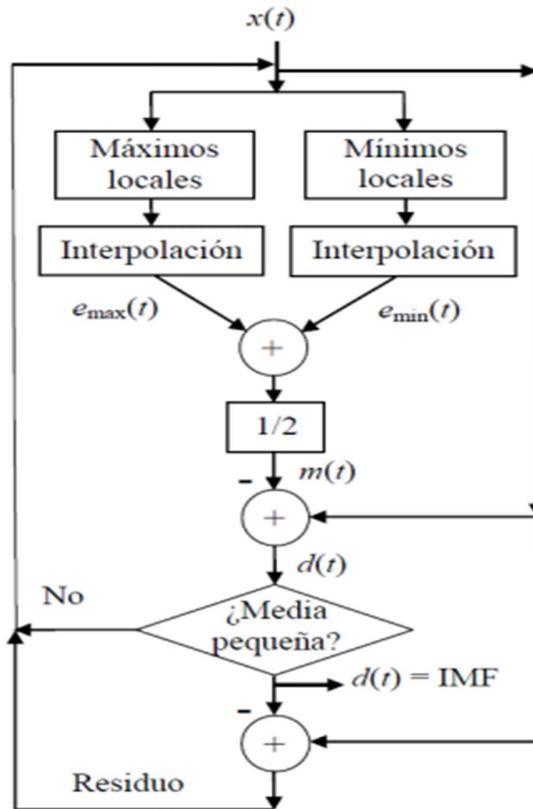
$$x(t) = \sum_{i=1}^n d_i(t) + r_n(t) \quad (3.5)$$

Donde  $n$  es el número de IMFs,  $r_n(t)$  es el residuo final que puede ser una constante o la moda de la serie, y las funciones  $d_i(t)$  son casi ortogonales entre sí, y todas tienen valor medio cero. Aunque esta representación es completa, no es totalmente ortogonal y no puede ser mostrado analíticamente. Sin embargo, la construcción de las IMF por medio de la resta de la señal y la media de los contornos superior e inferior asegura que los componentes son localmente ortogonales entre sí, y cualquier discrepancia es pequeña, por lo que este método puede ser considerado una proyección ortogonal [32].

Por la naturaleza de esta descomposición, este método divide la señal adaptivamente en  $N$  componentes fundamentales cada uno con una escala de tiempo diferente. De tal modo que los primeros componentes corresponden a las escalas de tiempo más pequeñas donde se concentran los cambios rápidos de la señal, equivalente a tener una ventana angosta en un análisis con la STFT.

Una de las ventajas de esta descomposición es que depende completamente de las características locales de la señal, por lo que este análisis es adaptativo e ideal para el análisis de señales no lineales y no estacionarias [34].

Para completar la THH, se le debe aplicar la transformada de Hilbert a cada una de las IMF.



**Figura 3.1:** Algoritmo del Método de Descomposición Empírica en Modos

### 3.1.3. Transformada de Hilbert

La transformada de Hilbert definida por:

$$y(t) = H[x(t)] = \frac{1}{\pi} VPC \int_{-\infty}^{\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (3.6)$$

donde VPC es el valor principal de Cauchy.

Con esta definición es posible expresar  $x(t)$  de forma fasorial, de tal forma que podemos tener una señal analítica. Una señal analítica es una señal compleja que tiene representación en el espectro de la frecuencia en un solo cuadrante correspondiente a las frecuencias positivas, y que además conserva toda la información de la señal original. Esta representación de la señal original en una señal analítica elimina la redundancia de información contenida en las frecuencias negativas del espectro. La parte real de una señal analítica es la serie temporal original, mientras que la parte imaginaria es la transformada de Hilbert.

Es la parte imaginaria de la señal de valor real  $x(t)$  Así, al tener la parte real e imaginaria, se puede definir la señal analítica:

$$z(t) = x(t) + iy(t) = a(t)e^{i\theta(t)} \quad (3.7)$$

donde  $a(t)$  es la amplitud instantánea definida como:

$$a(t) = \sqrt{x^2(t) + y^2(t)} \quad (3.8)$$

y  $\theta(t)$  es la función de fase definida como:

$$\theta(t) = \arctan\left(\frac{y(t)}{x(t)}\right) \quad (3.9)$$

Derivando  $\theta(t)$  con respecto al tiempo, se obtiene la frecuencia instantánea  $\omega(t)$ :

$$\omega(t) = \frac{d\theta(t)}{dt} \quad (3.10)$$

### 3.2. El espectro de Hilbert

Después de que una señal en el dominio del tiempo ha sido descompuesta donde  $a(t)$  es la amplitud instantánea,  $\theta(t)$  es la fase instantánea y  $\omega(t)$  es la frecuencia instantánea. Finalmente combinando la amplitud y la frecuencia instantánea es posible obtener la representación tiempo, frecuencia y amplitud de la señal original. la serie puede ser expresada como:

$$x(t) = \text{Re} \left\{ \sum_{j=1}^n a_j(t) e^{i \int \omega_j(t) dt} \right\} \quad (3.11)$$

Aquí el residuo  $r_n(t)$  es dejado aparte por ser o una función monótona decreciente o la moda de los datos. A pesar de que la transformada de Hilbert puede manejar la tendencia monótona como parte

de una oscilación larga, la energía involucrada en el residuo representa un promedio que podría ser sobrevaluado.

### 3.3. Descripción la base de datos

#### 3.3.1. Descripción de los Pruebas

La mayoría de los trabajos anteriores no se prueban con la población objetivo (personas mayores), lo que reduce su precisión en aplicaciones de la vida real. Además, todos los conjuntos de datos de otros trabajos contienen exclusivamente datos de adultos jóvenes, lo que dificulta la prueba de nuevas propuestas [35]. Para este trabajo utilizamos una base de datos pública disponible para estudios de caída [36], construida por la Universidad de Antioquia (Medellín, Colombia) para registrar las actividades en aulas y espacios abiertos de la universidad. El tiempo necesario para registrar todos los ensayos fue de aprox. 1,5 h por cada anciano y 3,5 h por cada joven.

De la base de datos elegimos la información de tres tipos de caminata adquiridas con un dispositivo portátil (sensores IMUs) y estudiamos los resultados de algunas de las funciones de detección más utilizadas tanto en personas jóvenes como en personas mayores. El propósito de este trabajo es analizar el campo de evaluación movimientos y cambios, y abordar dos temas abiertos que rara vez se discuten: entrenamiento con funciones para jóvenes destinadas a personas mayores y la evaluación de algoritmos de análisis de tiempo-frecuencia que puedan detectar diferencias entre diferentes tareas de caminata y grupos de jóvenes contra ancianos.

La relevancia de estos métodos de evaluación de caminata es que pueden ser utilizados como técnicas de evaluación de riesgo de caídas. Pues, como se reporta en algunos estudios a través de encuestas, los ancianos independientes se caen más al caminar, ducharse y subir o bajar escaleras; y caer menos al intentar levantarse o sentarse en una silla o una cama, o agacharse. Por otro lado, las personas mayores que viven en residencias de ancianos se caen más al caminar y al intentar levantarse de una silla o de una cama y se caen menos al subir o bajar escaleras [37].

Las pruebas de caminatas vienen en la tabla 3.1. Se seleccionaron en función de: movimientos comunes, actividades que son similares (en forma de onda de aceleración) a actividades con alta aceleración que pueden generar falsos positivos. Todas las tareas seleccionadas para este trabajo fueron aprobadas por unos médicos especialistas en geriatría y fisioterapia. Los Materiales Suplementarios reportados por los autores de la base de datos, contienen videos de cada tipo de caminata realizadas por los participantes [36].

Código	Actividades	Prueba	Duración
D01	Caminata Lenta	Uno	100 s
D02	Caminata Rápida	Uno	100 s
D03	Trotando	Uno	100 s

**Tabla3.1:** Tipos de actividades de la vida diaria seleccionadas para este trabajo.

### 3.3.2. Descripción de los Participantes

Esta base de datos se generó con la colaboración de 38 voluntarios divididos en dos grupos: personas mayores y adultos jóvenes. El grupo de ancianos estuvo formado por 15 participantes (8 hombres y 7 mujeres), y el grupo de adultos jóvenes estuvo formado por 23 participantes (11 hombres y 12 mujeres). La tabla 3.2 muestra la edad, el peso y la altura de cada grupo [36].

Todos estaban sanos e independientes, y ninguno presentaba problemas de marcha.

Participantes		Sexo	Edad	Altura (m)	Peso (kg)
<b>Anciano</b>	7	Mujer	62-75	1.50-1.69	50-72
	8	Hombre	60-71	1.63-1.71	56-102
<b>Adulto</b>	12	Mujer	19-30	1.49-1.69	42-63
	11	Hombre	19-30	1.65-1.83	58-81

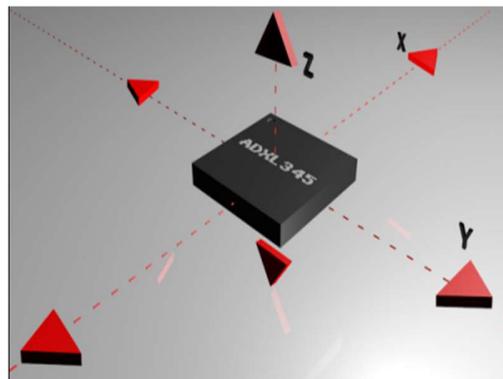
**Tabla3.2:** Perfil de los participantes

Todos los sujetos dieron su consentimiento informado para su inclusión antes de participar en el estudio. Todos los participantes fueron evaluados por un médico especialista en deportes.

## 3.4. Descripción de dispositivo

### 3.4.1. Sensores inerciales

Los Sensores Inerciales IMU (Inertial Measuring Unit, por sus siglas en inglés) miden la variación de rotación (giróscopos) y la aceleración lineal (acelerómetros). Un giróscopo de 3 ejes es un dispositivo inercial para detectar la rotación en el espacio 3D mediante la medición del ángulo de giro, pero tiene un problema inherente de deriva progresiva y ello limita su uso independiente. Para combatirlo, se puede usar de forma complementaria un acelerómetro de 3 ejes. El acelerómetro funciona basándose en la segunda ley de Newton; en condiciones de equilibrio o casi equilibrio, la salida puede ser aproximada a la gravedad, por lo que es posible usar un acelerómetro para la estimación de la inclinación [38].



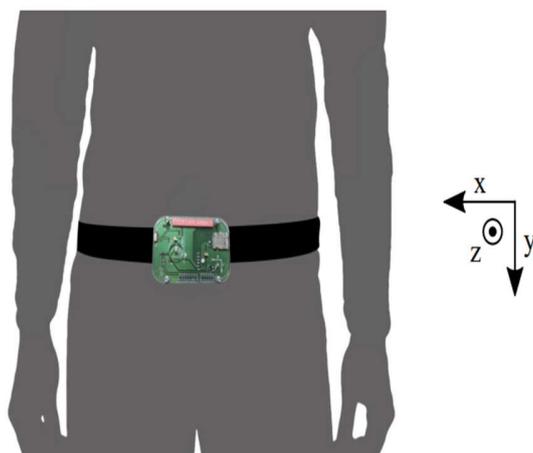
**Figura 3.2:** Sensor ADXL345 con referencia de la orientación de sus ejes y sentido de giro

Este sistema se puede utilizar en aplicaciones de rehabilitación, ciencias del deporte, animación cine y videojuegos, biomédica y ergonomía. También hay aplicaciones militares para simuladores de realidad virtual que utilizan soldados como entrenamiento. Otras aplicaciones son ya industriales para valorar el movimiento, aceleración y velocidad de vehículos, robots industriales y otros. Existen también sistemas de rehabilitación basados en IMUs, como el Riablo de CoRehab, el cual utiliza sensores de inercia para evaluar el ángulo de la rodilla y la inclinación del tórax [39].

Una ventaja de estos sistemas es que son dispositivos portátiles, ya que se pueden usar independientemente de la ubicación del usuario. Los dispositivos portátiles disponibles incluyen sistemas de desarrollo propio. En estos casos, el sensor preferido es el acelerómetro triaxial debido a su bajo costo, pequeño tamaño e incluyen un hardware robusto, un procesador potente y son económicamente asequibles [4].

### 3.4.2. Configuración experimental

El conjunto de datos se registró con un dispositivo integrado compuesto por un microcontrolador Kinets MKL25Z128VLK4 (NPX, Austin, Texas, EE. UU.), Un acelerómetro ADXL345 de Analog Devices (Norwood, Massachusetts, EE. UU.) (Configurado para  $\pm 16$  g, 13 bits de analógico a convertidor digital –ADC), un acelerómetro Freescale MMA8451Q ( $\pm 8$  g, 14 bits de ADC), un giroscopio ITG3200 ( $\pm 2000^\circ / s$ , 16 bits de ADC. Texas Instruments, Dallas, Texas, EE. UU.), una tarjeta SD para grabación y una batería genérica de 1000 mA / h. El dispositivo se fijó a la cintura de los participantes (Figura 1). Esta ubicación proporciona una gran distinción entre las actividades de un solo sistema de acelerómetro [40].



