



Trabajo Fin de Máster

Desarrollo del procedimiento de detección de caídas en ancianos mediante plantillas inteligentes

Development of the study detection of falls in the elderly through smart insoles

Autor

Rebeca Teresa Blanco

Director

Roberto Casas Nebra
Bonifacio Martín del Brío

ESCUELA DE INGENIERÍA Y ARQUITECTURA
2020

Resumen

La Organización Mundial de la Salud (*World Health Organization. Fact sheets.*, Last update 16 Jan. 2018) estima que cada año se producen 646.000 caídas fatales, lo que la convierte en la segunda causa de muerte por lesiones no intencionales, después de las lesiones causadas por el tráfico. La mayor cantidad de caídas fatales se produce en personas mayores de 65 años, debido a que la mayor morbilidad ocurre a partir de esta edad. Por lo tanto, la población anciana va a ser nuestro objeto de estudio.

En siguiente Trabajo de Fin de Máster (*TFM*) se desarrolla un procedimiento de detección de caídas en ancianos mediante unas plantillas sensorizadas. Está desarrollado en cuatro fases principales: estudio del estado del arte, diseño del procedimiento, procesado de datos y resultados y conclusiones. El objetivo principal del trabajo es la obtención de un modelo de detección de caídas fiable (alta precisión y un número de falsos positivos nulo).

El hardware utilizado para la recogida de datos deriva de una colaboración con la empresa Podoactiva y el grupo de investigación HOWLab de la Universidad de Zaragoza. Estas plantillas, contiene sensores (acelerómetro y resistivos de presión) y mediante un módulo *bluetooth* mandan los datos a unos receptores. Estos receptores han sido desarrollados por el grupo de investigación HOWLab de la Universidad de Zaragoza. Los detalles técnicos del hardware utilizado se encuentran en el Anexo B.

A lo largo de este trabajo se desarrollan cada una de las fases implicadas, así como la explicación de las decisiones de diseño tomadas en cada una de ellas. Finalmente se realizarán una serie de conclusiones y posibles líneas futuras.

Índice

1. Introducción	1
1.1. Motivación y contexto	1
1.2. Objetivos	2
1.3. Alcance	2
1.4. Estructura	3
2. Estado del arte	4
2.1. Introducción	4
2.2. Tipos de caídas	5
2.3. Técnicas de detección de caídas	6
2.3.1. Detección de caídas mediante <i>wearables</i>	7
2.3.2. Detección de caídas mediante sensores localizados en los pies	8
2.4. Procesado de datos	8
2.4.1. Obtención de los datos en crudo	9
2.4.2. Pre-procesado	9
2.4.3. Reducción de la dimensionalidad	9
2.4.4. Extracción de características	9
2.4.5. Representación semántica	9
2.5. Tablas comparativas	10
2.6. Conclusión	14
3. Diseño del procedimiento	15
3.1. Introducción	15
3.2. Definición del sensado	15
3.3. Definición de la base de datos	15
3.4. Definición del procedimiento de ensayos	16
3.4.1. Materiales	16
3.4.2. Ensayos	16

4. Procesado de los datos	20
4.1. Introducción	20
4.2. Preprocesado	20
4.2.1. Cálculo de ventana deslizante	21
4.2.2. Cálculo analítico	22
4.3. Reducción de la dimensionalidad	22
4.3.1. Análisis PCA	23
4.3.2. Selección de características	23
4.4. Extracción de características	25
4.5. Representación semántica	26
4.5.1. Algoritmo basado en umbrales	26
4.5.2. Algoritmo basado en modelos <i>machine learning</i>	31
4.5.3. Variabilidad de los modelos	33
5. Resultados	34
5.1. Introducción	34
5.2. Modelos totales	34
5.3. Modelos de sujetos	36
5.4. Modelos Reducidos	37
5.5. Modelos máquina estados	37
5.6. Discusión de resultados	39
6. Conclusiones y líneas futuras	40
6.1. Introducción	40
6.2. Conclusiones	40
6.3. Líneas futuras	41
Referencias	42
Lista de Figuras	45
Lista de Tablas	46
Anexos	47
A. Algoritmos	48
B. Detalles técnicos	105
B.1. Receptores <i>bluetooth</i> HOWlab	105
B.2. Plantillas Podoactiva	106

C. Análisis variables	107
D. Tablas de resultados	116

Capítulo 1

Introducción

1.1. Motivación y contexto

Estudios indican que la mayoría de caídas entre la gente mayor se producen a partir de los 65 años debido a factores extrínsecos (del exterior) e intrínsecos (salud de la persona), siendo así la segunda causa de muerte en el mundo.

En la actualidad hay abundante literatura sobre estudios de caídas, sin embargo no tantos de técnicas de detección y sistemas de detección de las mismas. Para poder detectar caídas se necesita diferenciar entre qué es caída y qué no lo es, estas últimas se llaman ADL (*Activities of Day Living*). Dentro de los sistemas de detección de caídas basadas en *wearables* se encuentran, más concretamente, los sistemas localizados en los pies, en concreto las plantillas sensorizadas.

Debido a las numerosas caídas y las consecuencias que traen consigo es importante su detección y/o prevención. En nuestro caso, nos centramos en detección. Por este motivo surge el presente Trabajo Final de Master (TFM), desarrollado en la Universidad de Zaragoza dentro del grupo de investigación HOWLab (*Human Openware Research Lab* (HOWLab, 2020) cuyo objetivo principal es la investigación y desarrollo de tecnologías centradas en las personas y sus entornos, Figura 1.1. Tomando como punto de partida unas plantillas sensorizadas como sistema de detección de caídas, resultado de una colaboración entre HOWLab y Podoactiva (Podoactiva, 2020).



Figura 1.1: HOWLab, Escuela de Ingeniería y Arquitectura de Zaragoza y Podoactiva

1.2. Objetivos

El objetivo principal de este Trabajo de Fin de Máster consiste en la realización del desarrollo de un procedimiento de detección de caídas fiable. Tras el estudio del estado del arte realizado, se ha detectado que la principal problemática que existe a la hora de detectar caídas es la falta de datos del mundo real de estas mismas, no existe un marco global y, por ello, es necesario que la construcción de la base de datos sea grande y fiable, y así no dé lugar a falsos positivos (FP). Para alcanzar este objetivo principal, se proponen los siguientes objetivos:

Este proyecto aborda seis objetivos principales.

- Estudio del estado del arte de técnicas de detección de caídas mediante *wearables*, en concreto, sensores localizados en los pies.
- Desarrollo de procedimientos de ensayo y detección de caídas.
- Construcción de base de datos.
- Tratamiento y análisis (preprocesado) de datos.
- Desarrollo de algoritmos de detección de caídas.
- Obtención y análisis de resultados.

1.3. Alcance

Con el fin de conseguir el objetivo principal del trabajo, se divide el problema de manera que se cumplan cada uno de los objetivos parciales. De esta forma, se descompone el trabajo en diferentes fases.

La fase inicial consiste en la búsqueda, selección y estudio de los artículos más relevantes de la temática de detección de caídas en ancianos mediante *wearables*.

En base a la fase anterior, en la siguiente fase se eligen las características más relevantes para realizar una buena detección de caídas y se definen los ensayos de caídas y ADL a realizar.

Una vez definidos los ensayos, se construye la base de datos realizando los ensayos en un laboratorio y, guardando los datos de los mismos.

La siguiente fase involucra el procesado de los datos obtenidos, el cual finaliza mediante la representación semántica de los mismos.

La penúltima fase consiste en desarrollar algoritmos con la ayuda de la información obtenida de la representación semántica. Se desarrollan dos tipos de algoritmos, los basados en métodos analíticos (Máquina de estados mediante umbrales) y los basados en *machine learning*.

Finalmente, se extraen las conclusiones en base a los resultados obtenidos de los algoritmos realizados y se exponen las posibles líneas futuras de trabajo.

1.4. Estructura

El contenido de este trabajo se resume de la siguiente manera:

- Capítulo 2 - **Estado del arte** : en este capítulo se estudian las técnicas de detección de caídas y, más en profundidad, las basadas en *wearables*.
- Capítulo 3 - **Diseño del procedimiento**: en este capítulo se define el procedimiento seguido para la elaboración de la base de datos, así como los materiales necesarios para la elaboración de los ensayos y la definición de estos mismos.
- Capítulo 4 - **Procesado de los datos**: en este capítulo se explican y desarrollan las fases del procesado de datos involucradas en el problema a tratar.
- Capítulo 5 - **Resultados**: en este capítulo se recogen y exponen los resultados obtenidos.
- Capítulo 6 - **Conclusiones y líneas futuras**: en este capítulo se desarrollan las conclusiones obtenidas del trabajo y se proponen una serie de líneas futuras.

Capítulo 2

Estado del arte

Para la elaboración de este estado del arte se ha buscado en el buscador *Google Scholar* las siguientes palabras clave: *fall elderly causes*, *fall detection wearables*, *fall detection*, *fall detection insoles* y *fall detection foot*. El rango de resultados se ha acotado entre artículos publicados en 2010 hasta la actualidad.

2.1. Introducción

Estudios indican que la mayoría de caídas entre la gente mayor se producen a partir de los 65 años, mayoritariamente mujeres (Dhargave y Sendhilkumar, 2016), (Ozturk y cols., 2017), (Moraes y cols., 2017), (Sharif, Al-Harbi, Al-Shihabi, Al-Daour, y Sharif, 2018), aunque la mayor mortalidad se da en hombres (*World Health Organization. Fact sheets.*, Last update 16 Jan. 2018).

La Organización Mundial de la Salud (*World Health Organization. Fact sheets.*, Last update 16 Jan. 2018) estima que cada año se producen 646.000 caídas fatales, lo que la convierte en la segunda causa de muerte por lesiones no intencionales, después de las lesiones causadas por el tráfico. De éstas, más del 80 % se encuentran en países de ingresos bajos y medianos. La mayor cantidad de caídas fatales se produce en personas mayores de 65 años, debido a que la mayor morbilidad ocurre a partir de esta edad. Cada año se producen 37,3 millones de caídas lo suficientemente graves como para requerir atención médica.

Las caídas suelen producirse por la mañana, ya que son horas de mayor periodo de actividad respecto al resto del día. Los lugares donde se producen con mayor frecuencia son el baño y la calle. (Dhargave y Sendhilkumar, 2016).

En estas caídas se ven involucrados dos tipos de riesgo, el intrínseco y el extrínseco. El primero de ellos se relaciona con las características de la propia persona: el envejecimiento (edad y genero) (Gamage, Rathnayake, y Alwis, 2018), asociado con

la salud de la persona, causante de músculos débiles o problemas de desequilibrio (Gamage y cols., 2018; Medeiros y cols., 2014; Alves y cols., 2016; Ronthal, 2019).