**Figura 3.3:** Dispositivo utilizado para la adquisición. El dispositivo integrado de desarrollo propio incluía dos acelerómetros y un giroscopio. Se fijó a la cintura de los participantes [36]

En este trabajo solo se utilizaron los datos de aceleración adquiridos con el sensor ADXL345, ya que es energéticamente eficiente y proporciona un intervalo más amplio. Sin embargo, los datos registrados con el otro acelerómetro y el giroscopio también están disponibles públicamente para estudios posteriores. La orientación del sensor (ver Figura 3.2) presenta el eje z positivo en la dirección de avance, el eje y positivo en la dirección de la gravedad y el eje x positivo apuntando hacia el lado derecho del participante. Todas las pruebas se realizaron con la muestra de frecuencia original de 200 Hz.

### 3.5. Descripción del análisis

Una vez se ha conseguido tener la señal de acelerómetro separados de tres ejes, es común emplear técnicas analíticas cuantitativas para evaluar sus características únicas de los movimientos. Hay que estudiar las características como la amplitud, fases y la frecuencia; sin embargo, el requerir la intervención subjetiva del experto para evaluar estas características.

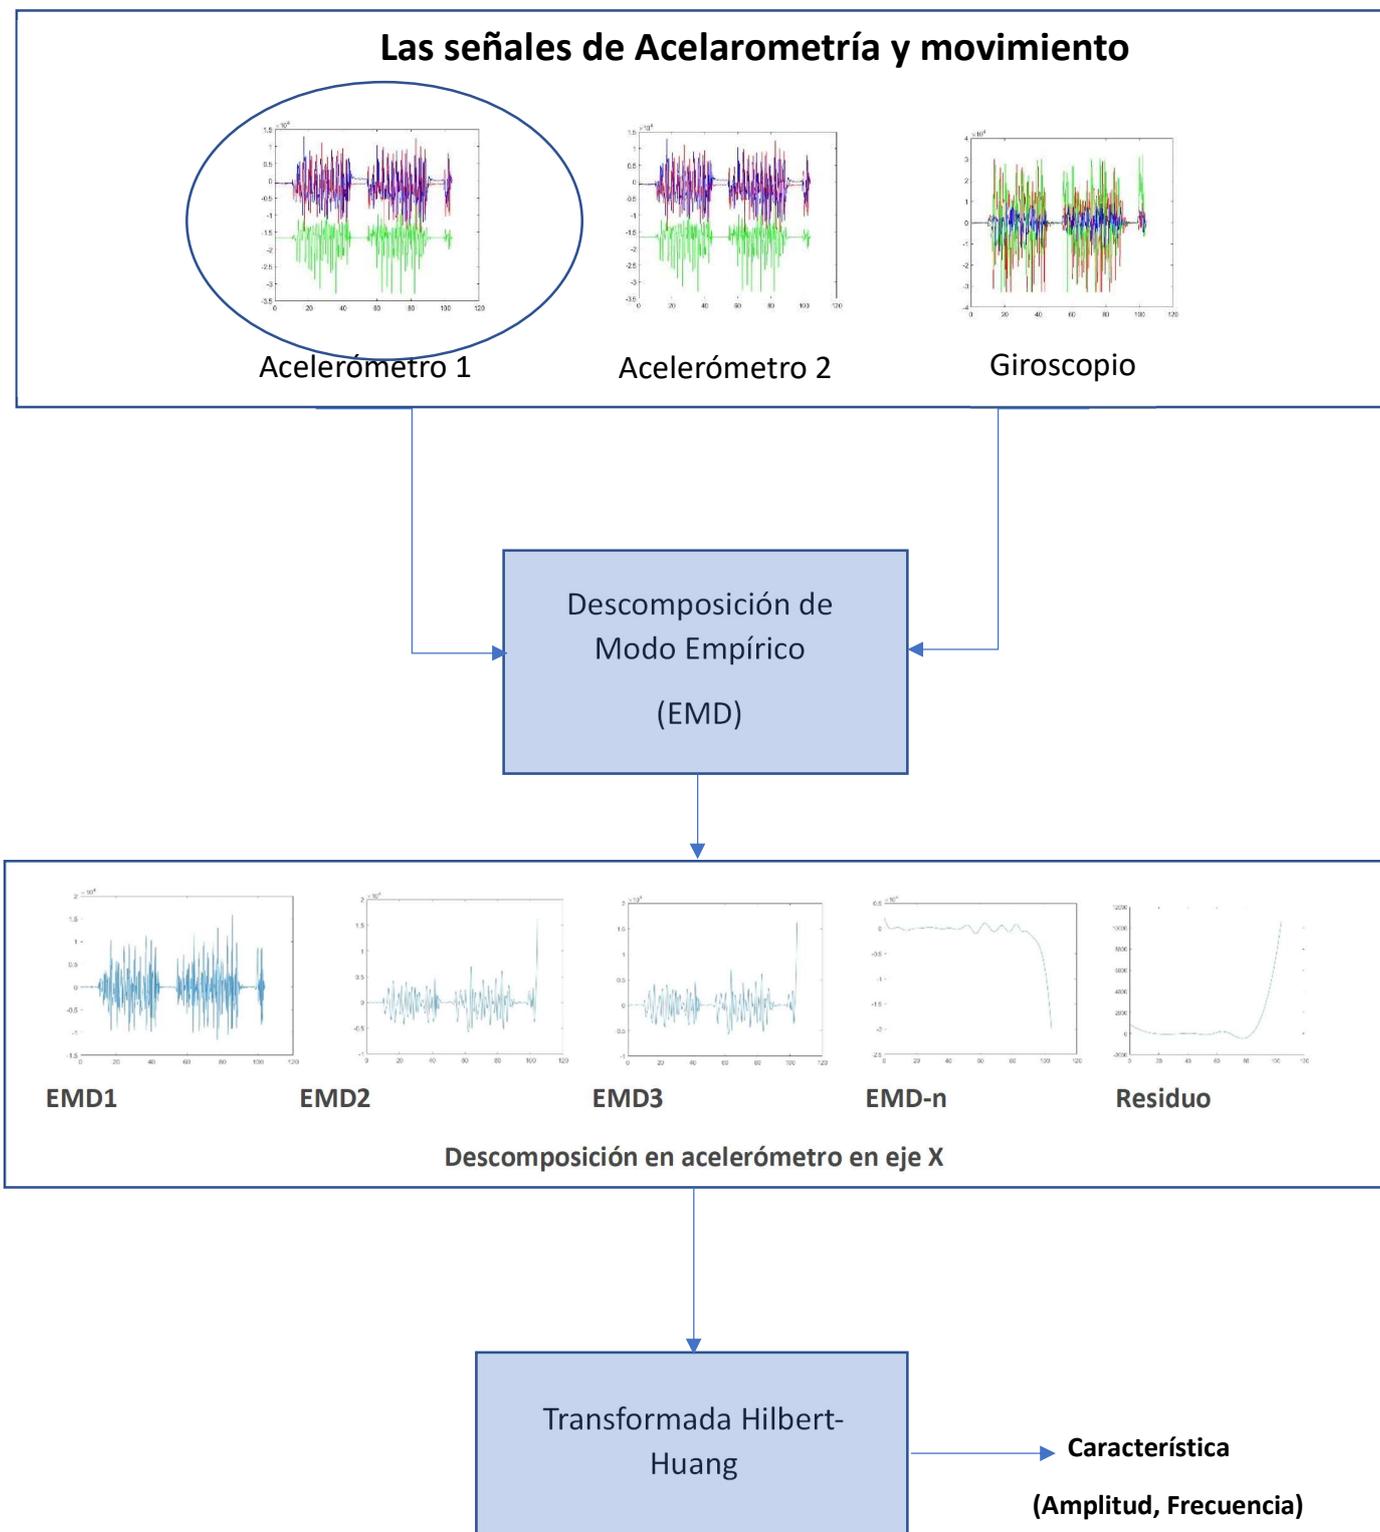
Entre estas técnicas se destacan como pioneras las basadas en análisis temporal por su sencillez y facilidad de evaluación, debido a que no requieren ningún tipo de transformación de la señal. También están las basadas en análisis espectral, para las cuales se requiere de la transformación de la señal, como la transformada de Fourier de tiempo corto (STFT short time Fourier transform, por sus siglas en inglés) con la cual se obtiene información de la señal en el dominio tiempo-frecuencia [41]; sin embargo, esta técnica asume la condición de estacionariedad en la señal, lo cual es contradictorio a la naturaleza de los bioseñales como señales del movimiento de los sensores. A pesar de reportar resultados con un desempeño bueno, su naturaleza estocástica no estacionaria ha hecho necesario explorar técnicas alternativas que ayuden a mejorar el proceso de extracción de métricas en señales no lineales y no estacionarias, como las de acelerometría durante la caminata humana.

Una solución a este inconveniente se refleja en los últimos trabajos de investigación en el área de procesamiento de señales con la técnica de análisis espectral basada en la "teoría de wavelets", mediante las transformadas wavelets: DTW (Discrete Wavelet Transform, por sus siglas en inglés) y WPT (Wavelet Packet Transform, por sus siglas en inglés). Con esta técnica se consigue una representación de la señal en los dominios tiempo-frecuencia mucho más compacta que la conseguida por transformada de Fourier STFT, puesto que permite disponer de información de la señal en sus dominios de tiempo y frecuencia de manera simultánea [42]. El principal inconveniente de esta herramienta reside en la selección a priori de algunos parámetros como las funciones base predeterminadas (wavelet madre) y el nivel de descomposición. Por lo tanto, se pretende usar una técnica reciente, adecuada para el análisis de señales no estacionarias y no lineales, denominada la Descomposición Empírica de Modos [32]. Este análisis permite la extracción de las oscilaciones embebidas que se producen en las señales EMG. El uso de esta técnica reporta resultados iguales y en algunos casos superiores a los obtenidos con las técnicas anteriores [41][42][32][43][44].

### 3.5.1. Descomposición de las señales y extracción de características por Transformada Hilbert-Huang

Para la descomposición de las señales y extracción de características seguimos los siguientes pasos:

1. Elegir señales de acelerometría de tres ejes X, Y, Z, del base de datos de cada prueba y de cada sujeto.
2. Cada tarea es de 100 segundos, dividimos a 5 etapas de 20 segundos para facilitar el análisis.
3. El siguiente paso para aplicar la transformación de Hilbert-Huang es la descomposición en modo empírico (EMD, por sus siglas en inglés). La Descomposición Empírica de Modos (Empirical Mode Descomposición, EMD), es un método adaptativo para el análisis de señales no lineales y no estacionarias, cuyo objetivo es descomponer la señal multicomponente en un conjunto finito de componentes oscilantes modulados en frecuencia y amplitud, denominados funciones de modo intrínseco (FMI). Cada FMI debe cumplir con las siguientes condiciones:
  - (a) La cantidad de puntos extremos (máximos y mínimos) y la cantidad de cruces por cero deben ser iguales o diferir a lo sumo en uno;
  - (b) La media local, definida como el valor medio de las envolventes superior e inferior, debe ser nula para todo punto. Esto implica que el valor medio de cada FMI es cero. A su vez EMD es auto adaptativo porque los FMI, que funcionan como funciones básicas, están determinados por la señal en sí. Por lo que este método no requiere ningún conocimiento a priori de la señal y evita la suposición sobre la estacionariedad y linealidad de las señales [41].



**Figura3.4:** Diagrama descomposición de las señales y extracción de características por Transformada Hilbert-Huang

4. A continuación de la HHT es la transformación de Hilbert. Después del paso de descomposición, los IMFs (función de modo intrínseco) se envían a este proceso, que se define como la parte de 3.1.3 de la tesis.
5. Sacar características de las señales procesadas en tiempo-frecuencia.

### 3.6. Extracción de características tiempo-frecuencia

La señal del acelerómetro de los sensores descompuesta generalmente presenta información redundante por mucho movimiento del cuerpo y el ruido del ambiente, por lo que obtener información directamente de la misma no es la opción óptima para la interpretación (y clasificación) de estas señales. En esta sección, el objetivo es extraer un conjunto de características relevantes de la señal que permitan representar una señal a partir de un conjunto de características determinantes e importantes para estudiar diferentes patrones de caminata entre jóvenes y ancianos. La extracción de características consiste en obtener información relevante de la señal del acelerómetro de los sensores descompuesta y relacionarla con los movimientos. Estas características pueden ser obtenidas en el dominio del tiempo y en el dominio de la frecuencia mediante una transformación de los datos originales, formando así un vector de características tiempo-frecuencia.

Las características en el dominio del tiempo son las más populares en aplicaciones de tiempo real [48], esto se debe a que no se necesita hacer transformación alguna de los datos. Se basan simplemente en la amplitud de la señal, forma de onda y algunas características que se relacionan con la frecuencia. A continuación, se describe la característica más común que se puede extraer del dominio del tiempo.

#### 3.6.1. Media Cuadrática (RMS)

En matemáticas, la media cuadrática, valor cuadrático medio, raíz de la media cuadrática o RMS (por sus siglas en inglés “root mean square”) es una medida estadística de la magnitud de una cantidad variable. Puede calcularse para una serie de valores discretos o para una función matemática de variable continua. El nombre deriva del hecho de que es la raíz cuadrada de la media aritmética de los cuadrados de los valores.

EL valor RMS se calcula tomando la raíz cuadrada de la media aritmética de las amplitudes de muestra cuadradas de una forma de onda, y se denota como [45]:

$$\mathcal{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (3.12)$$

### 3.6.2. Frecuencia instantánea media (MIF)

La frecuencia instantánea media MIF (j) de  $c_j(t)$  con  $\mathcal{N}$  puntos de datos como la media ponderada  $\omega_j(t)$  usando el cuadrado  $a_j(t)$  como peso. Se calcula con:

$$\mathcal{MIF} = \frac{\sum_{i=1}^{\mathcal{N}} \omega_j(i) a_j^2(i)}{\sum_{i=1}^{\mathcal{N}} a_j^2(i)} \quad (3.13)$$

Después de obtener la frecuencia media de cada IMF, las dos normas de cada valor de amplitud de IMF se calculan a lo largo de la época para proporcionar una medida de la magnitud relativa de cada banda de frecuencia en la época. Cada frecuencia media de banda estrecha se pondera según la norma de amplitud de esa banda, y los resultados se suman para proporcionar una estimación de la frecuencia media basada en EMD. Entonces, la frecuencia media de la señal original se define por:

$$\mathcal{MIF} = \frac{\sum_{j=1}^{\mathcal{N}} \|a_j\| \mathcal{MIF}(j)}{\sum_{j=1}^{\mathcal{N}} \|a_j\|} \quad (3.14)$$

## 3.7. Selección de características y la prueba "t"

Para el conjunto de señales del acelerómetro del sensor inercial se calcularon los valores RMS, fase y frecuencia media instantánea en los ejes X, Y y Z de las señales de acelerometría obtenidas con el sensor colocado en el centro de gravedad de los individuos (tórax), según de la sección 3.6, durante las tareas de caminata lenta, rápida y trotando (D01, D02 y D03). Para evaluar las diferencias de estos patrones entre el grupo de jóvenes y ancianos, en el presente trabajo se implementó una técnica de inferencia estadística conocida como prueba "t" de Student.

La prueba "t" de Student emparejada, es un tipo de estadística deductiva. Se utiliza para determinar si hay una diferencia significativa entre las medias de dos grupos. Con toda la estadística deductiva, asumimos que las variables dependientes tienen una distribución normal. Especificamos el nivel de la probabilidad (nivel de la alfa, nivel de la significación,  $p$ ) que estamos dispuestos a aceptar antes de que cerco datos ( $p < .05$  es un valor común se utiliza en cualquier prueba estadística) [46].

La prueba estadística para t de Student es el valor t. Conceptualmente, la t valor representa el número de unidades estándares que están separando las medias de los dos grupos.

Con una t-prueba, se indica con un cierto grado de confianza que la diferencia obtenida entre los medios de los grupos de la muestra sea demasiado grande para ser un acontecimiento chance. Si nuestra t prueba produce un t-valor que da lugar a una probabilidad de 0.1, decimos que la probabilidad de conseguir la diferencia que encontramos sería por casualidad 1 en 100 veces.

La idea básica para calcular una prueba de *Student* es encontrar la diferencia entre las medias de los dos grupos y dividirla por el error estándar (de la diferencia), es decir la desviación de estándar de la distribución de las diferencias. Un intervalo de confianza para una prueba t con dos colas es calculado multiplicando los valores críticos por el error de estándar y agregando y restando eso de la diferencia de las dos medias. El efecto tamaño se utiliza para calcular la diferencia práctica. Si existe una cantidad suficiente de muestras en nuestra población de estudio, es muy fácil encontrar una diferencia estadísticamente significativa. Saber si esa diferencia es práctica o significativa es otra pregunta. Con los estudios implicando diferencias de grupo, el tamaño del efecto es la diferencia de las dos medias dividido por la desviación estándar del grupo control (o la desviación estándar media de ambos grupos si no hay grupo de control).

### 3.7.1. Test de hipótesis

Los pasos para seguir para realizar un t-test de medias independientes son:

1. Establecer las hipótesis.
2. Calcular el estadístico (parámetro estimado) que se va a emplear.
3. Determinar el tipo de prueba, una o dos colas.
4. Determinar el nivel de significancia  $\alpha$ .
5. Cálculo de del valor-p y comparación con el nivel de significancia establecido.
6. Cálculo del tamaño del efecto (opcional pero recomendado).
7. Conclusiones.

1. Establecer las hipótesis.

**Hipótesis nula ( $H_0$ ):** por lo general es la hipótesis escéptica, la que considera que no hay diferencia o cambio. Suele contener en su definición el símbolo =. En el caso de comparar dos medias independientes la hipótesis nula considera que  $\mu_1 = \mu_2$ .

**Hipótesis alternativa ( $H_A$ ):** considera que el valor real de la media poblacional es mayor, menor o distinto del valor que establece la  $H_0$ . Suele contener los símbolos  $>$ ,  $<$ ,  $\neq$ . En el caso de comparar dos medias independientes la hipótesis alternativa considera que  $\mu_1 \neq \mu_2$ .

## 2. Calcular el estadístico (parámetro estimado)

El estadístico es el valor que se calcula a partir de la muestra y que se quiere extrapolar a la población de origen. En este caso es la diferencia de las medias muestrales  $(\bar{X}_1 - \bar{X}_2)$ .

## 3. Determinar el tipo de prueba, una o dos colas

Las pruebas de hipótesis pueden ser de una cola o de dos colas. Si la hipótesis alternativa emplea ">" o "<" se trata de una prueba de una cola, en el que solo se analizan desviaciones en un sentido. Si la hipótesis alternativa es del tipo "diferente de" se trata de una prueba de dos colas, en el que se analizan posibles desviaciones en las dos direcciones. Solo se emplean test de una cola cuando se sabe con seguridad que las desviaciones de interés son en un sentido y únicamente si se ha determinado antes de observar la muestra, no a posteriori.

## 4. Determinar el nivel de significancia $\alpha$

El nivel de significancia  $\alpha$  determina la probabilidad de error que se quiere asumir a la hora de rechazar la hipótesis nula. Se emplea como punto de referencia para determinar si el valor de  $p$  obtenido en la prueba de hipótesis es suficientemente bajo como para considerar significativas las diferencias observadas y por lo tanto rechazar  $H_0$ . A menor valor de  $\alpha$ , menor probabilidad de rechazar la hipótesis nula. Por ejemplo, si se considera  $\alpha=0.05$ , se rechazará la hipótesis nula en favor de la hipótesis alternativa si el valor de  $p$  obtenido es menor que **0.05**, y se tendrá una probabilidad del 5% de haber rechazado  $H_0$  cuando realmente es cierta. En nivel de significancia debe establecerse en función de que error sea más costoso:

Error tipo I: Error de rechazar la  $H_0$  cuando realmente es cierta

Error tipo II: Error de considerar como cierta  $H_0$  cuando realmente es falsa.

## 5. Cálculo de valor de $p$ y comparación con el nivel de significancia

Si las condiciones mencionadas previamente se cumplen, se puede considerar que:

$$T = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{SE} \sim t_{(df)} \quad (3.15)$$

Siendo

$$SE = \sqrt{\frac{\hat{S}_1^2}{n_1} + \frac{\hat{S}_2^2}{n_2}} \quad (3.16)$$

Donde  $\hat{S}$  es la cuasi desviación típica muestral o desviación típica muestral corregida.

$$p = P(|T_{calculada}| \geq t_{df,1-\alpha/2}) \quad (3.17)$$

## 6. Tamaño del efecto

El tamaño del efecto es la diferencia neta observada entre los grupos de un estudio. No se trata de una medida de inferencia estadística ya que no se pretende identificar si las poblaciones son significativamente diferentes, sino que simplemente indica la diferencia observada entre muestras, independientemente de la varianza que tengan. Se trata de un parámetro que siempre debe acompañar a los valores de  $p$ , ya que  $p$  solo indica si hay evidencias significativas para rechazar la hipótesis nula pero no dice nada de si la diferencia es importante o práctica. Esto último se averigua mediante el tamaño del efecto.

## 7. Interpretación de los resultados

Si el valor de  $p$  es menor que el valor de  $\alpha$  seleccionado, existen evidencias suficientes para rechazar  $H_0$  en favor de  $H_A$ .

Una forma visual para comprender la utilidad de este análisis es usando la herramienta estadística descriptiva conocida como diagrama de caja, la cual permite ver cómo es la dispersión de los datos con la mediana, los percentiles 25 y 75 y los valores máximos y mínimos. Al poner en contraste las distribuciones de los datos para observar la similitud entre conjuntos de información.

## 3.8. Descripción ANOVA (para n niveles de un solo factor)

El análisis de varianza (ANOVA, por sus siglas en inglés) de un factor nos sirve para comparar varios grupos en una variable cuantitativa (variable aleatoria). Se aplica para contrastar la igualdad de medias de tres o más poblaciones independientes y con distribución normal, muestreados en la misma variable aleatoria. Supuestas  $k$  poblaciones independientes, las hipótesis del contraste son siguientes:

1. **H<sub>0</sub>**:  $\mu_1 = \mu_2 = \dots = \mu_k$  Las medias poblacionales son iguales
2. **H<sub>1</sub>**: Al menos dos medias poblacionales son distintas

Para realizar el contraste ANOVA, se requieren  $k$  muestras independientes de la variable de interés. Una variable de agrupación denominada *factor* y clasifica las observaciones de la variable en las distintas muestras.

Suponiendo que la hipótesis nula es cierta, el estadístico utilizado en el análisis de varianza sigue una distribución F de Fisher-Snedecor con  $k-1$  y  $n-k$  grados de libertad, siendo  $k$  el número de muestras y  $n$  el número total de observaciones que participan en el estudio [47].

### 3.9. Descripción MANOVA (para $n$ niveles de un solo $m$ factores)

El análisis multivariable de la varianza (MANOVA, por sus siglas en inglés) es una extensión del análisis de la varianza (ANOVA, por sus siglas en inglés) en donde se tiene en cuenta más de una variable de criterio o independiente. Es, pues, una técnica de dependencia que analiza el comportamiento de un conjunto de variables métricas dependientes en las subpoblaciones o grupos establecidos por la combinación de los valores del conjunto de variables categóricas (o factores) independientes. El ANOVA y el MANOVA, como procedimientos de inferencia estadística, se aplican para contrastar la significación estadística de las diferencias entre grupos. Mientras que en ANOVA la hipótesis nula contrastada es la igualdad de las medias de la variable dependiente entre los grupos (se contrasta la igualdad entre los grupos de una única variable dependiente); en el MANOVA la hipótesis nula contrastada es la igualdad de un conjunto (vector) de medias de las variables dependientes entre los grupos delimitados por los valores de la/s variable/s (factor/es) independientes (se contrasta la igualdad de un valor teórico el cual combina óptimamente las medidas dependientes múltiples dentro de un valor único que maximiza las diferencias entre los grupos). El MANOVA contrasta la hipótesis nula de que los vectores de las medias de todos los grupos son iguales y/o provienen de la misma población. Matemáticamente lo anotaremos como sigue:

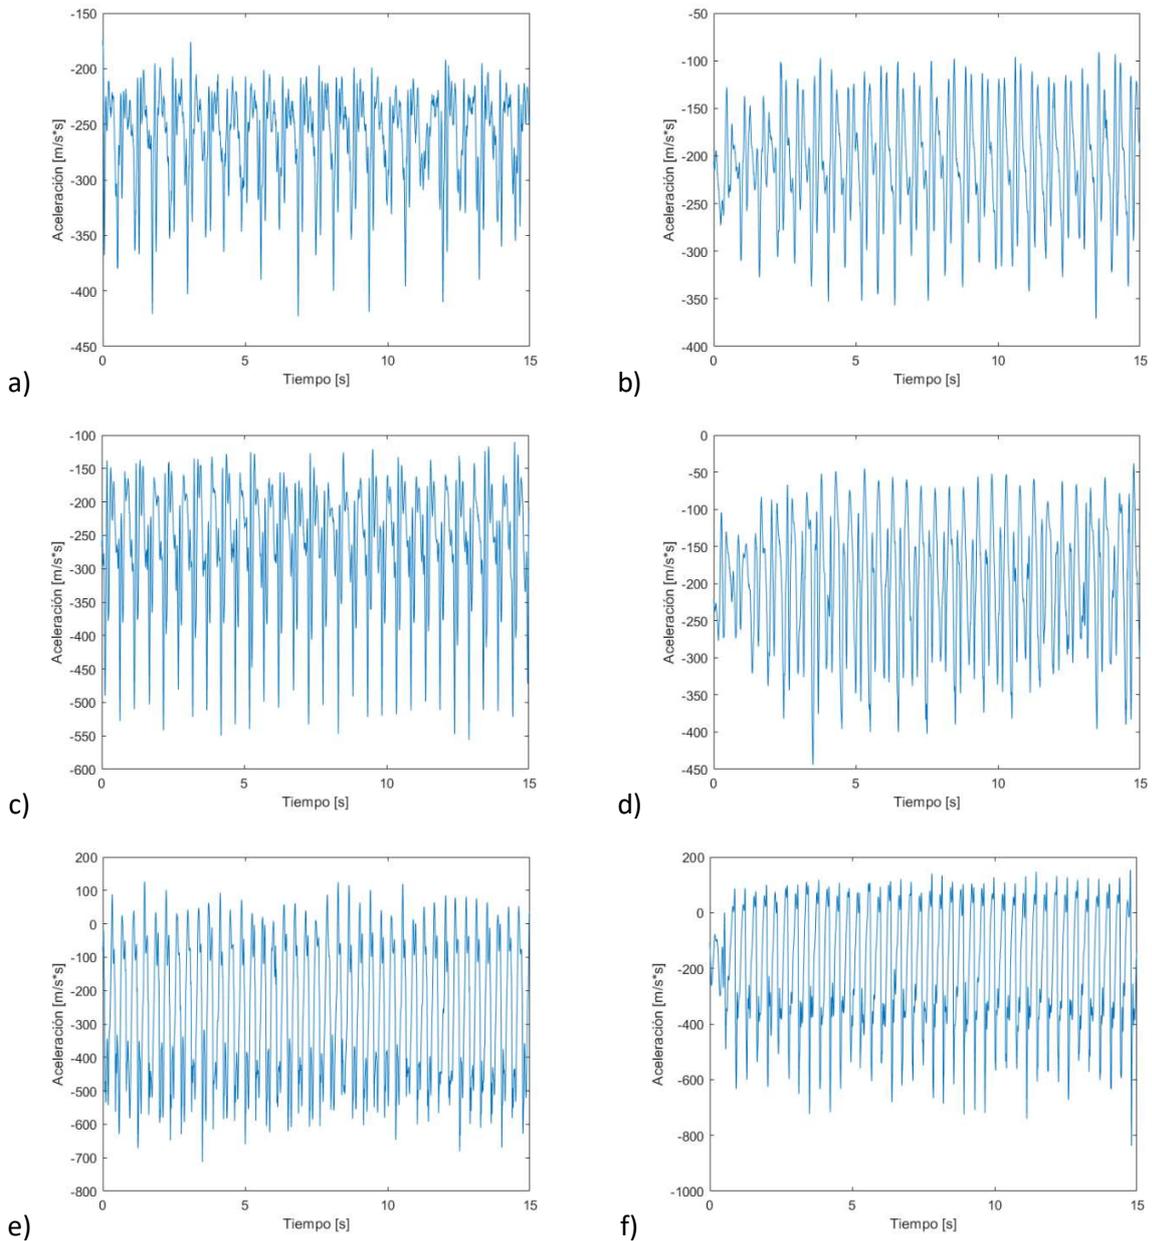
$$H_0: \mu_1 = \mu_2 = \mu_3 = \dots = \mu_n \quad (3.18)$$

Los supuestos estadísticos paramétricos que han de cumplir los datos para que se les pueda aplicar el análisis de varianza son tres: deben proceder de muestras aleatorias simples, debe existir normalidad en la distribución de los datos y las varianzas de las subpoblaciones deben ser iguales.

El análisis multivariante de la varianza con  $n$  factores se basa en que la variabilidad total de la muestra puede descomponerse en la variabilidad debida a las diferencias entre grupos y la debida a las diferencias dentro de los grupos. A su vez, y tal y como ya sucediera con el análisis factorial de varianza, la variabilidad explicada por el efecto de pertenecer a un grupo se descompone en: la variabilidad debida a los efectos de cada una de las variables independientes (efectos principales) y la debida al efecto de todas las posibles interacciones que se producen entre ellas [48].

# Capítulo 4.

## Resultados



**Figura 4.1:** Señales de acelerometría en el eje de gravedad (eje Y) comparando un sujeto adulto (columna izquierda) y un sujeto anciano (columna derecha), para caminata lenta a) y b), caminata moderada c) y d) y trotando e) y f). En general se observa menos rango de amplitud en los ancianos, y mayor frecuencia en la caminata rápida (trotando).

En este capítulo se presentan los resultados obtenidos mediante el análisis de señales en tiempo-frecuencia de las señales de acelerometría, con el fin de entender mejor la diferencia entre dos grupos de adultos y los ancianos, así como las posibles diferencias entre las tres condiciones experimentales evaluadas (caminata lenta, caminata rápida, trotando). Para todas las pruebas realizadas se tomaron los 450 registros de los sujetos de la base de datos disponible (ver Tabla 3.1 y 3.2).

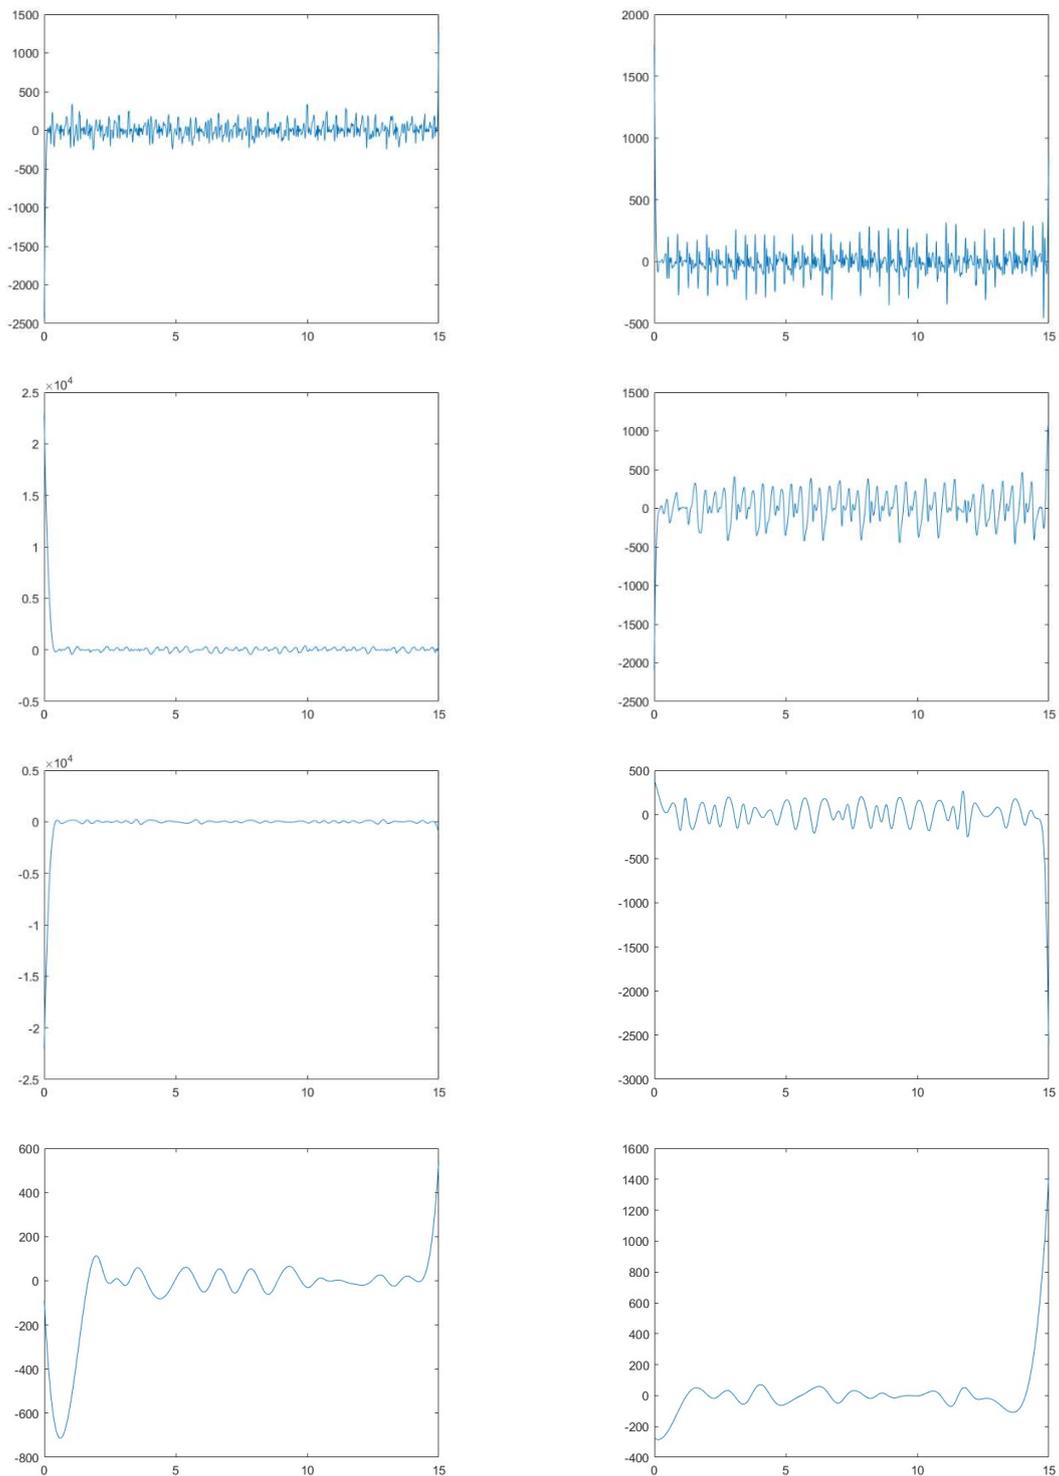
Para comenzar a entender los patrones de caminata observados y sus diferencias entre adultos y ancianos, en la Figura 4.1 se muestran las señales de acelerometría en el eje de gravedad (eje Y) comparando un sujeto adulto (columna izquierda) y un sujeto anciano (columna derecha), para caminata lenta, caminata moderada y trotando. En general se observa menos rango de amplitud en los ancianos, y mayor frecuencia en la caminata rápida (trotando). Otras diferencias en los patrones fueron detectadas con la metodología propuesta, como se verá a continuación.

#### 4.1. Aplicación de la transformada de Hilbert-Huang

Hacemos la prueba con 30 sujetos (15 ancianos, 15 adultos) cada sujeto hizo tres pruebas (caminata lenta, caminata rápida, trotando) de 100 segundos cada una. Para obtener facilitar el análisis y el tiempo de procesamiento de las señales, cada señal la segmentamos primero en 5 ventanas (épocas) de 20 segundos cada una. Con ello se puede decir que se extendió la base de datos de 90 señales originales (30 sujetos\*3Pruebas) a 450 registros (90 señales\*5 épocas). Posteriormente a cada uno de estos nuevos registros se aplicó el método de descomposición de modo empírico (EMD). En general observamos que el número mínimo de funciones de modo intrínseco obtenidas (FMI) era de entre 4 y 6 descomposiciones, más el residuo. Por ello, con el fin de obtener homogeneidad en la información para todas las señales, se obtuvieron la frecuencia media instantánea (MIF) y el valor RMS en amplitud instantánea (RMS) por medio de la transformada de Hilbert, de las primeras cuatro  $FMI_k$ .

Posteriormente, con el conjunto de características específicas obtenidas, hicimos un análisis estadístico multivariado para las 450 señales segmentadas, a fin de estudiar las posibles diferencias significativas tomando en cuenta el grupo y la condición experimental como factores, a fin de deducir diferentes patrones de caminata. Los resultados completos del análisis vienen en la tabla siguiente. La implementación del método de Hilbert-Huang y generación de las características se realizó en Matlab.

En la Figura 4.2 se ilustra la descomposición de modo empírico aplicando a señales de acelerometría en el eje de la gravedad (eje Y) de un individuo adulto (gráficas de la columna izquierda) y un anciano (gráficas de la columna derecha). A simple vista se observan diferencias en las funciones de modo intrínseco obtenidas, que serán la base del análisis comparativo descrito a continuación.