Los principales riesgos intrínsecos se deben a problemas de visión y/o oído, problemas cognitivos, mareos, miedo a caer, discapacidad, hipertensión, problemas neurológicos (Parkinson), diabetes, mareos, depresión... Estos riesgos intrínsecos constituyen comorbilidaes en el individuo, produciendo un incremento significativo en el riesgo de caída de este mismo (Moraes y cols., 2017),(Sharif y cols., 2018). El riesgo extrínseco se relaciona con el entorno. Los principales riesgos extrínsecos se deben a factores externos: el entorno, como el terreno, escaleras o cualquier objeto (por ejemplo, muebles) y la toma de medicamentos psicoactivos (Rahmawati, Mustafidah, Pramantara, y Wahab, 2019), (Reis y Jesus, 2017) con los que la persona sea propensa a tropezarse.

Debido a las numerosas caídas y las consecuencias que traen consigo es importante su detección y/o prevención. En nuestro caso, nos centramos en la detección de las mismas.

2.2. Tipos de caídas

La tipificación de caídas varía según los autores, la mayoría de ellos define al menos cuatro principales (hacia delante, hacia atrás, hacia el lado derecho y hacia el lado izquierdo) pero sin ningún argumento previo que les lleve a esta selección (Rakhman, Nugroho, Widyawan, y Kurnianingsih, 2014; Sun, Wang, Pei, Tao, y Chen, 2015; Tao, Qian, Chen, Shi, y Xu, 2011; Nguyen, Mirza, Naeem, y Baig, 2017; Wang, Peng, y Zhou, 2019), (Otanasp, 2016) argumenta esta selección mediante (Noury, Rumeau, Bourke, ÓLaighin, y Lundy, 2008) donde se pone en manifiesto que la mayoría de las caídas ocurren en el plano sagital (hacia delante o hacia atrás) como consecuencia de un movimiento voluntario (agacharse, levantarse, sentarse...) y que la ruptura de cadera es muy frecuente en ambos tipos de caídas. Otros como (Shi y cols., 2015) y (Lee, Chang Min, Jisu, Shinsuk, y Hyun, 2019) incluyen resbalones,(Shibuya y cols., 2015) incluye variantes con especificaciones como doblar o estirar las rodillas al caer, tropezarse y sentarse. (Montanini, Del Campo, Perla, Spinsante, y Gambi, 2018) divide las caídas en 8 grupos dependiendo de su finalización (tumbado, sentado y orientación de rodillas), diferenciando, a su vez, cuatro situaciones, dependiendo de si el individuo se levanta o no del suelo. Finalmente, (Su, Ho, Rantz, y Skubic, 2015) hace distinción entre 14 tipos de caídas en base al estudio de dos bases de datos de caídas realizadas por el Centro de cuidado de ancianos y rehabilitación de la universidad de Missouri, en una de ellas se recopilan vídeos de caídas de los baños de unos apartamentos residencia

de ancianos en TigerPlace (Missouri) y en la otra vídeos de caídas en la sala de estar.

Como se observa, no existe una justificación clara para definir los tipos de caídas, por ello, para una buena realización y detección de estas mismas, surge la necesidad de estudio de éstas. Tener datos reales es muy difícil porque no hay muchas bases de datos, uno de los mejores análisis encontrados es el de (Robinovitch y cols., 2013), en él se capturan 227 caídas de 130 individuos (edad media 78 años, desviación estándar 10). En sus resultados se refleja que la causa más frecuente de caídas se debe el cambio de peso incorrecto, que representa el 41 % (93 de 227) de las caídas, seguido de tropiezos (48, 21 %), golpes (25, 11 %), pérdida de soporte (25, 11 %) y colapso (24, 11 %). Los resbalones representan solo el 3 % (seis) de las caídas. Las tres actividades asociadas con la mayor proporción de caídas son caminar hacia adelante (54 de 227 caídas, 24 %), pararse quieto (29 caídas, 13 %) y sentarse (28 caídas, 12 %). Además, comparan esta información con informes anteriores del entorno y concluyen que hay una mayor ocurrencia de caídas durante la posición de pie y su translación, una menor ocurrencia al caminar y una mayor proporción debido a las perturbaciones del centro de masa que las perturbaciones de la base de apoyo. De este artículo se obtiene y se selecciona como base de datos de estudio (Robinovitch, 2018), base de datos de 105 vídeos de caídas en espacios comunes de una residencia de ancianos.

Tras su estudio se han seleccionado cinco tipos principales de caídas: hacia atrás, hacia delante, lateral estando de pie, lateral andando y al sentarse. La adición de esta última se debe a que su dinámica es diferente a una caída hacia atrás. Dentro de estos 5 tipos principales, se hará distinción de subtipos de caídas que dependerán de la finalización de estas mismas, en función de la orientación del cuerpo.

2.3. Técnicas de detección de caídas

Las técnicas de detección de caídas se pueden distribuir en dos grupos, las que están basadas en *wearables* y las basadas en otras tecnologías como cámaras (De Miguel, Brunete, Hernando, y Gambao, 2017), radar Doppler (Su y cols., 2015) o micrófonos (Li, Ho, y Popescu, 2012). Siendo las primeras objeto de interés.

A su vez las técnicas basadas en *wearables* se dividen en dos grupos: técnicas en las que el sensor se coloca en cualquier parte del cuerpo (cabeza pecho, cintura...) y técnicas en las que el sensor se coloca solamente en el pie (ya sea atado o mediante una plantilla). Se realiza esta distinción de grupos debido al especial interés en este último (ya que va a ser nuestro objeto de estudio). Más adelante, en el apartado Tablas comparativas, aparecen las tablas comparativas de los artículos del estudio realizado.

2.3.1. Detección de caídas mediante *wearables*

La detección de caídas mediante *wearables* se realiza a través de sensores localizados en una o varias partes del cuerpo. Mediante la toma de datos de estos sensores y, con la abstracción de los mismos, se lleva a cabo la detección de caídas.

La mayor parte de los sensores utilizados en la detección de caídas mediante *wearables* son acelerómetros (Otanasa, 2016; Yu, Chen, y Brown, 2018; Nguyen, Zhou, Mirza, y Naeem, 2018), acelerómetro y sensores de presión (Trkov, Chen, Yi, y Liu, 2015; Howcroft, Kofman, y Lemaire, 2017; Lee y cols., 2019), acelerómetro y giróscopo (Shibuya y cols., 2015; Rakhman y cols., 2014) o combinación de los tres (Shi y cols., 2015).

Se suelen localizar en el pecho (Rakhman y cols., 2014; Otanasa, 2016; Yu y cols., 2018), pelvis y T4 (Shibuya y cols., 2015), pelvis y pies (Shi y cols., 2015; Lee y cols., 2019), pelvis, pierna, pies y cabeza (Howcroft y cols., 2017), pierna (Nguyen y cols., 2018) o pierna y pies (Trkov y cols., 2015).

La construcción de la base de datos se realiza mediante la toma de datos del sensor o distintos sensores. El tamaño de las mismas es variado y, suele ser mayor cuando se aplican algoritmos de *machine learning*. (Rakhman y cols., 2014) recoge 120 caídas y 210 ADL, (Shi y cols., 2015) recoge 628 caídas y 1698 ADL para entrenamiento y 264 caídas y 642 ADL para test, (Shibuya y cols., 2015) recoge 101 caídas, 69 ADL y 152 DGI, (Yu y cols., 2018) recoge 200 caídas y 385 ADL para entrenamiento y 22 caídas y 2618 ADL para test y, por último, (Lee y cols., 2019) recoge 720 caídas y 1440 ADL (70 % para entrenamiento y 30 % para test). (Howcroft y cols., 2017) no menciona el tamaño de la muestra pero si indica que utiliza el 75 % de los datos para entrenamiento y el 25 % para test.

Las exactitudes más altas en la detección de caídas las consiguen (Rakhman y cols., 2014) con un 98 % de media y una tasa de falsos positivos del 2 %, (Trkov y cols., 2015) con un 97.72 % con el sensor localizado en la pelvis y un 98.565 % en pies y pelvis, (Shibuya y cols., 2015) con un 98.8 % con el sensor localizado en la vertebra T4, pero se detectan falsos positivos en la caída hacia atrás, y un 98.7 % con el sensor localizado en pelvis y, por último, (Lee y cols., 2019) con un 95 % pero, detección de 65 falsos positivos hacia atrás, 1 hacia los lados y 71 al sentarse (para diferentes modelos). Aunque no menciona la exactitud, (Yu y cols., 2018) indica que se consigue una tasa de falsos positivos de menos del 2 %.

2.3.2. Detección de caídas mediante sensores localizados en los pies

La mayor parte de los sensores que se utilizan en la detección de caídas mediante sensores localizados en los pies son acelerómetros (Sim y cols., 2011; Sun y cols., 2015), acelerómetro y presión (Montanini y cols., 2018), acelerómetro y giróscopo (Wang y cols., 2019), giróscopo y presión (Rosa y cols., 2017), presión (Tao y cols., 2011) y RFID (Chen y Lin, 2010).

De la misma forma que en el apartado anterior, el tamaño de la base de datos es muy variado, siendo mayor cuando se aplican algoritmos de *machine learning*. (Sim y cols., 2011) recoge 18 muestras para cada tipo de caída, (Sun y cols., 2015) recoge 120 muestras para cada tipo de caída, (Montanini y cols., 2018) recoge 544 caídas y 136 ADL y, por último, (Wang y cols., 2019) recoge 6800 caídas y 1000 ADL Wang. Por otro lado, (Rosa y cols., 2017) utiliza una base de datos ya construida en el proyecto WIISEL.

Las exactitudes más altas en la detección de caídas las consiguen (Sun y cols., 2015) con un 100 % en caídas hacia delante y un 92 % en caídas hacia atrás en plano y 80 % en cuesta pero con una tasa de falsos positivos hacia atrás del 8 %, (Montanini y cols., 2018) con un 90 % y una tasa de falsos positivos de 0 en escenario real y, por último, (Wang y cols., 2019) con un 98.61 %. (Sim y cols., 2011) no menciona la exactitud en la detección de caídas pero si indica que se detectan falsos positivos en caídas hacia atrás y hacia los lados.

2.4. Procesado de datos

En IoT las fases del proceso de abstracción de los datos son las siguientes: obtención de los datos en crudo, pre-procesado, reducción de dimensionalidad, extracción de características, inferencia y representación semántica, ver Figura 2.1. La aplicación de las fases intermedias depende del tipo de aplicación.