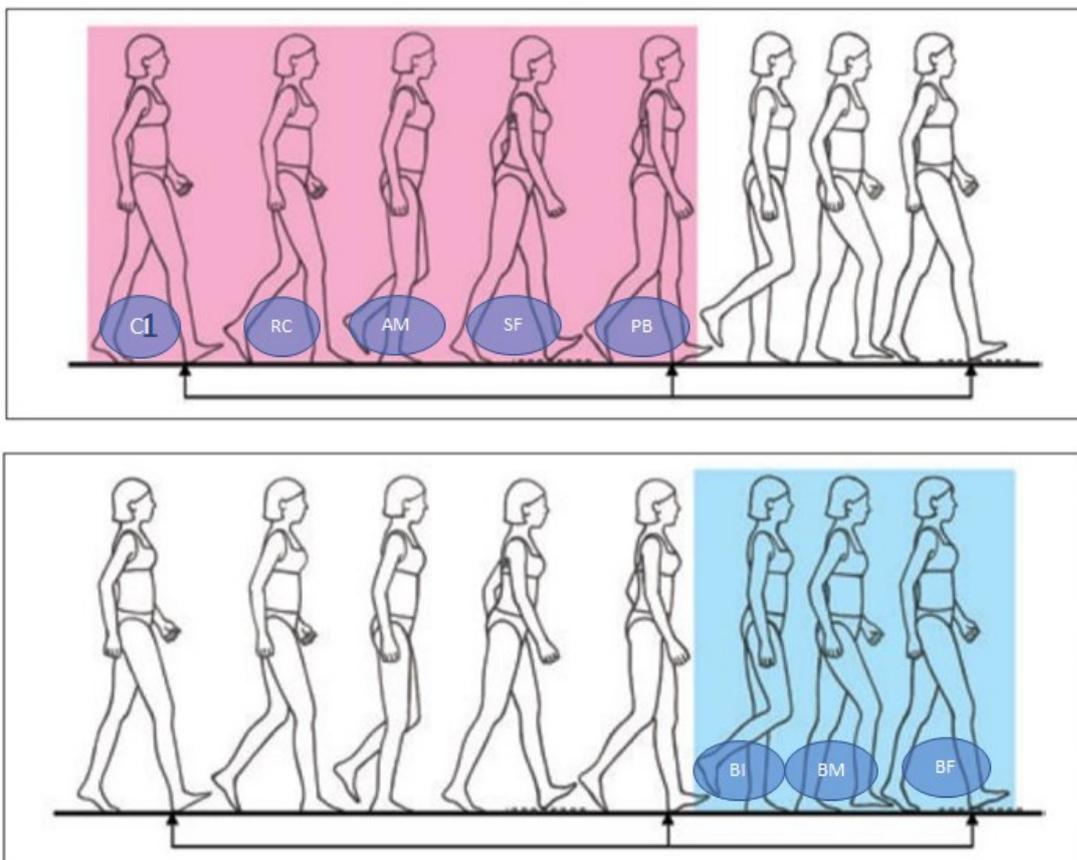


**Figura 4.2:** Descomposición de modo empírico aplicando a señales de acelerometría en el eje de la gravedad (eje Y) de un individuo adulto (gráficas de la columna izquierda) y un anciano (gráficas de la columna derecha). A simple vista se observan diferencias en las funciones de modo intrínseco obtenidas.

## 4.2. Patrones de caminata observados

A partir de la transformada HHT se calcularon los valores de frecuencia media instantánea en los tres ejes de las señales (valores MIF-X, MIF-Y y MIF-Z), así como los valores RMS de la media de la amplitud (valores RMS-X, RMS-Y, RMS-Z), con los cuales se evaluaron diferencias en los patrones de aceleración durante la caminata.

A continuación, se describen los patrones observados y posteriormente se presentan los análisis estadísticos comparativos. Para entenderlos mejor en la siguiente Figura 4.3 se ilustran las fases de la caminata humana normal, dividida en la fase de apoyo y la fase de balanceo. La fase de apoyo se divide a su vez en: contacto inicial (CI), respuesta a la carga (RC), apoyo medio (AM), soporte final (SF), pre-balanceo (PB). La fase de balanceo se divide en: balanceo inicial (BI), balanceo medio (BM), balanceo final (BF).

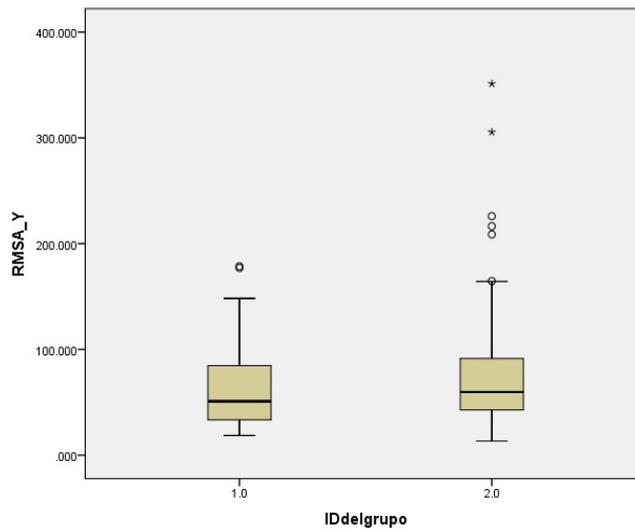


**Figura 4.3:** Fases de la marcha humana, dividida en fase de apoyo (arriba) y fase de balanceo (abajo). A su vez la fase de apoyo se divide en: Contacto inicial (CI), respuesta a la carga (RC), apoyo medio (AM), soporte final (SF), pre-balanceo (PB). La fase de balanceo se divide en: Balanceo inicial (BI), balanceo medio (BM), balanceo final (BF).

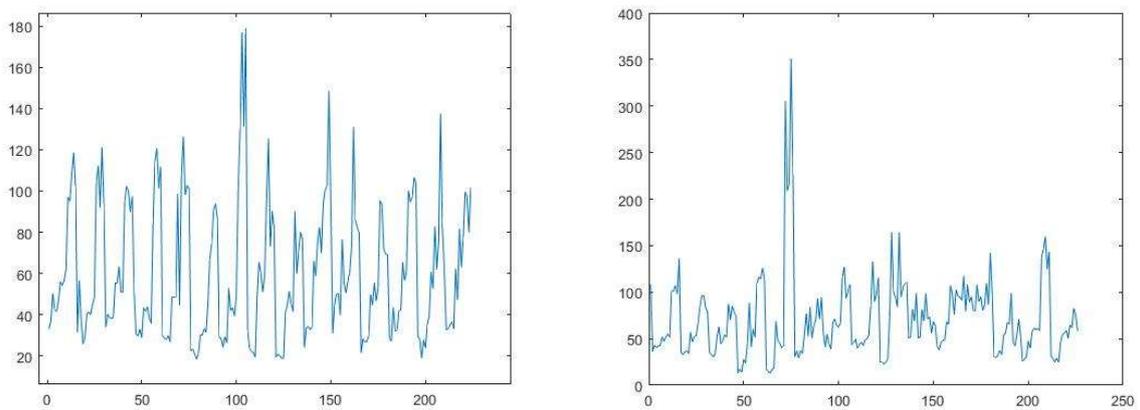
#### 4.2.1. Amplitud de la aceleración en eje Y (RMS Y)

La amplitud en eje Y (de la gravedad) en los ancianos tiene un rango más amplio y mayor dispersión que los adultos. En los adultos nos muestra que hay un *outlier*, pero no hay ninguna razón para sospechar, porque solo es uno y no tan lejano de la media.

Sin embargo, en los ancianos encontramos 6 *outliers* y que están más lejano de la media, eso nos indica que el patrón de caminata medido en el eje Y de los ancianos es más disperso.



**Figura 4.4:** Diagrama de caja en característica de RMS en eje Y entre grupos (id=1, adultos; id=2, ancianos)



**Figura 4.5:** Amplitud RMS en el eje Y de las 225 señales, tanto para adultos (izquierda) y ancianos (derecha).

En la Figura 4.5, se observan los valores de MIF en el eje Y para las 225 señales de aceleración utilizadas, tanto para los adultos y los ancianos. Hay más diferencias en los ancianos como se ve la en el pico de la gráfica de los ancianos (gráfica de la derecha). Los adultos son más regulares, probablemente porque tienen menos problemas de caminata.

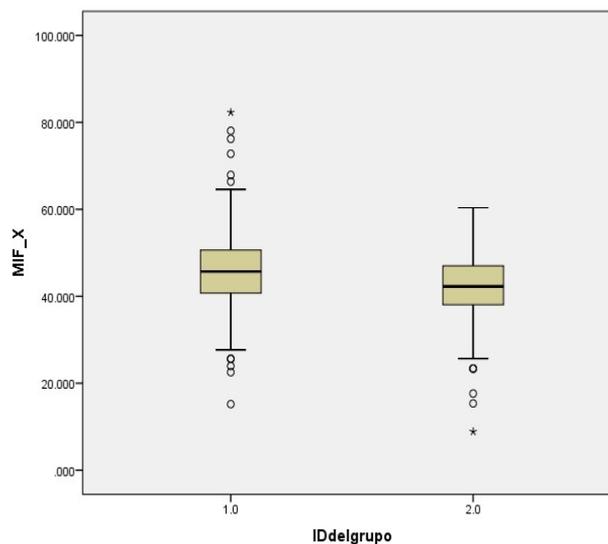
Como observamos también, los adultos tienen un rango más normal que en los ancianos.

En cambio, los ancianos debido a condiciones de su edad, cada uno está exhibiendo patrones más diferentes entre caminata lenta, caminata rápida, y trotando.

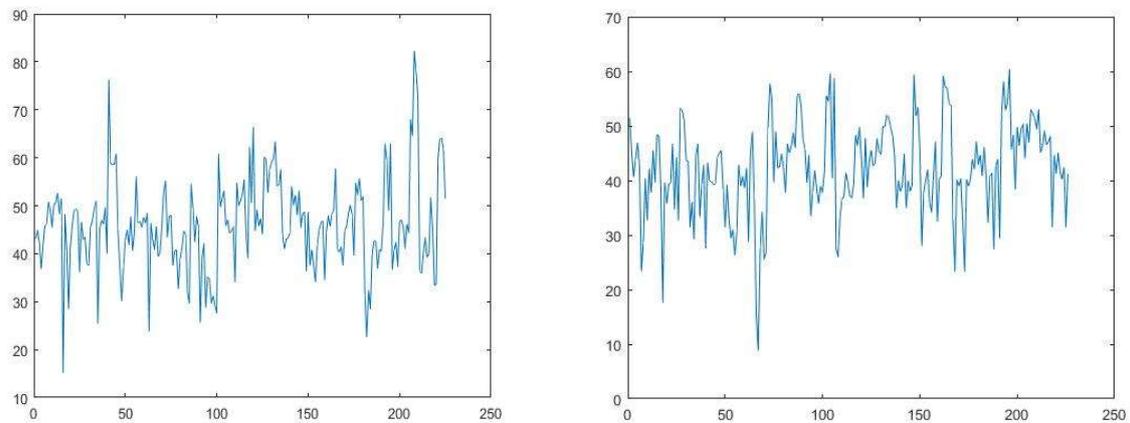
Para ilustrarle mejor colocamos las lecturas de esa misma señal para los adultos y los ancianos. En los adultos efectivamente se observan series de tiempo con caminata más estacionaria, pero en la caminata de ancianos se ve menos estabilidad y más irregular, hay un pico más amplio que indica un comportamiento de ajuste o tal vez un indicio de riesgo de caída.

#### 4.2.2. Frecuencia media instantánea en el eje X (MIF X)

MIF es la frecuencia de oscilación, que en eje X es la oscilación de la frecuencia lateral relacionada con los movimientos de estabilidad lateral. Como observamos en el diagrama de caja hay más dispersiones en los adultos y el rango de oscilación en los adultos se ve más amplio el rango (Figura 4.6). En este caso parece haber mayor habilidad de movimientos laterales de control de estabilidad en adultos que en ancianos en la fase de apoyo durante la caminata. Esto se puede ver las MIF en X de las 225 señales para ambos grupos, que nos muestran algunos movimientos fuera de rango en los adultos más que en los ancianos (Figura 4.7).



**Figura 4.6:** Diagrama de caja en característica de MIF en eje X entre grupos (id=1, adultos; id=2, ancianos).

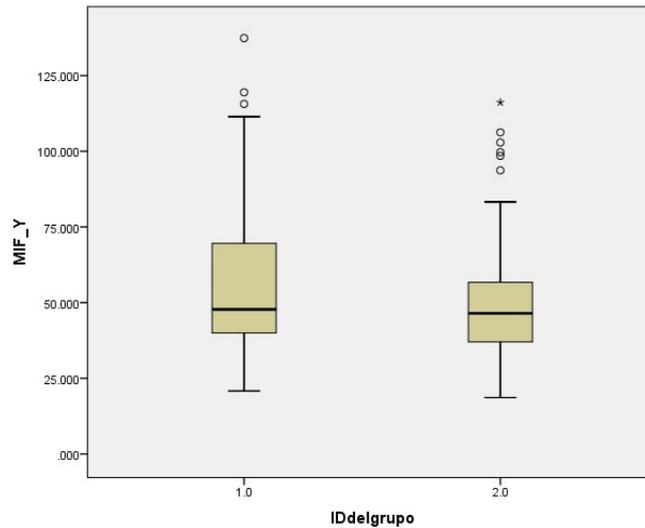


**Figura 4.7:** Frecuencia MIF en el eje X de las 225 señales, tanto para adultos (izquierda) y ancianos (derecha).

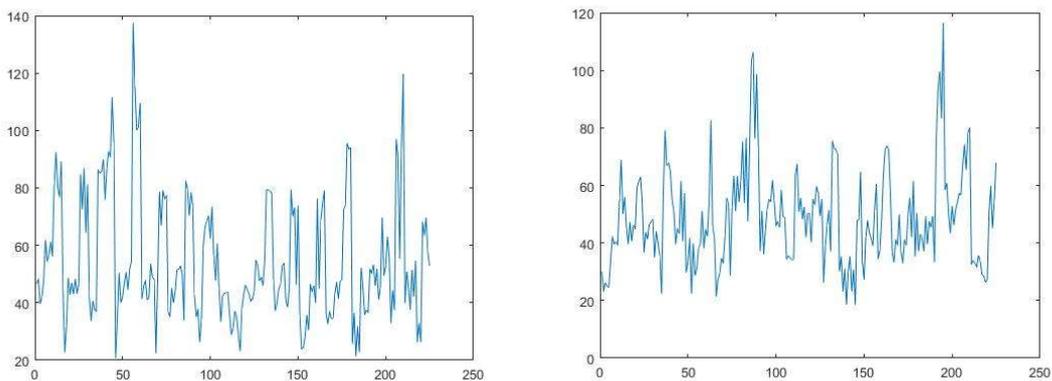
#### 4.2.3. Frecuencia media instantánea en el eje Y (MIF Y)

En el caso de la frecuencia media instantánea de la aceleración en el eje Y, al igual que en la sección anterior se ven patrones menos estacionarios en los ancianos, pero en los adultos observamos más estabilidad y más regulares, en el eje Y es la oscilación subir y bajar al respeto del piso.

La forma en que calculamos las medidas que estamos tomando como comparativos son muy importantes porque son capaces de encontrar las diferencias tanto de balanceo de lateral y frontal como la frecuencia oscilación de las fases de pre-balanceo y balanceo de la caminata (movimientos arriba y abajo) tanto para diferenciar entre poblaciones de sujetos, como del tipo de tareas. Por lo tanto esto valida que esta información en frecuencia puede ser utilizada en el futuro para estudios más exhaustivos comparativos que permitan a evaluar riesgo de caída (evaluar patrones de la caminata).



**Figura 4.8:** Diagrama de caja en característica de MIF en eje Y entre grupos (id=1, adultos; id=2, ancianos).

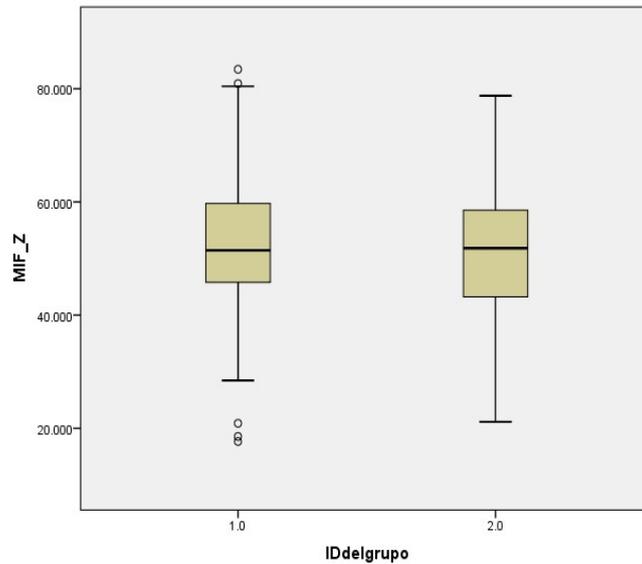


**Figura 4.9:** Frecuencia MIF en el eje Y de las 225 señales, tanto para adultos (izquierda) y ancianos (derecha).

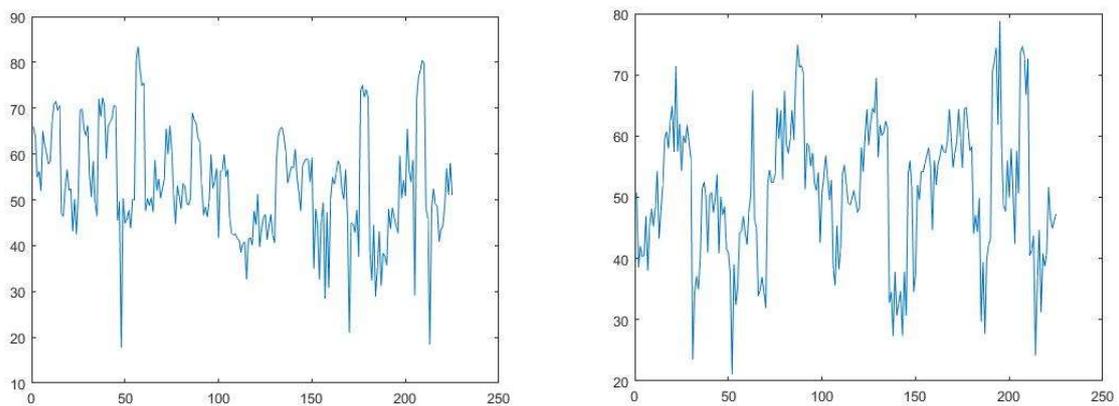
Como observamos en la Figura 4.9, las frecuencias de oscilación en el eje Y en los adultos tenemos un rango más amplio mayor mucha dispersión.

#### 4.3.4. Frecuencia media instantánea en el eje Z

La frecuencia de oscilación en el eje Z, que es la frecuencia de oscilación frontal, muestra a diferencia de los ejes anteriores una dispersión similar en los adultos que los ancianos. Sin embargo, como se verá más adelante, si existen diferencias en este eje entre la adultos y ancianos para cuanto están trotando.



**Figura 4.10:** Diagrama de caja en característica de MIF en eje Z entre grupos (id=1, adultos; id=2, ancianos).

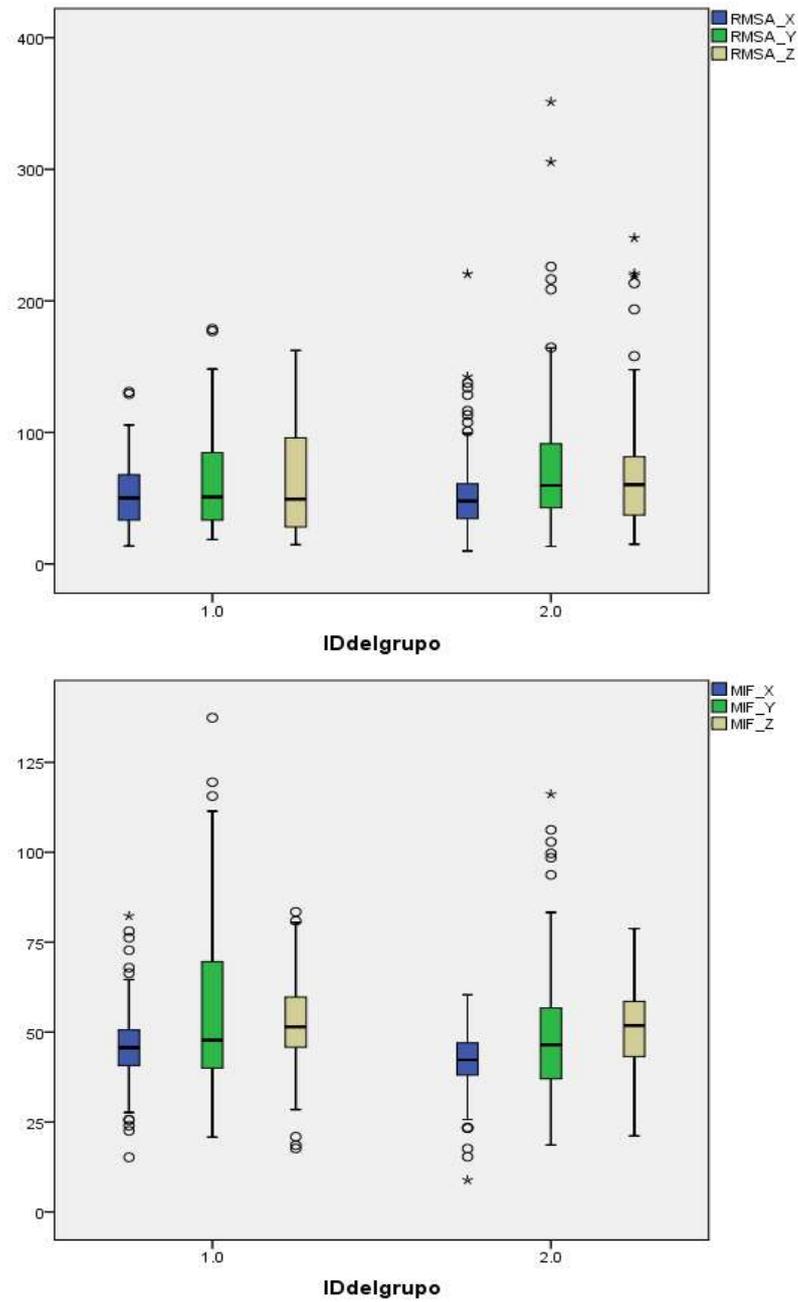


**Figura 4.11:** Frecuencia MIF en el eje Z de las 225 señales, tanto para adultos (izquierda) y ancianos (derecha).

Como se ilustra en las gráficas de la Figura 4.11, las frecuencias de oscilación de los participantes nos brindan soporte para la hipótesis de que cuando los adultos trotan son más estables que los ancianos y los ancianos no tienen mucho balanceo. Valdría la pena investigar si esto pudiera significar ser un factor de riesgo de caída, pues interpretamos que los ancianos no balancean cuando caminan rápido tienen menos punto de apoyo tienen menos estabilidad y aumentando posiblemente la probabilidad de caer.

#### 4.3.5. Comparación entre grupos para RMS y MIF de aceleración

Hacemos una comparación entre las características RMS de amplitud y MIF de la frecuencia en tres ejes X, Y, Z, entre los dos grupos de adultos y ancianos.



**Figura 4.12:** Diagramas de caja en características RMS y MIF en tres ejes X, Y, Z entre los grupos (grupo 1: adultos, grupo 2: ancianos)

Como observamos en la característica RMS de amplitud en los ancianos hay más dispersiones en los tres ejes, especialmente en el eje de Y que es a la gravedad (sube y baja del cuerpo). Pero como esperábamos el rango de los diagramas de caja (desviación estándar) es más amplio en los adultos que los ancianos por algunas razones, como que tal vez los ancianos tienen movimientos más inseguros o con cuidado en comparación con los adultos.

Al contrario, comparando las frecuencias medias instantáneas entre los grupos, mediante la característica MIF que es oscilación de la frecuencia en tres ejes X, Y, Z, hay más dispersiones en los adultos especialmente en el eje Y que es al respecto de la gravedad. Además, las desviaciones estándares de los diagramas de caja son mayores en los adultos que los ancianos, que nos muestra que la oscilación varía más en los adultos que los ancianos.

### 4.3 Análisis estadístico comparativo

El análisis comparativo de estos datos aplicando la prueba T Student comparando los adultos contra los ancianos arrojó diferencias significativas entre ambos grupos, para la mayoría de ellas.

Lo anterior nos motivó a comparar ahora también con respecto al tipo de caminata (que son tres condiciones). Para ello se realizó posteriormente un análisis multivariado de la varianza (MANOVA), tomando en cuenta 2 factores, es decir, 2 grupos (adultos, ancianos) X 3 condiciones (caminata lenta, caminata rápida, trotando). Con lo cual se obtuvieron los valores estadísticos descriptivos de media y desviación estándar reportados en la siguiente tabla 4.1. Pero además en las condiciones diferentes, encontramos diferencias interesantes también incluidas en la tabla 4.1. Los análisis estadísticos se realizaron en SPSS v.20.

En particular encontramos diferencias significativas para la característica de RMS de amplitud solo en el eje Y entre los adultos y los ancianos. También nos da diferencias dependiendo el tipo de tarea que en este caso diferencias entre los tres tipos de caminata lenta, caminata rápida, y trotando. Esto último tanto para adultos como para ancianos.

Contrariamente en caso de amplitud en RMS-X y RMS-Z, no encontramos diferencias entre los ancianos y los adultos, pero encontramos la diferencia entre todos los tipos de caminata entre sí.