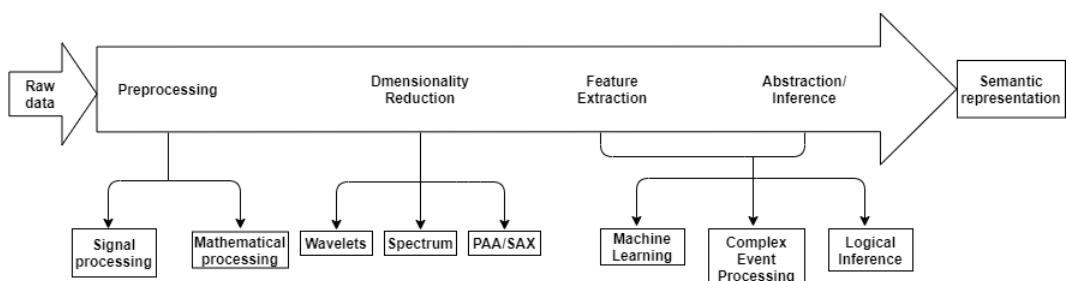


Figura 2.1: Fases del procesado de datos

2.4.1. Obtención de los datos en crudo

Como se puede observar en las Tablas 2.1 y 2.4 el rango de frecuencias con el se realiza de la toma de datos de aceleraciones, ángulos y presiones se encuentra entorno a los 100Hz.

2.4.2. Pre-procesado

En la fase de pre-procesado se preparan los datos para su utilización en las fases posteriores. Este tratamiento se puede realizar mediante filtros y estadística.

En esta fase la mayoría de autores aplican métodos estadísticos, (Shi y cols., 2015) calcula el valor máximo, (Rakhman y cols., 2014) y (Shibuya y cols., 2015) calculan el valor máximo y mínimo, (Sim y cols., 2011) y (Nguyen y cols., 2018) calculan la media, (Otanap, 2016) y (Shi y cols., 2015) calculan la media y desviación estándar y (Howcroft y cols., 2017) calcula el valor máximo, mínimo, media y mediana. Aun que, con menos frecuencia, también se hace uso de filtros, (Trkov y cols., 2015) aplica filtros Kalman, (Rakhman y cols., 2014) y (Sim y cols., 2011) filtro de paso alto e incluso otros más específicos (Rosa y cols., 2017).

2.4.3. Reducción de la dimensionalidad

La mayoría de los autores no suelen realizar esta fase ya que, utilizan pocas variables o realizan una extracción de características con el fin de reducir dicha dimensionalidad. Entre ellos, (Tao y cols., 2011) aplica el análisis PCA (Análisis de Componentes Principales).

2.4.4. Extracción de características

La extracción de características y, a su vez, representación semántica, se realiza en mayor parte mediante algoritmos de *machine learning* o modelos ocultos de Markov. (Howcroft y cols., 2017) y (Tao y cols., 2011) aplican inferencia bayesiana y redes neuronales (NN), (Yu y cols., 2018) utiliza modelos ocultos de Markov (HMM) y (Wang y cols., 2019) redes neuronales convolucionales CNN.

2.4.5. Representación semántica

Las técnicas de detección de caídas que más se utilizan se realizan mediante algoritmos de umbral (Rosa y cols., 2017), (Chen y Lin, 2010), (Sim y cols., 2011), (Rakhman y cols., 2014), (Sun y cols., 2015), (Otanap, 2016), (Montanini y cols., 2018), pueden estar combinados con otros como ACFDA (*Acceleration Change-based*

Falls Detection Algorithm) (Nguyen y cols., 2018), árbol de decisión (Shi y cols., 2015), (Lee y cols., 2019). También se utilizan máquinas de vectores de soporte (SVM) (Shibuya y cols., 2015), (Howcroft y cols., 2017) y modelos dinámicos (Trkov y cols., 2015).

2.5. Tablas comparativas

Tabla 2.1: *Set up* y Características de sensado

Artículo	<i>Set up</i>	Características de sensado				Características extraídas
		Sensores	Posición	Frecuencia	Ventana	
Rakhman y cols, 2014	Smartphone en bolsillo izquierdo camisa	Acelerómetro y giróscopo	Pecho	-	-	Máximo, mínimo y módulo de aceleración y ángulos giróscopo
Trkov y cols, 2015	5 acelerómetros en lateral de cada pierna y plantillas en los zapatos	10 acelerómetros y 2 de fuerza	Pierna y pies	100Hz	1s	Desplazamiento talón, velocidad talón, ángulo de la pierna, ángulo del muslo
Shi y cols, 2015	-	Acelerómetro, fuerza y giróscopo	Pelvis y pies	96fps	20 min para ADL	-
Shibuya y cols, 2015	WGAS (<i>Wireless Analysis Sensor</i>) en una caja 3D	Acelerómetro y giróscopo	Pelvis y vertebra T4	160Hz	-	Rango de la velocidad angular, rango de la aceleración. Ambas en los 3 ejes
Otanasa, 2016	-	Acelerómetro	Pecho	-	-	Módulo aceleración en tiempo real
Howcroft y cols, 2017	Sensores sujetos con banda en la cabeza y pierna y cinturón en pelvis	Acelerómetro y fuerza	Pelvis, pierna pies y cabeza	fuerzas: 120Hz acelerómetro: 50Hz	-	Temporal, COP, Impulso, estáticos, FFT, máximo exp. Layapunov ratio de armónico pares e impares
Nguyen y cols, 2018	Smartphone en bolsillo izquierdo de la pierna	Acelerómetro	Distribuidos por la pierna	-	-	Aceleración
Yu y cols, 2018	Bolsillo izquierdo de la camisa	Acelerómetro	Pecho	12,5Hz	De 3s a 10 s	Módulo de la aceleración
Lee, 2019	Plantillas en los zapatos	Acelerómetro y fuerza	Pelvis y pies	100Hz	-	Módulo y variación de aceleración, ángulos, COP y variaciones de COP en ejes x e y
Chen y Lin, 2010	Sala con tag y persona camina	Tag activo RFID y tags pasivos distribuidos por el suelo	En talón	2.45GHz	-	Longitud del paso y localización del anciano en la sala

Tabla 2.2: Detección y Características de la base de datos

Artículo	Método de reconocimiento	Características de base de datos			
		Edad	Nº experimentos	Procedimiento	Nº personas
Rakhman y cols, 2014	Umbral	-	120 caídas 210 ADL	En laboratorio: ADL y caídas en colchoneta	1 hombre
Trkov y cols, 2015	<i>Extended Kalman</i> filtro (EKF)	-	-	En laboratorio: caminar en plataforma ritmo cte y resbalones	1 hombre
Shi y cols, 2015	Árbol de decisión (Algoritmo C4.5, J48 en Weka)	-	628 caídas y 1698 ADL, 264 caídas y 642 ADL (<i>test set</i>)	-	12 hombres y 1 mujer
Shibuya y cols, 2015	SVM de 6 entradas	-	101 caídas 69 ADL 152 DGI	En laboratorio: ADL y caídas en colchoneta	2
Otanasp, 2016	Umbral dinámico	19-21	192 ADL y caídas (48 de cada tipo: delante, atrás, lados)	-	4 hombres y 2 mujeres
Howcroft y cols, 2017	SVM Bayesiana Red neuronal (NN)	65 o más	75 % de participantes para data y 25 % para test	-	75
Nguyen y cols, 2018	Umbral ACFDA	27	-	En laboratorio: ADL y caídas en alfombra	1 hombre
Yu y cols, 2018	Modelos Markov	23-29	200 caídas y 385 ADL (datos), 22 caídas y 2618 ADL (<i>test</i>)	En laboratorio: ADL y caídas FARSEEING (<i>data set</i>)	10
Lee, 2019	Árbol de decisión	27,22 2,7	720 caídas y 1440 ADL, 70 % entrenamiento y 30 % test	En laboratorio: ADL y caídas en reposa pies y colchón	9 hombres
Chen y Lin, 2010	Grado de anormalidad de la marcha	-	5 veces 100 lecturas del sensor	Andar por el suelo de una habitación	-

Tabla 2.3: Resultados

Artículo	Resultados		
	Exactitud	Falsos positivos	
Rakhman y cols, 2014	93,3 % (120 caídas) Media: 98 % (210 ADL)		2 %
Trkov y cols, 2015	-		-
Shi y cols, 2015	Pelvis: 97,792 % Pelvis + pies: 98,565 %		-
Shibuya y cols, 2015	T4: 98,8 % Pelvis: 98,7 %	T4: Caída hacia delante (rodillas flexionadas), tropiezo con objeto pequeño, caída mientras te sientas, estirarse estando de pie	
Otanasaap, 2016	ADL: 97,4 %		-
Howcroft y cols, 2017	Cabeza+pelvis+pierza izq+ DT: 57 % Pelvis + DT: 54 %		-
Nguyen y cols, 2018	-		-
Yu y cols, 2018	98,1 % (base datos) 78,6 % (mundo real)		Menos de 2 %
Lee, 2019	95 %	Hacia atrás 65, hacia los lados 1, al sentarse 71 (Estos datos se han recogido para diferentes modelos)	
Chen y Lin, 2010	-		-

Tabla 2.4: *Set up* y Características de sensado

Artículo	Set up	Características de sensado				Características extraídas
		Sensores	Posición	Frecuencia	Ventana	
Tao y cols, 2011	-	8 pares de sensores de fuerza resistivos	Distribuidos por la parte posterior y anterior de la planta	-	10s	-
Sim y cols, 2011	Sensor sujeto con velcro	Acelerómetros	Parte posterior de la planta	255Hz	-	Amplitud media de aceleración
Sun y cols, 2015	Sensor sujeto con cinta	Dos acelerómetros	En medio de la planta y ortogonales entre sí	-	-	Ángulo
Rosa y cols, 2017	Sujetos usan el sistema durante 2 semanas durante ADL y caminar	14 tiras de sensores de presión resistivos, acelerómetro y giróscopo	En medio de la planta	-	60s	Soporte único izquierdo, inclinación de la fuerza de golpe del talón izquierdo, amplitud media de la acel. medio lateral y el doble soporte derecho
Montanini y cols, 2018	Sensor en la plantilla dentro del zapato	3 sensores de fuerza y un acelerómetro	Sensores de fuerza en la parte posterior y talón. Acelerómetro en medio de la planta	100Hz	15s	Fuerza de los sensores y ángulos (<i>pitch</i> y <i>roll</i>)
Wang, y cols, 2019	Sensor en plantilla dentro del zapato	Acelerómetro y giróscopo	En el talón	50Hz	7s	-