Característica	Tarea	Adultos	Ancianos	P (<0.05)		
		Media+Desviacion Std	Media+Desviacion Std	Grupo (adultos vs Ancianos)	Condición	Grupo * Condición
RMS Amplitud X	Caminata Lenta	30.92±16.03	32.36±12.65	NP	<b>0.000</b>	NP
	Caminata Rápida	49.91±9.17	51.43±23.94			
	Trotando	75.25±13.59	71.14±24.11			
RMS Amplitud Y	Caminata Lenta	31.03±8.46	39.88±19.79	<b>0.000</b>	<b>0.000</b>	NP
	Caminata Rápida	52.48±13.27	64.80±20.75			
	Trotando	98.31±22.61	106.53±51.29			
RMS Amplitud Z	Caminata Lenta	26.52±11.72	33.28±13.32	NP	<b>0.000</b>	<b>0.001</b>
	Caminata Rápida	51.55±13.43	59.11±14.22			
	Trotando	113.12±22.58	104.48±39.57			
MIF X	Caminata Lenta	39.66±6.89	39.52±6.89	<b>0.000</b>	<b>0.000</b>	<b>0.001</b>
	Caminata Rápida	44.82±7.26	38.47±7.82			
	Trotando	53.42±9.17	47.97±7.08			
MIF Y	Caminata Lenta	39.59±8.28	42.26±11.71	<b>0.000</b>	<b>0.000</b>	<b>0.000</b>
	Caminata Rápida	49.14±13.76	45.51±14.46			
	Trotando	74.44±21.07	58.23±18.66			
MIF Z	Caminata Lenta	47.47±8.93	48.55±10.78	<b>0.003</b>	<b>0.000</b>	<b>0.006</b>
	Caminata Rápida	49.22±9.74	48.15±11.11			
	Trotando	62.58±10.57	56.30±9.90			

**Tabla 4.1:** Análisis estadístico comparativo para 6 características de tiempo y frecuencia entre dos grupos de adultos y ancianos y tres condiciones

En MIF Y que es la frecuencia de oscilación en el eje de la gravedad, se observan diferencias entre ancianos y adultos de subir y bajar al respecto del piso durante la caminata trotando. En la MIF del eje X, que es la oscilación lateral en caminata lenta no observamos diferencia entre grupos, pero en caminata rápida y trotando sí. Incluso entre las pruebas, en los ancianos no se ve diferencia entre

caminata lenta y rápida. En la frecuencia de aceleración del movimiento hacia arriba y abajo se ve la diferencia en todos los tipos de la prueba (caminata lenta, caminata rápida, trotando), pero cuando revisamos la oscilación lateral y frontal en caminata lenta y rápida no hay diferencia, en comparación con los adultos. Sin embargo, cuando caminan rápido los ancianos no son capaces de tener un mecanismo de oscilación que les permite equilibrarse de manera adecuada; tienen dificultad de balancear lateral que es muy importante para mantener el equilibrio cuando están caminando de manera más rápida.

Además, en eje Z que es la oscilación frontal, no observamos diferencia entre grupos, los patrones en la aceleración frontal son iguales excepto en trotando.

Para estas explicaciones hay una hipótesis que, cuando los adultos caminan son más estables que los ancianos, y los ancianos no tienen mucho balanceo. Eso puede ser un factor de riesgo de caída, porque los ancianos no balancean cuando caminan rápido, puede ser que tengan menos punto de apoyo, menos estabilidad y por lo tanto posiblemente probabilidad de caer.

Estas diferencias se pueden comprobar en las últimas tres columnas de la tabla, donde observamos en que las celdas de la tabla con valores de  $p < 0.05$  son las características que nos interesan, por mostrar diferencias entre grupos o las condiciones (que se muestra en negrita en la tabla 4.1)

Las partes azules son las partes en donde observamos diferencias significativas en la media  $\pm$  desviación standard entre los grupos (adultos y ancianos).

Revisando detalladamente la tabla encontramos diferencias significativas entre adultos y ancianos en particular para los casos en RMS-Y para todas las condiciones experimentales (caminata lenta, caminata rápida, trotando), en MIF-X entre las condiciones de caminata rápida y trotando, en MIF-Y para condición trotando, en MIF-Z para la condición trotando, que indicamos con colores azules.

En comparación al detalle entre tipos de caminata el análisis demostró que hay diferencias entre todas las variables. Hay diferencias en aceleración entre adultos y ancianos en el eje Y de la gravedad. Es decir, cuando el individuo realiza los movimientos repetitivos de subir y bajar en el eje de la gravedad durante las fases de pre-balanceo y balanceo de la caminata, tanto para caminata lenta y caminata rápida y trotando.

Por parte de la amplitud, en los ancianos se observa hay una amplitud de aceleración mayor que los adultos, los ancianos teniendo un movimiento más inseguro, que nos muestra un cambio de mayor velocidad. El cambio de ritmo es más abrupto en comparación de los adultos. Los ancianos parecen estar brincando durante la caminata. Esto parece indicar que posiblemente realizan movimiento en los talones con mayor extensión que los adultos jóvenes y menor flexión en las rodillas, esto por algunas razones que pueden atribuirse a condiciones biomecánicas mulculoesqueléticas, neuromecánicas o por cuestión neurológica, fuerza, o incluso control vestibular, lo cual requiere más investigación.

En cuanto a la frecuencia, esta nos da información de qué grupo oscila más. Aquí está al revés, los movimientos más rápidos están entre los adultos en general, como lo reflejan las frecuencias mayores en la aceleración.

En general en las frecuencias medias instantáneas medidas de la aceleración tanto en el eje X, Y, Z, en los ancianos tienen una aceleración con menor frecuencia o más lenta, pero tienen un cambio de aceleración de mayor amplitud, es decir movimientos al parecer más inestables o abruptos, sobre todo en el eje de la gravedad.

Aunque el objetivo no era encontrar entre las diferencias entre condiciones (caminata lenta, caminata rápida, trotando) sino entre grupos, encontramos que nuestras tres medidas tanto en amplitud como en la frecuencia nos expresan diferencias significativas entre todo tipo de caminata (caminata lenta, caminata rápida, trotando), sin importar que sean adultos o ancianos.

Una vez que hemos hecho MANOVA comparando los grupos y las condiciones, comprobamos que exactamente hay cambios tanto en la frecuencia como en la amplitud de las aceleraciones en los tres ejes cuando comparamos caminata lenta, caminata rápida y trotando, sin importar que son adultos, lo cual se confirmó finalmente mediante una prueba Post-hoc de Bonferroni.

## Capítulo 5.

### Conclusiones y trabajo futuro

En este trabajo se presentó el desarrollo y estudio de la variabilidad del centro de masa durante la caminata humana mediante análisis en tiempo-frecuencia de señales de acelerometría obtenidas mediante un sensor de movimiento inercial (IMU). Para el estudio usamos una base de datos pública de señales de acelerometría entre dos grupos de adultos y ancianos con tres pruebas diferentes de caminata lenta, caminata rápida, y trotando. Con ellas aplicamos la descomposición de las señales en multi-escalas de frecuencia mediante la transformada de Hilbert-Huang para obtener características los dominios tiempo-frecuencia, para evaluar los movimientos y conocer los cambios de patrones de centro de masa del cuerpo humano durante la caminata.

En este trabajo detectamos que existen diferencias entre los ancianos y adultos jóvenes y sabemos que hay diferencias entre ellos y entre las condiciones experimentales (caminata lenta, caminata rápida, trotando).

Podemos concluir que el patrón en la amplitud de la caminata medida en el eje Y que corresponde al eje de gravedad es una información que parece ser relevante para poder discriminar entre los adultos y los ancianos, mientras que las oscilaciones medidas por amplitud de los movimientos laterales y frontales no parece incidir en la caminata.

Sin embargo, por otro lado, si queremos analizar la caminata en diferentes tipos (lenta, moderada, rápida) las tres variables son útiles para determinar diferencias.

Si nos quisiéramos enfocar a evaluar la caminata dependiendo de a que ritmo lo hacen los individuos, sería importante tomar en cuenta la amplitud de los oscilaciones laterales y frontales y en el eje vertical o eje de la gravedad. Sin embargo, para comparar entre grupo de ancianos, solo el eje de gravedad parece proporcionar información diferencial. Esta es por tanto una variable muy importante porque nos proporciona información tanto de la condición física del sujeto como tipo de caminata que está ejecutando.

Los resultados experimentales muestran que este algoritmo es suficientemente valido para encontrar diferencias, por lo que podría ser de utilidad para más estudios sobre caminata a futuro.

Con respecto a la frecuencia se tiene la hipótesis que, cuando los adultos caminan son más estables que los ancianos, y los ancianos no tienen mucho balanceo lateral y frontal. Esto podría ser un indicativo del deterioro motor durante el envejecimiento y posiblemente un factor de riesgo de caída. Los ancianos no balancean cuando caminan rápido, parecen tener menos puntos de apoyo y menos estabilidad y con por ende probabilidad de caer.

Una posible explicación es que en nuestro estudio logramos comprobar algunos patrones que indican las diferencias en control de movilidad o de estabilidad durante de la caminata, en particular observamos un patrón diferente en el eje Y en la caminata en la amplitud en el eje de gravedad, en donde los ancianos tienen más dispersiones que los adultos. Por otro lado, en la frecuencia de oscilación en el eje de la gravedad, los adultos tienen una banda más amplia que los ancianos. Al momento no sabemos cuál es la razón, pero se tiene la hipótesis que puede haber diferencia en la movilidad en los tobillos y en las rodillas o en la cadera y otras articulaciones, debidos muchos factores. Lo cual motiva a mayores estudios a futuro.

Como trabajo futuro, la presente tesis podría enfocarse en el estudio de factores de riesgo de caídas en ancianos. En el caso de sufrir caída en las que el anciano no se queda completamente tumbado en el suelo o no son lo suficientemente bruscas, el sistema podría no detectar la ocurrencia de las mismas. Por este motivo, uno de los trabajos más prioritarios consistiría en, la integración de más acelerómetros en el sistema u otros sensores pertinentes, o integrar más bioseñales como señales de EMG u otras señales fisiología para conseguir aumentar la información que permita detectar diferentes tipos de caída, pero sobre todo evaluar el riesgo de sufrirlas antes de que sucedan.

Dado el caso, una solución para este problema sería la introducción de un botón de activación de la alerta accesible para el anciano. De esta manera, sería el propio anciano el que podría decidir la necesidad del envío de la alerta en caso de fallo del sistema.

Además, tenemos planteado como trabajo futuro reducir las dimensiones de los componentes de hardware a un tamaño considerablemente menor.

Por otra parte, tenemos una idea para diseñar una pista de marcha observada con especialistas de fisiología, geriatría y medicina del deporte, para hacer más pruebas como subir y bajar de escalera, subir y bajar de una rampa, o tareas cotidianas como sentarse y levantarse de una silla y acostarse en la cama, etc.

Hay que estudiar más a fondo diferentes tareas, además de la caminata lenta, caminata rápida y trotando, porque dependiendo de la tarea vamos a tener patrones diferentes, lo que puede ser una probabilidad mayor o menor de riesgo de caída. Por eso en el trabajo futuro vamos a hacer un detector para cada tipo de caminata entre los ancianos como (caminata lenta, caminata rápida, trotando, subir y bajar de las escaleras, etc.). Dependiendo de lo que detecte, podría inferirse un mayor o menor de riesgo de caída.

Además, entendemos que hay limitaciones en las medidas de amplitud y frecuencia, debido a que solo se usó un sensor en el centro de masa del sujeto (abdomen). ¿Qué sucedería si ponemos más sensores en otras partes del cuerpo al anciano en condiciones diferentes? Podríamos desarrollar un algoritmo para indicar qué tipo de condiciones están haciendo para entender el riesgo de caída.