Tabla 2.5: Detección y Características de la base de datos

Artículo	Método de reconocimiento	Características de base de datos			
		Edad	Nº experimentos	Procedimiento	Nº personas
Tao y cols, 2011	ANN de 8 entradas y entre 1 y 30 capas ocultas	-	-	En laboratorio: ensayos de ADL's y caídas	-
Sim y cols, 2011	Umbral de aceleración y un patrón de caída	26	18 para cada sujeto y tipo de caída	-	2 chicos y 1 chica
Sun y cols, 2015	Umbral variación del ángulo y función para FP	-	120 para cada tipo de caída	En laboratorio: caminar y caídas en 4 direcciones	1 joven
Rosa y cols, 2017	Mediante una secuencia de eventos de las características y cálculo del FRI	71,1	Base de datos WISEL	En laboratorio: caminar y no caminar	29
Montanini y cols, 2018	Detección fases de la marcha y cálculo del índice de caída	21-25 y 67	544 caídas y 136 ADL	En laboratorio: toma datos de ADL's y caídas	3 mujeres y 14 hombres. 2 ancianos (para test)
Wang, y cols, 2019	Redes neuronales convolucionales 1D (CNN9)	22-40	6.800 caídas y 1000 ADL	En laboratorio: datos de ADL's y caídas	5 hombres y 5 mujeres

Tabla 2.6: Resultados

Artículo	Resultados	
	Exactitud	Falsos positivos
Tao y cols, 2011	75 % (12 tests)	-
Sim y cols, 2011	ADL: 81.5 %	Caídas hacia los lados y hacia atrás
Sun y cols, 2015	100 % hacia delante 92 % hacia atrás (en plano) y 80 % hacia atrás (en cuesta)	hacia atrás
Rosa y cols, 2017	En ancianos con alto riesgo de caídas FRI difiere de los resultados clínicos	-
Montanini y cols, 2018	Media: 90 % Máxima: 97,1 %	0 % en escenario real
Wang, y cols, 2019	Media: 98,61 %	-

2.6. Conclusión

En base a lo comentado en el apartado anterior, (Montanini y cols., 2018) obtiene los mejores resultados en la detección de caídas con una obtención del 90 % de exactitud y una tasa de 0 % de falsos positivos. Seguido de (Shi y cols., 2015) con un 98,8 % (sensor en T4) y detección de falsos positivos hacia delante (no menciona la ocurrencia de falsos positivos). Por último, (Wang y cols., 2019) y (Shibuya y cols., 2015) que obtienen una exactitud de 98,61 % y 98,565 % en pelvis y pies, respectivamente, pero ninguno menciona la ocurrencia de falsos positivos. Por lo tanto, se puede concluir que se obtienen mejores resultados cuando:

- Los sensores se localizan en los pies, pelvis o combinación de ambas.
- Se utilizan algoritmos basados en el cálculo de índices DGI (*Dynamic Gait Index*) y FRI (*Fall Risk Index*) (Montanini y cols., 2018), máquinas de vectores de soporte (SVM) (Shibuya y cols., 2015), árboles de decisión (Shi y cols., 2015) y redes neuronales (CNN)(Wang y cols., 2019).

No obstante, hay que tener en cuenta que el principal problema a la hora de detectar caídas es la falta de datos de caídas del mundo real, aunque existen repositorios de conjunto de datos para ADL y caídas de investigaciones anteriores, sigue sin existir un marco de evaluación general. Esta carencia de información de datos conlleva al problema de falsos positivos. (Ren y Peng, 2019) menciona la realización de un sistema de detección de caídas debería adaptarse y aprender nuevas actividades para reducir estos falsos positivos.

Capítulo 3

Diseño del procedimiento

3.1. Introducción

En este capítulo se define el procedimiento seguido para la elaboración de la base de datos: definición del sensado, de la base de datos y del procedimiento de ensayos. Dentro de esta última sección se encuentran, además, los materiales necesarios para la elaboración de los ensayos y la definición de los mismos.

3.2. Definición del sensado

Los aspectos más relevantes a tener en cuenta en el proceso de sensado son los citados en el capítulo anterior y los que aparecen en las Tablas 2.1 y 2.4. En nuestro estudio utilizaremos datos de aceleraciones, aceleraciones angulares y ángulos, tanto en los tres ejes como su módulo, y presiones de la planta del pie (debajo de los huesos primer cuneiforme, cuboides, astrágalo y calcáneo).

Estos sensores, como se ha mencionado anteriormente, se encuentran en el interior de unas plantillas colocadas dentro de unas zapatillas deportivas.

Se toman datos de 16 subtipos de caídas y 15 subtipos de ADL, ensayados 10 veces cada uno por sujeto (en algunos casos se han ensayado más), en total se recogen 320 caídas y 330 ADL. Esta toma de datos se realiza a una frecuencia de 50Hz, el tiempo de ventana se define en el capítulo siguiente.

3.3. Definición de la base de datos

Los aspectos más relevantes a tener en cuenta para la definición de la base de datos son los citados en el capítulo anterior y los que aparecen en las Tablas 2.2 y 2.5. En nuestro caso, se ha realizado esta base de datos con 2 sujetos, un hombre y una mujer de 58 y 23 años, respectivamente.

3.4. Definición del procedimiento de ensayos

Los materiales necesarios para la realización de los ensayos son los siguientes:

3.4.1. Materiales

El material necesario para realizar los ensayos es el siguiente:

- Laboratorio amplio para poder caminar en línea recta al menos durante unos 7s
- Colchonetas de unos 5cm de espesor
- Objeto pesado o bien sujeto al suelo con el que tropezarse
- Mueble bien sujeto al suelo (mesa, silla, camilla...) para que no se mueva al agarrar
- Báscula para pesar a los sujetos
- Metro para medir a los sujetos

3.4.2. Ensayos

Nuestra detección de caídas está orientada a ancianos con un cierto nivel de autonomía, es decir, que no necesiten de objetos como sillas de ruedas o andadores para la realización de las ADL, por ello, no se han estudiado este tipo de caídas.

La base de datos (Robinovitch, 2018) escogida es la más grande que se ha encontrado en estudios recientes, posee 105 vídeos, cada uno de ellos lleva adjunto un fichero de datos en los que se reflejan las siguientes características: ID, género, edad, altura, peso, caídas en los últimos seis meses, independencia, CPS (*Cognitive Performance Scale*), visión, enfermedades, nº de medicaciones, tipo de medicación, herido, fractura cadera y heridas reportadas. Se han añadido seis características más a tener en cuenta (tipo de caída, situación de partida, evento desencadenante, desarrollo, situación final y evolución después de la caída) para segmentar las fases de las caídas y determinar si existen similitudes entre las mismas. Tras realizar el estudio se ha llegado a la conclusión de que la mayoría de las caídas se caracterizan por un patrón dinámico determinado, tanto en el tránscurso de la caída como en la situación final, por ello, se concluye que pueden clasificarse en tipos y subtipos. Se han seleccionado estos vídeos obtenido así una nueva base de datos de 59 caídas de 27 mujeres y 32 hombres, de media $83,33 \pm 8,16$ años, $165,12 \pm 11,82$ cm de altura y $63,57 \pm 13,01$ kg de peso. Cabe mencionar que la mayoría de ellos posee diferentes comorbilidades.

Parte de estas ADL se detectarán como falsos positivos (FP), actividades diarias clasificadas como caídas. Con el fin de reducir estos falsos positivos se identifican características en cada actividad para su definición, además cada ensayo estará etiquetado (nombre entre paréntesis).

A continuación se definen y dividen los ensayos en tipos y subtipos de ADL y caídas:

ADL

- **Caminar** (*Walk*): el sujeto debe caminar en linea recta durante 7-10s a un ritmo lento, simulando la marcha de un anciano.
- **Caminar falso positivo** (*Walk FP*): dentro de esta categoría se clasifican 3 tipos de actividades a ensayar.
 - Caminar con cambio de ritmo: el sujeto debe caminar unos 5m en línea recta con ritmo lento y seguidamente realiza un cambio de ritmo más rápido, durante otros 5m aproximadamente.
 - Caminar y girar: el sujeto debe caminar unos 5m en línea recta con ritmo lento y seguidamente efectúa un giro de 180° pivotando sobre una pierna. Se ensaya el giro hacia la derecha y hacia la izquierda.
 - Caminar y esquivar: el sujeto debe caminar unos 5m en línea recta con ritmo lento, seguidamente pivota a un lado para esquivar un objeto y finalmente continua su marcha realizando un pequeño giro para volver a su trayectoria original. Se ensaya el esquive hacia la derecha y hacia la izquierda.
- **Sentarse falso positivo** (*Sitting FP*): dentro de esta categoría se clasifican 3 tipos de actividades a ensayar.
 - Sentarse sin cruzar las piernas: el sujeto debe colocarse de espaldas a una silla y posteriormente flexionar las piernas despacio dejándose caer en la silla.
 - Sentarse cruzando las piernas: el sujeto se sienta de la misma manera que antes pero, una vez sentado, cruza una de las piernas.
 - Levantarse de estar sentado: el sujeto se levanta, con una leve ayuda de las manos, de la silla. Se ensaya tanto sin como con las piernas cruzadas.

- **Tumbarse** (*Lay*): el sujeto se sienta de la misma manera que antes, una vez sentado, gira el cuerpo mientras alza las piernas para apoyarlas en la camilla. Finalmente se acomoda, echando el cuerpo y tronco hacia atrás y se mantendrá unos segundos en esa posición. Se ensaya la subida hacia la derecha y hacia la izquierda.
- **Tumbarse falsos positivos** (*Lay FP*): dentro de esta categoría se clasifican 2 tipos de actividades a ensayar.
 - Tumbarse cruzando las piernas: el sujeto debe tumbarse de la misma manera que antes pero, una vez tumbado, cruza una de las piernas. Se ensaya la subida hacia la derecha y hacia la izquierda.
 - Levantarse de estar tumbado: el sujeto se recuesta, con una leve ayuda de las manos, baja una pierna detrás de otra de la camilla y, finalmente, se levanta. Se ensaya tanto sin como con las piernas cruzadas.
- **Estar de pie** (*Stand*): estar de pie parado durante 7-10s.

Caídas

- **Caída hacia atrás** (*Backwards*): el sujeto se coloca de espaldas a la colchoneta, da 2-3 trapiés hacia atrás, dejándose caer con el cuerpo orientado unos 45° hacia atrás, lleva las manos a la altura de la cadera sin apoyarlas y, finalmente, cae apoyando los glúteos y ligeramente las manos. Se ensaya la finalización de la caída con el cuerpo orientado hacia arriba, hacia la derecha y hacia la izquierda.
- **Caída hacia delante** (*Forwards*): el sujeto camina 5 pasos hacia delante, tropieza con un objeto con un pié y se deja caer llevando las manos hacia delante y, finalmente, cae apoyando las rodillas y ligeramente las manos. También se realiza el mismo ensayo pero realizando un par de trapiés tras el tropiezo. La finalización en ambos se ensaya con el cuerpo orientado hacia abajo, hacia la derecha y hacia la izquierda.
- **Caída al sentarse** (*Sitting*): el sujeto agarra una mesa y, con las piernas semiflexionadas, intenta sentarse muy despacio (llevando el cuerpo hacia atrás) manteniendo la posición, se suelta de la mesa dejándose caer hacia atrás y, finalmente, cae apoyando el coxis y posteriormente la espalda levantando ligeramente las piernas semiflexionadas. Se ensaya la finalización de la caída con el cuerpo orientado hacia arriba, hacia la derecha y hacia la izquierda.

- **Caída lateral inicialmente de pie** (*Lateral Stand*): el sujeto posiciona las piernas a la altura de la cadera, cambia de dirección pivotando sobre una pierna, cruzando una de ellas por delante de la otra tropezándose con esta misma, alza las manos para equilibrar dejándose caer lateralmente y, finalmente cae apoyando los glúteos/espalda con las piernas semi flexionadas dando una vuelta (o no) sobre si mismo manteniendo las piernas semi flexionadas. Se ensaya la finalización de la caída con el cuerpo orientado hacia la derecha e izquierda.
- **Caída lateral inicialmente andando** (*Lateral Walking*): el sujeto camina 5 pasos hacia delante, en el paso final cruza un pie por delante del otro desequilibrándose, alza las manos para equilibrar, tropieza y, finalmente, cae con el cuerpo orientado 45º hacia atrás, apoyando el lateral de los glúteos/espalda y levantando ligeramente las piernas semiflexionadas. Se ensaya la finalización de la caída con el cuerpo orientado hacia la derecha e izquierda.

Mediante estas descripciones se han llevado a cabo el desarrollo de vídeo tutoriales de los mismos, ver (Teresa, 2020). Estos vídeo tutoriales serán los que ensayarán los sujetos.

Ejecución

Cada sujeto entra en la sala y se le toman datos de nombre, edad, peso y altura para definir la etiqueta. Posteriormente, se le muestra el vídeo tutorial del ensayo a realizar y se le pedirá que lo replique. El sujeto es grabado en la realización de cada tipo de ensayo. Como se ha mencionado en el capítulo anterior, este proceso se repetirá 10 veces (o más) por ensayo.

Capítulo 4

Procesado de los datos

4.1. Introducción

En este capítulo se explica y desarrolla el trabajo realizado en cada una de las fases del procesado de datos. Los códigos desarrollados de los respectivos algoritmos para cada fase del procesado se encuentran en el Anexo A.

El punto de partida del procesado de datos es la toma de estos mismos, la cual se realiza mediante un software de adquisición de datos (ya desarrollado) de las plantillas. Este software toma los datos de las variables a una frecuencia de 50 Hz, calcula sus derivadas y los devuelve en un fichero Excel (formato .csv). Se genera, entonces, un fichero con los datos de cada variable de cada plantilla.

A continuación, se comentan las fases del procesado de datos, las cuales involucran algunas de las técnicas de análisis y tratamiento de datos que se han encontrado en el estado del arte.

4.2. Preprocesado

Una vez realizados los ensayos del capítulo anterior obtenemos los ficheros Excel con los datos de cada ensayo para cada sujeto. El preprocesado de datos se realiza mediante una ventana deslizante y consiste en el cálculo de una serie de características de las señales para cada variable. No se aplica filtro para el ruido porque los valores de umbral no son comparables (son bastante mayores), en las Tablas C.1-C.4 del Anexo C se encuentran los valores del SNR (*Signal to Noise Ratio*) de cada una de las señales de las variables, tanto como para caídas como para ADL. En la mayoría de ellas se observa que los valores son mayores de 0dB, por lo tanto tenemos más señal que ruido. Sin embargo, en el caso de las presiones este ratio es menor que cero en algún caso, esto se debe a que durante los ensayos no todas las señales de presión se activan, dado que su activación depende de cada sujeto (forma del pie y pisada).

Antes de preprocesar los datos se crea otro fichero Excel (donde se anotan los ensayos) y un programa que abra ese fichero para leer y comprobar que hemos obtenido correctamente los datos de cada variable. Esta comprobación se realiza mediante la obtención de las gráficas para cada una de las variables, además estas gráficas permiten realizar un análisis visual del aspecto de las señales de las mismas. De este análisis se concluye que los valores de las variables iniciales de ambos pies, aceleraciones principalmente, no difieren entre sí, ver Figura C.1. Esta información gráfica nos permite plantear la detección basada en umbrales mediante una máquina de estados. Tras verificar que las señales son correctas se obtienen ficheros Excel de datos de 279 caídas y 392 ADL, estos ficheros de datos serán los utilizados para el estudio de caídas.

4.2.1. Cálculo de ventana deslizante

Para obtener los parámetros de la ventana temporal (tiempo de ventana (TW) y tiempo de deslizamiento (TD)) se ha realizado una función en la que se detecta el principio y final de la caída (zona amarilla) y el tiempo de estabilización (zona naranja), ver Figura 4.1. Observando el valor de la derivada de la aceleración total se fijan los valores umbral de inicio, fin (ambos $\pm 0,23$) y estabilización de la caída (0,11), ver Figura 4.2. El diagrama de flujo de la función del cálculo de las ventanas se encuentra en la Figura C.2 del Anexo C. Se aplica la función a cada caída para obtener los tiempos de cada caída, realizando la media y la desviación estándar de estos mismos se obtienen unos valores de 2,594s de media y 0,71s de desviación estándar para el tiempo de ventana y 0,75s de media y 0,21s de desviación estándar para el tiempo de deslizamiento. En base a estos resultados, se elige un tiempo de ventana de 3,15s y un tiempo de deslizamiento de 500ms, asegurando así el muestreo total o parcial de la caída, teniendo en cuenta que el microcontrolador donde se vaya a implementar el programa debe tener memoria suficiente para tratar con estas ventanas de datos.



Figura 4.1: Zonas caída

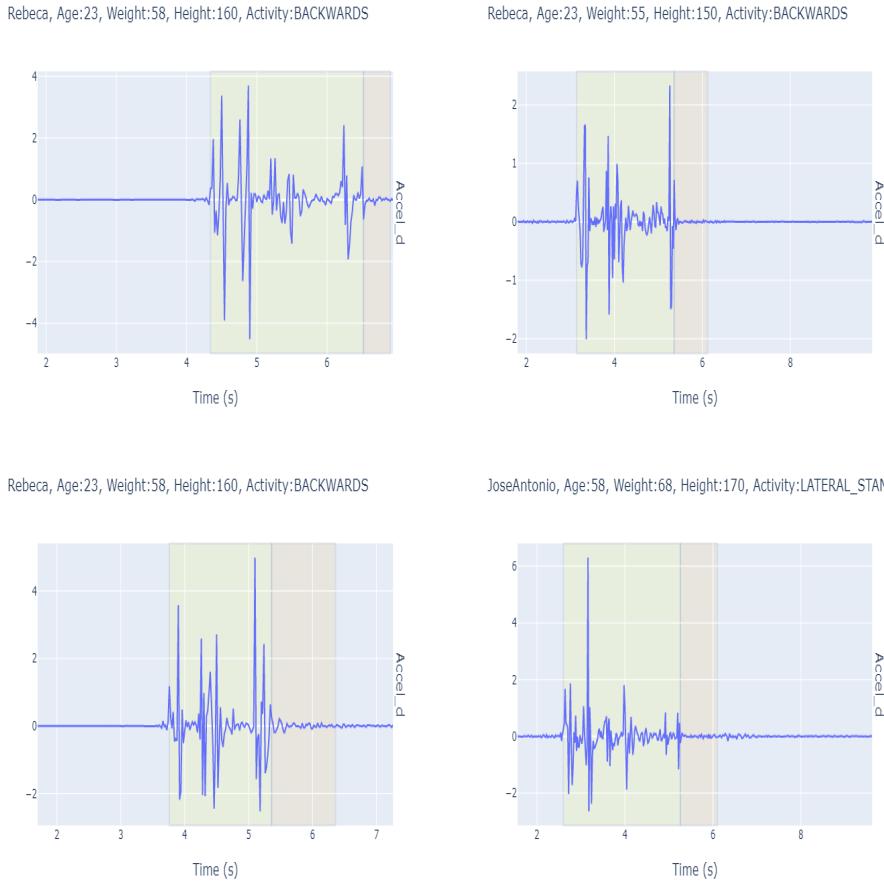


Figura 4.2: Detección de la ventana deslizante para diferentes caídas y sujetos

4.2.2. Cálculo analítico

Este preprocesado consiste en el cálculo analítico de una serie de estadísticos de las señales (indicadores): curtosis, máximo, mínimo, media, desviación estándar, varianza y potencia de la señal. Mediante la ventana de tiempo se calculan a lo largo de la caídas, con el fin de ver la evolución de los mismos, ver Figura C.4. Tanto estos indicadores como los modelos entrenados con los mismos se designan con la etiqueta n_-, por ejemplo, el coeficiente de curtosis de la señal de aceleración se nombra n_A_k.

4.3. Reducción de la dimensionalidad

Se tienen 16 variables (Ax, Ay, Az, A, P1, P5, Parcs, Pheel, Ptot, Roll, Pitch, Yaw, Wx, Wy, Wz, W), cada una con aproximadamente 150 datos por ensayo, un total de 608.208 muestras de entrenamiento y 101.368 de test. En el caso de los indicadores se tienen 112 variables (7 indicadores obtenidos del cálculo analítico por cada una de las 16 variables), con un total de 4407 muestras de entrenamiento y 735 de test. Con el

fin de reducir la gran cantidad de datos a tratar se aplican técnicas de reducción de dimensionalidad, se opta por el análisis de componentes principales (PCA) y algoritmos de selección de características. Estas técnicas se pueden encontrar en (Pedregosa y cols., 2011).

4.3.1. Análisis PCA

Se realiza un análisis PCA para reducir la dimensionalidad del espacio de variables.

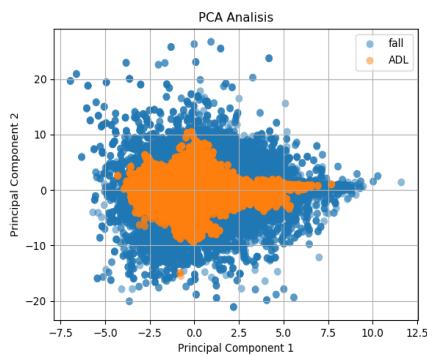


Figura 4.3: Análisis PCA de variables

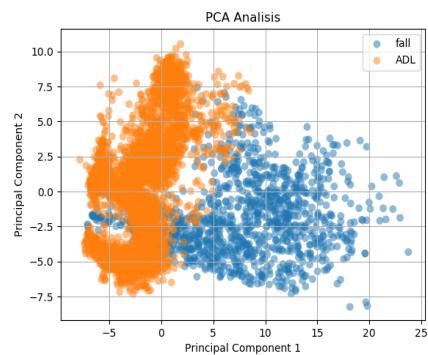


Figura 4.4: Análisis PCA de indicadores

Como se puede ver en la Figura 4.3 hay una amplia zona donde se solapan las actividades diarias y las caídas, sin embargo, si nos fijamos en la Figura 4.4 apenas hay solapamiento. Es decir, muy probablemente se obtendrán mejores resultados en la detección de caídas utilizando indicadores en vez de los datos en crudo de las variables.