## Referencias

- [1] "WHO Global Report on Falls Prevention in Older Age - World Health Organization - Google Books."  
[https://books.google.com.mx/books?hl=en&lr=&id=ms9o2dvfaQkC&oi=fnd&pg=PA1&dq=WHO+Global+Report+on+Falls+Prevention+in+Older+Age,+World+Health+Org.&ots=5LwXKJXEWX&sig=j0WqHCsoGH-NNe5oB-Badzgult8&redir\\_esc=y#v=onepage&q=WHO Global Report on Falls Prevention](https://books.google.com.mx/books?hl=en&lr=&id=ms9o2dvfaQkC&oi=fnd&pg=PA1&dq=WHO+Global+Report+on+Falls+Prevention+in+Older+Age,+World+Health+Org.&ots=5LwXKJXEWX&sig=j0WqHCsoGH-NNe5oB-Badzgult8&redir_esc=y#v=onepage&q=WHO Global Report on Falls Prevention) (accessed Nov. 05, 2020).
- [2] D. A. Skelton and S. M. Dinan, "Exercise for falls management: Rationale for an exercise programme aimed at reducing postural instability," *Physiother. Theory Pract.*, vol. 15, no. 2, pp. 105–120, 1999, doi: 10.1080/095939899307801.
- [3] A. J. Campbell, M. J. Borrie, and G. F. Spears, "Risk factors for falls in a community-based prospective study of people of 70 years and older," *Journals Gerontol.*, vol. 44, no. 4, 1989, doi: 10.1093/geronj/44.4.m112.
- [4] R. Igual, C. Medrano, and I. Plaza, "Challenges, issues and trends in fall detection systems," *BioMedical Engineering Online*, vol. 12, no. 1. BioMed Central Ltd., p. 66, Jul. 06, 2013, doi: 10.1186/1475-925X-12-66.
- [5] M. Mubashir, L. Shao, and L. Seed, "A survey on fall detection: Principles and approaches," *Neurocomputing*, vol. 100, pp. 144–152, Jan. 2013, doi: 10.1016/j.neucom.2011.09.037.
- [6] "Caídas." <https://www.who.int/es/news-room/fact-sheets/detail/falls> (accessed Nov. 05, 2020).
- [7] D. Galvis, "ALTS DE LA MARCHA INESTABILIDAD Y CAIDAS." Accessed: Nov. 05, 2020. [Online]. Available: [https://www.academia.edu/15011665/ALTS\\_DE\\_LA\\_MARCHA\\_INESTABILIDAD\\_Y\\_CAIDAS](https://www.academia.edu/15011665/ALTS_DE_LA_MARCHA_INESTABILIDAD_Y_CAIDAS).
- [8] "Detector automático de caídas y monitorización de actividad para personas mayores | Revista Española de Geriatria y Gerontología," Accessed: Sep. 23, 2020. [Online]. Available: <https://www.elsevier.es/es-revista-revista-espanola-geriatria-gerontologia-124-articulo-detector-automatico-caidas-monitorizacion-actividad-13110088>.
- [9] "Overview | Falls in older people: assessing risk and prevention | Guidance | NICE."
- [10] R. González *et al.*, "Desarrollo de un sistema de detección de caídas basado en acelerómetros," 2015.
- [11] Y. Delahoz and M. Labrador, "Survey on Fall Detection and Fall Prevention Using Wearable and External Sensors," *Sensors*, vol. 14, no. 10, pp. 19806–19842, Oct. 2014, doi: 10.3390/s141019806.
- [12] "Smart Care Technology Life changing, life saving." Accessed: Nov. 05, 2020. [Online]. Available: [www.tunstallhealthcare.com.au](http://www.tunstallhealthcare.com.au).
- [13] G. Mastorakis and D. Makris, "Fall detection system using Kinect's infrared sensor," *J. Real-Time Image Process.*, vol. 9, no. 4, pp. 635–646, Mar. 2014, doi: 10.1007/s11554-012-0246-9.
- [14] M. Belshaw, B. Taati, D. Giesbrecht, and A. Mihailidis, "INTELLIGENT VISION-BASED FALL DETECTION SYSTEM: PRELIMINARY RESULTS FROM A REAL-WORLD DEPLOYMENT," 2010.

- [15] M. Yu, A. Rhuma, S. M. Naqvi, L. Wang, and J. Chambers, "A posture recognition-based fall detection system for monitoring an elderly person in a smart home environment," *IEEE Trans. Inf. Technol. Biomed.*, vol. 16, no. 6, pp. 1274–1286, 2012, doi: 10.1109/TITB.2012.2214786.
- [16] H. Hawley-Hague, E. Boulton, A. Hall, K. Pfeiffer, and C. Todd, "Older adults' perceptions of technologies aimed at falls prevention, detection or monitoring: A systematic review," *Int. J. Med. Inform.*, vol. 83, no. 6, pp. 416–426, 2014, doi: 10.1016/j.ijmedinf.2014.03.002.
- [17] K. Tra and T. V. Pham, "Human fall detection based on adaptive background mixture model and HMM," in *International Conference on Advanced Technologies for Communications*, 2013, pp. 95–100, doi: 10.1109/ATC.2013.6698085.
- [18] Z. A. da S. Gama and A. Gómez-Conesa, "Risk factors for falls in the elderly: Systematic review," *Revista de Saude Publica*, vol. 42, no. 5. Universidade de Sao Paulo, pp. 946–956, 2008, doi: 10.1590/s0034-89102008000500022.
- [19] E. Castro Martín, A. DE La Comunidad Factores Asociados, and D. DE Luis Ángel Pérula Torres D Roger Ruiz, ""PREVALENCIA DE CAÍDAS EN."
- [20] N. Noury *et al.*, "Fall detection - Principles and methods," in *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 2007, pp. 1663–1666, doi: 10.1109/IEMBS.2007.4352627.
- [21] A. Yazar, F. Keskin, B. U. Töreyn, and A. E. Çetin, "Fall detection using single-tree complex wavelet transform," *Pattern Recognit. Lett.*, vol. 34, no. 15, pp. 1945–1952, 2013, doi: 10.1016/j.patrec.2012.12.010.
- [22] M. Wu, X. Dai, Y. D. Zhang, B. Davidson, M. G. Amin, and J. Zhang, "Fall detection based on sequential modeling of radar signal time-frequency features," in *Proceedings - 2013 IEEE International Conference on Healthcare Informatics, ICHI 2013*, 2013, pp. 169–174, doi: 10.1109/ICHI.2013.27.
- [23] "(PDF) Wagyromag: red inalámbrica de sensores inerciales para el registro y procesamiento de movimientos corporales."  
[https://www.researchgate.net/publication/262977585\\_Wagyromag\\_red\\_inalambrica\\_de\\_sensores\\_inerciales\\_para\\_el\\_registro\\_y\\_procesamiento\\_de\\_movimientos\\_corporales](https://www.researchgate.net/publication/262977585_Wagyromag_red_inalambrica_de_sensores_inerciales_para_el_registro_y_procesamiento_de_movimientos_corporales) (accessed Nov. 05, 2020).
- [24] J. Wang, Z. Zhang, B. Li, S. Lee, and R. Sherratt, "An enhanced fall detection system for elderly person monitoring using consumer home networks," *IEEE Trans. Consum. Electron.*, vol. 60, no. 1, pp. 23–29, 2014, doi: 10.1109/TCE.2014.6780921.
- [25] J. M. Infante and L. G. Lanz, "Area quirúrgica - Introducción," *Medicina Clinica*, vol. 124, no. SUPPL.1. Elsevier, pp. 16–17, Mar. 01, 2005, doi: 10.1016/S0210-5705(09)71003-9.
- [26] M. Ghislieri, L. Gastaldi, S. Pastorelli, S. Tadano, and V. Agostini, "Wearable inertial sensors to assess standing balance: a systematic review," *Sensors (Switzerland)*, vol. 19, no. 19. MDPI AG, Oct. 01, 2019, doi: 10.3390/s19194075.
- [27] L. Montesinos, R. Castaldo, and L. Pecchia, "Wearable inertial sensors for fall risk assessment and prediction in older adults: A systematic review and meta-analysis," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 3. Institute of Electrical and Electronics Engineers Inc., pp. 573–582, Mar. 01, 2018, doi: 10.1109/TNSRE.2017.2771383.

- [28] J. J. Craig, A. P. Bruetsch, S. G. Lynch, F. B. Horak, and J. M. Huisinga, "Instrumented balance and walking assessments in persons with multiple sclerosis show strong test-retest reliability," *J. Neuroeng. Rehabil.*, vol. 14, no. 1, p. 43, May 2017, doi: 10.1186/s12984-017-0251-0.
- [29] A. Rouis, N. Rezzoug, and P. Gorce, "Validity of a low-cost wearable device for body sway parameter evaluation," *Comput. Methods Biomech. Biomed. Engin.*, vol. 17, no. SUPP1, pp. 182–183, 2014, doi: 10.1080/10255842.2014.931671.
- [30] N. Jia, "Detecting Human Falls with a 3-Axis Digital Accelerometer," 2009.
- [31] K. Chaccour, R. Darazi, A. H. El Hassani, and E. Andres, "From Fall Detection to Fall Prevention: A Generic Classification of Fall-Related Systems," *IEEE Sens. J.*, vol. 17, no. 3, pp. 812–822, Feb. 2017, doi: 10.1109/JSEN.2016.2628099.
- [32] N. E. Huang *et al.*, "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis," *Proc. R. Soc. London. Ser. A Math. Phys. Eng. Sci.*, vol. 454, no. 1971, pp. 903–995, Mar. 1998, doi: 10.1098/rspa.1998.0193.
- [33] N. E. Huang, "INTRODUCTION TO THE HILBERT–HUANG TRANSFORM AND ITS RELATED MATHEMATICAL PROBLEMS," 2005, pp. 1–26.
- [34] A. O. Andrade, P. Kyberd, and S. J. Nasuto, "The application of the Hilbert spectrum to the analysis of electromyographic signals," *Inf. Sci. (Ny).*, vol. 178, no. 9, pp. 2176–2193, May 2008, doi: 10.1016/j.ins.2007.12.013.
- [35] N. Pannurat, S. Thiemjarus, and E. Nantajeewarawat, "Automatic fall monitoring: A review," *Sensors (Switzerland)*, vol. 14, no. 7. MDPI AG, pp. 12900–12936, Jul. 18, 2014, doi: 10.3390/s140712900.
- [36] E. Casilari, J.-A. Santoyo-Ramón, and J.-M. Cano-García, "Analysis of Public Datasets for Wearable Fall Detection Systems," *Sensors*, vol. 17, no. 7, p. 1513, Jun. 2017, doi: 10.3390/s17071513.
- [37] S. R. Lord, J. A. Ward, P. Williams, and K. J. Anstey, "An epidemiological study of falls in older community-dwelling women: the Randwick falls and fractures study," *Aust. J. Public Health*, vol. 17, no. 3, pp. 240–245, Sep. 1993, doi: 10.1111/j.1753-6405.1993.tb00143.x.
- [38] L. Atallah *et al.*, "Validation Of An Ear Worn Sensor For Activity Monitoring In COPD," in *American Thoracic Society International Conference Meetings Abstracts American Thoracic Society International Conference Meetings Abstracts*, May 2010, pp. A1211–A1211, doi: 10.1164/ajrccm-conference.2010.181.1\_meetingabstracts.a1211.
- [39] A. Leardini, G. Lullini, S. Giannini, L. Berti, M. Ortolani, and P. Caravaggi, "Validation of the angular measurements of a new inertial-measurement-unit based rehabilitation system: Comparison with state-of-the-art gait analysis," *J. Neuroeng. Rehabil.*, vol. 11, no. 1, Sep. 2014, doi: 10.1186/1743-0003-11-136.
- [40] I. Cleland *et al.*, "Optimal Placement of Accelerometers for the Detection of Everyday Activities," *Sensors*, vol. 13, no. 7, pp. 9183–9200, Jul. 2013, doi: 10.3390/s130709183.
- [41] H. Xie and Z. Wang, "Mean frequency derived via Hilbert-Huang transform with application to fatigue EMG signal analysis," *Comput. Methods Programs Biomed.*, vol. 82, no. 2, pp. 114–120, May 2006, doi: 10.1016/j.cmpb.2006.02.009.

- [42] M. Ozsert, O. Yavuz, and L. Durak-Ata, "Analysis and classification of compressed EMG signals by wavelet transform via alternative neural networks algorithms," *Comput. Methods Biomech. Biomed. Engin.*, vol. 14, no. 6, pp. 521–525, 2011, doi: 10.1080/10255842.2010.485130.
- [43] V. K. Mishra, V. Bajaj, A. Kumar, and G. K. Singh, "Analysis of ALS and normal EMG signals based on empirical mode decomposition," *IET Sci. Meas. Technol.*, vol. 10, no. 8, pp. 963–971, Nov. 2016, doi: 10.1049/iet-smt.2016.0208.
- [44] A. K. Bourke *et al.*, "Assessment of waist-worn tri-axial accelerometer based fall-detection algorithms using continuous unsupervised activities," in *2010 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC'10*, 2010, pp. 2782–2785, doi: 10.1109/IEMBS.2010.5626364.
- [45] M. Asghari Oskoei, M. A. Oskoei, and H. Hu, "Myoelectric control systems—A survey," *Biomed. Signal Process. Control*, vol. 2, no. 4, pp. 275–294, Accessed: Nov. 05, 2020. [Online]. Available: [https://www.academia.edu/8055151/Myoelectric\\_control\\_systems\\_A\\_survey](https://www.academia.edu/8055151/Myoelectric_control_systems_A_survey).
- [46] "Prueba 't' de Student."
- [47] "Introduccion al SPSS, Universitat de Valencia." <https://www.uv.es/innovamide/spss/0702b.wiki> (accessed Nov. 10, 2020).
- [48] "Análisis de Varianza | Análisis de variación | Spss." <https://es.scribd.com/document/152899033/Analisis-de-Varianza> (accessed Nov. 10, 2020).