Como resultado del análisis PCA se obtiene que el conjunto de variables se ve reducido a 11 nuevas variables y el conjunto de indicadores a 31 nuevas variables. La varianza escogida para selección del numero de las componentes es del 95 %, es decir, el número de variables obtenidas de este análisis representan el 95 % de la varianza, para cada caso.

4.3.2. Selección de características

Con el fin de reducir el tiempo de entrenamiento y la complejidad de los modelos pero seguir teniendo un rendimiento alto, se han utilizado los métodos de selección de características *Feature importance* y *Recursive Feature Elimination*, ambos se encuentran en la documentación de *Scikit-learn*.

Feature importance

Este primer método utilizado calcula la importancia de las variables a partir de un número determinado de características a elegir. Este número de variables óptimo se

obtiene de forma iterativa, escogiendo el que dé mejores resultados. Se ha incrementado el número de variables escogidas de 5 en 5 para variables y de 20 en 20 para indicadores, los resultados de aparecen en la Figura 4.5.

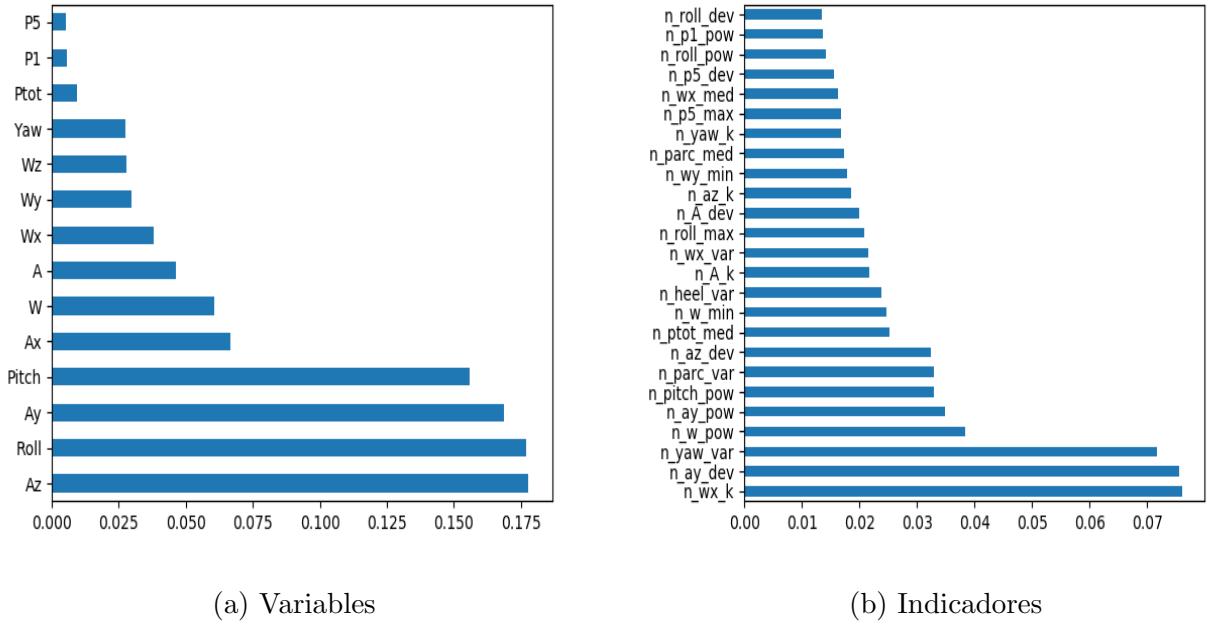


Figura 4.5: *Feature importance*

Este método tiene el problema de que la importancia que da el algoritmo a las características puede ser engañosa para las características que contienen muchos valores únicos (espurios), para resolverlo se aplica el mismo método pero permutando las columnas (en la documentación de *Scikit-learn permutation importance*). El problema de este método es que si varias variables están correlacionadas, como el estimador las usa todas por igual, la importancia de la permutación puede ser baja para todas estas características, entonces, si las características se eliminan en función del umbral de importancia, dichas características correlacionadas podrían eliminarse todas al mismo tiempo. Como solución se aplica RFE (explicado a continuación) y/o métodos similares pueden ayudar con este problema, hasta cierto punto.

Recursive Feature Elimination (RFE)

Este método obtiene el número de características óptimo mediante la eliminación recursiva de las mismas. A continuación, en la Figura 4.6, se muestran los resultados, tanto para variables como para indicadores.

En el caso de los datos en crudo, el número de variables se ve reducido de 16 a 12 (ver Figura 4.6a), mientras que en el caso de indicadores se ve reducido de 112 a

tan solo 6 (ver Figura 4.6b) (ampliada en Figura C.5 del Anexo C). El porcentaje de acierto que se obtiene es de 99,6 % y 99,3 %, respectivamente (línea azul).

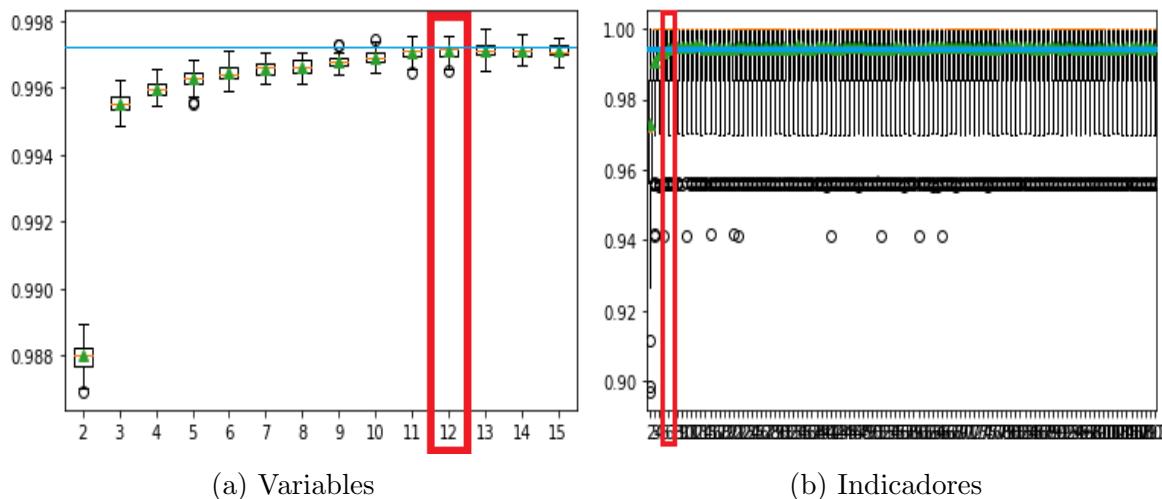


Figura 4.6: *Recursive Feature Elimination*

Mediante el atributo *ranking_* de este método se calculan dichas características óptimas. En el código del programa A se observa el resultado para cada una de las características, variables e indicadores, respectivamente. Estos resultados se corresponden con las variables Ax, Ay, Az, A, Ptot, Roll, Pitch, Yaw, Wx, Wy, Wz, W y con los indicadores n_A_max, n_A_min, n_wz_min, n_p1_med, n_roll_var.

4.4. Extracción de características

En esta fase se procesan las caídas aplicando la ventana deslizante y realizando el cálculo analítico de las mismas. Los umbrales definidos para la detección de caídas, serán las medias de todas las características de estas ventanas, ver Figura 4.7.

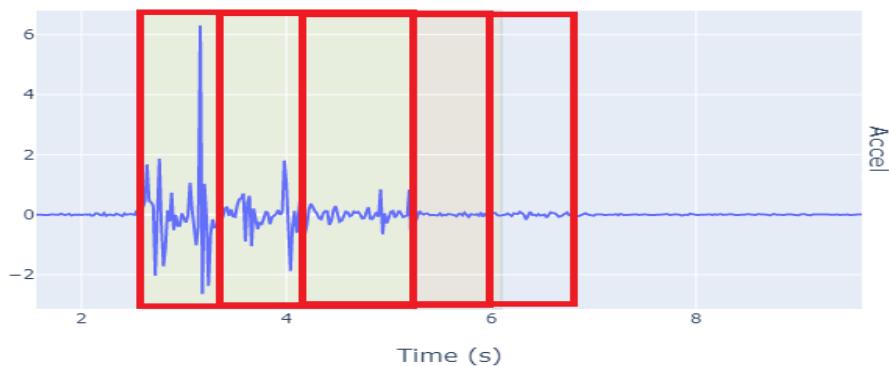


Figura 4.7: Procesado de caída mediante ventana

4.5. Representación semántica

El objetivo de este apartado es desarrollar un modelo general de detección de caídas. Para realizar esta representación semántica se han desarrollado dos tipos de algoritmos, uno basado en el desarrollo de una máquina de estados a través de umbrales, y otro basado en el desarrollo de modelos de *machine learning*.

4.5.1. Algoritmo basado en umbrales

El algoritmo principal consta de una función principal (*getTargets*) en donde se incluyen otras subfunciones para el procesado de ensayos y obtención de resultados, y otras dos (*conteo* y *showResults*) para el conteo de resultados y la visualización de los mismos. Ver Figura 4.8.

Programa Principal

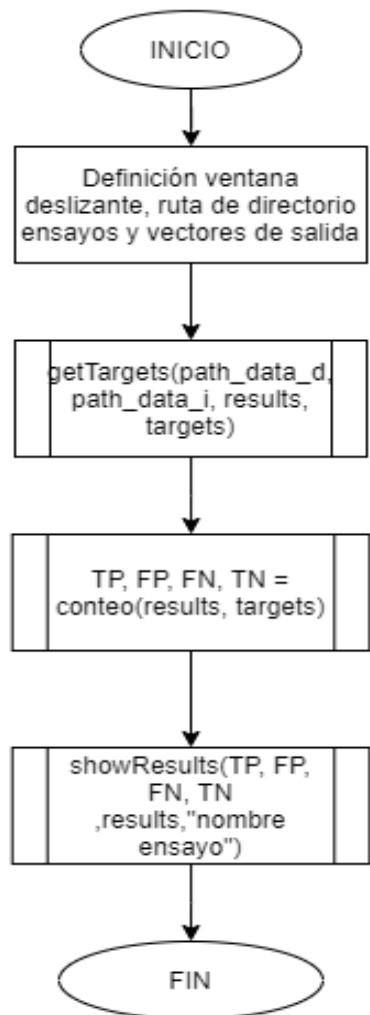


Figura 4.8: Diagrama de flujo del programa principal

La función *getTargets* (ver Figura 4.10) devuelve dos vectores con la salida predicha y la salida real de cada ensayo, para ello mediante la función *ProcessTest* se van procesando los ensayos uno a uno.

getTargets

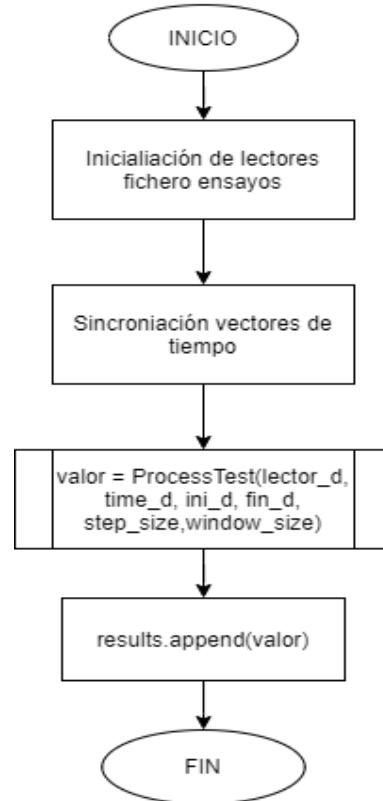


Figura 4.9: Diagrama de flujo de la obtención del vector de salidas de ventanas

La función *ProcessTest* utiliza dos funciones *estado* y *isFall* para obtener un vector de 1 y 0 (caída y no caída) según el valor de la estadística de la ventana de tiempo, ver Figura 4.10.

Process Test

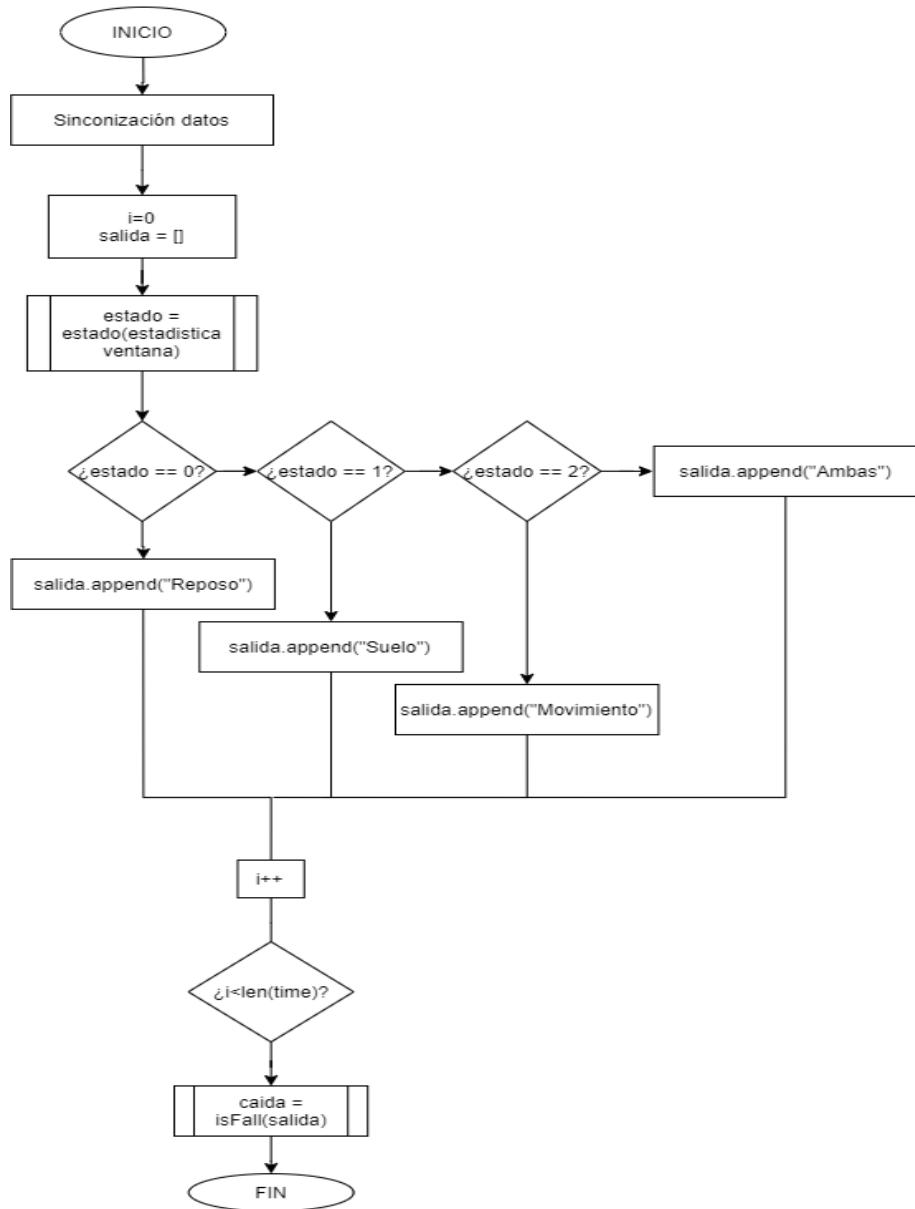


Figura 4.10: Diagrama de flujo del procesado de un ensayo

Mediante la función *estado* se realiza el cálculo analítico de cada variable para cada ventana de tiempo, obteniendo así el valor de los indicadores en cada ventana temporal. Los indicadores de cada ventana del valor máximo de aceleración total y valor medio de ángulo *roll* se van comparando con el umbral definido anteriormente, mediante el resultado de esta comparación obtendremos las salidas 0 (Reposo), 1 (Movimiento), 2 (Suelo) y 3 (Ambas), ver Figura 4.11. Cada salida se define de la siguiente manera:

- ”Reposo”: indica que los valores de aceleración total y ángulo *roll* son muy bajos, esto indica, probablemente, que la persona está en reposo o realizando una ADL
- ”Movimiento”: indica que el valor de la aceleración total ha superado el umbral de caída y el valor del ángulo *roll* es bajo, esto indica, probablemente, que la persona se ha podido tropezar
- ”Suelo” indica que el valor de la aceleración total es bajo y el valor del ángulo *roll* ha superado cierto umbral, esto indica, probablemente, que la persona se encuentre en el suelo
- ”Ambas”: indica que los valores de aceleración total y ángulo *roll* están por encima de los umbrales, esto rara vez ocurre en caídas, por lo que no va a ocurrir con frecuencia

estado

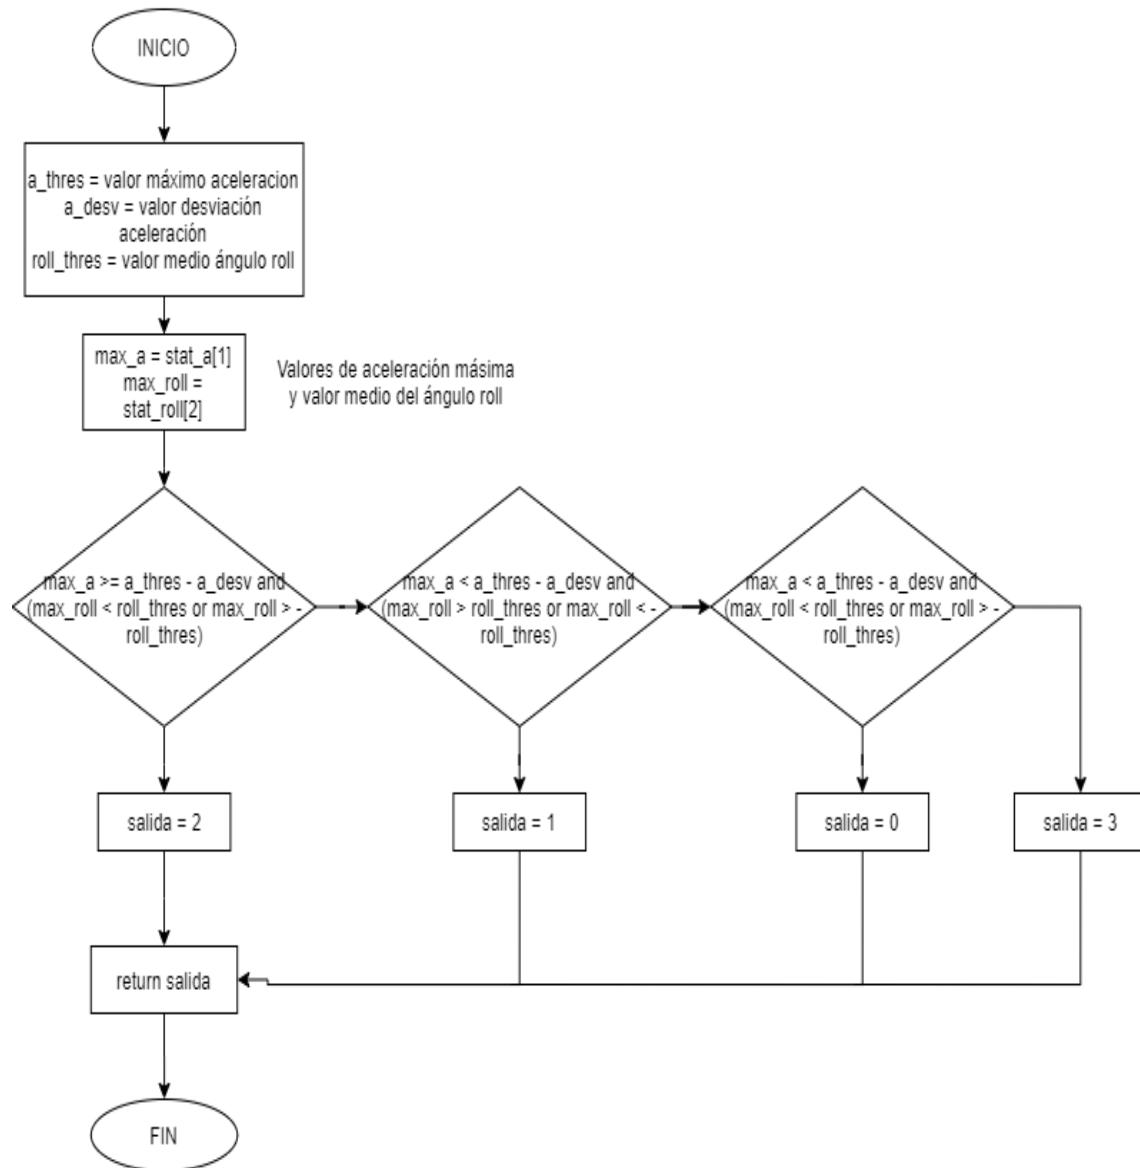


Figura 4.11: Diagrama de flujo de la obtención del estado de la ventana temporal

Una vez procesado el ensayo, mediante la función *isFall*, obtendremos un vector de salidas correspondientes a las ventanas temporales del ensayo. Finalmente, se realizará el conteo de estados seguidos que hay en el vector salida (es lo que se definen como índices de riesgo de caída), si estos números son mayores o iguales que un umbral (definido como dos), es decir, que a lo largo del ensayo haya al menos 2 ventanas de tiempo en las que los indicadores sobrepasan cierto umbral de caída, se determina que se trata de una caída, por el contrario, se tratará de una ADL. Se han escogido las variables aceleración total y ángulo *roll* para la definición de umbrales, como resultado de la Figura anterior 4.5, donde ambas (entendiendo que la aceleración total es el

módulo de las componentes x, y, z) ocupan las posiciones de más importancia del gráfico. Ver Figura 4.12.

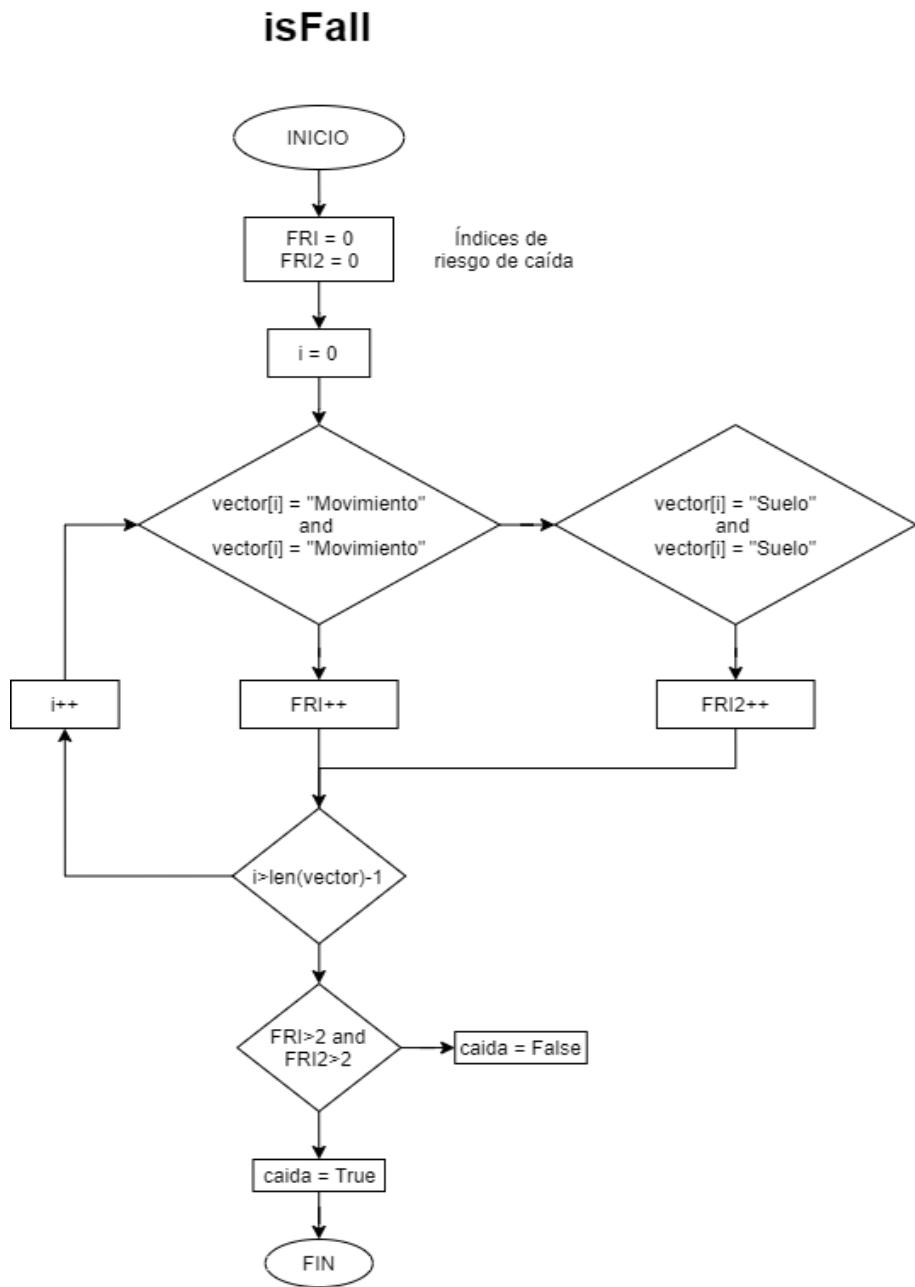


Figura 4.12: Diagrama de flujo de la obtención de la salida, caída o no caída

4.5.2. Algoritmo basado en modelos *machine learning*

Antes de realizar los modelos y, con el fin de observar la correlación entre las variables para posteriormente elegir un *kernel* (lineal o no lineal) adecuado a los mismos, se calcula y visualiza la correlación entre las variables, tanto para caídas como para ADL, ver Figuras C.6 y C.7 del Anexo C. En éstas puede observarse que la relación

entre las las variables es, para la mayoría de ellas, no lineal. Por lo tanto, se deduce que se obtendrán mejores resultados mediante modelos con *kernel* no lineal.

El problema a abordar se trata de un problema de clasificación supervisado (detección de caída o no caída mediante una base de datos de ensayos etiquetados), se plantean modelos basados en máquinas de vectores de soporte (SVM) con *kernels* no lineales y perceptrón multicapa (MLP). Las SVM son una de las técnicas más utilizadas para clasificación para resolver problemas complejos de tamaño pequeño-mediano, tienen la ventaja de no tener mínimos locales, detectan automáticamente el tamaño del modelo y tienen menor tendencia al sobre ajuste, sin embargo, pueden requerir mucha memoria y son de elevado coste computacional. Por otro lado, los modelos MLP ya poseen neuronas no lineales (activación sigmoidea o similar) y son un modelo de aproximación muy general, aunque pueden quedarse atrapados en mínimos locales.

Nuestro objetivo es desarrollar un algoritmo de detección de caídas con el que se obtenga una exactitud alta con bajo porcentaje de falsos positivos. Estos modelos se encuentran en *Scikit-learn*, en este caso utilizaremos máquinas de vectores de soporte específicas para clasificación (SVC y NuSVC) y MLP. A continuación, se introducen los modelos desarrollados:

- **NuSVC**: Modelo máquina de vectores de soporte para clasificación no lineal, parámetro (*nu*) para controlar el número de vectores de soportes.
- **SVC_rbf**: Modelo máquina de vectores de soporte para clasificación con *kernel rbf* (función de base radial)
- **SVC_poly**: Modelo máquina de vectores de soporte para clasificación con *kernel polynomial* (función polinómica)
- **SVC_sig**: Modelo máquina de vectores de soporte para clasificación con *kernel sigmoid* (función sigmoidea)
- **MLP**: Modelo neuronal perceptrón multicapa, optimiza la función coste usando LBFGS o descenso de gradiente estocástico.

Con el fin de reducir el tiempo de entrenamiento, la complejidad de los modelos, el número de falsos positivos y aumentar el porcentaje de acierto, se han desarrollado estos mismos modelos entrenados mediante indicadores (n_NuSVC, n_SVC_rbf, n_SVC_poly, n_SVC_sig, n_MLP), PCA (NuSVC_pca, SVC_rbf_pca, SVC_poly_pca, SVC_sig_pca,

MLP_pca) y combinación de ambos (n_NuSVC_pca, n_SVC_rbf_pca, n_SVC_poly_pca, n_SVC_sig_pca, n_MLP_pca).

El entrenamiento y test de todos los modelos se realiza dividiendo el conjunto de datos en un 70% para entrenamiento y un 30% para test. Los demás parámetros (excepto el *kernel*) se seleccionan por defecto.

4.5.3. Variabilidad de los modelos

Con el fin de estudiar la variabilidad entre modelos y sujetos, se han desarrollado los mismos modelos comentados en la sección anterior entrenados con los datos de un sujeto (S1) y testeados con los datos del otro sujeto (S2) y, viceversa.

Capítulo 5

Resultados

5.1. Introducción

En este capítulo se comentan los resultados de los modelos obtenidos y se muestran las tablas de resultados de los modelos más relevantes. Resultados de número de *true positives* (TP), *true negatives* (TN), *false negatives* (FN), *false positives* (FP) y exactitud total. Exactitud total entendida como se muestra en la ecuación 5.1.

$$P(\%) = \frac{TP + TN}{Total} * 100 \quad (5.1)$$

El resto de tablas de resultados del resto de modelos se encuentran en el Anexo D

Finalmente, se incluye una sección de discusión de los resultados, en donde se resume brevemente los mejores resultados obtenidos.

5.2. Modelos totales

La Tabla 5.1 muestra los resultados de los modelos entrenados y testeados con los datos de ambos sujetos, se emplean 608208 datos en crudo y 4407 datos de indicadores en entrenamiento y, 101368 datos en crudo y 735 datos de indicadores en test, todo ello por cada una de las variables. Se obtienen mejores resultados mediante los modelos de indicadores que mediante modelos de datos en crudo, a su vez, estos modelos mejoran sus resultados aplicando PCA. El mejor resultado se consigue con el modelo perceptrón multicapa entrenado con el análisis PCA de los indicadores (n_MLP_pca), con una tasa de FP nula y una exactitud media de 99,72 %.

Tabla 5.1: Resultados modelos totales

Resultados	Modelo	TP (<i>True positives</i>)	TN (<i>True Negatives</i>)	FN (<i>False Negatives</i>)	FP (<i>False Positives</i>)	Exactitud total(%)
Total	SVC_rbf.pkl	18690	78547	3785	346	95,924
	SVC_poly.pkl	17984	78481	4491	412	95,163
	SVC_sig.pkl	13365	69724	9110	9169	81,967
	MLP.pkl	19657	77924	2818	969	96,264
	NuSVC.pkl	18755	78582	3720	311	96,023
	SVC_rbf_pca.pkl	18471	78511	4004	382	95,673
	SVC_poly_pca.pkl	17685	78385	4790	508	94,773
	SVC_sig_pca.pkl	11965	68286	10510	10607	79,167
	MLP_pca.pkl	19126	78166	3349	727	95,979
	NuSVC_pca.pkl	18618	78547	3857	346	95,853
	n_SVC_rbf.pkl	50	534	108	43	79,455
	n_SVC_poly.pkl	0	577	158	0	78,503
	n_SVC_sig.pkl	40	353	118	224	53,469
	n_MLP.pkl	20	348	138	229	50,068
	n_NuSVC.pkl	0	577	158	0	78,503
	n_SVC_rbf_pca.pkl	154	577	4	0	99,455
	n_SVC_poly_pca.pkl	153	577	5	0	99,319
	n_SVC_sig_pca.pkl	130	546	28	31	91,972
	n_MLP_pca.pkl	156	577	2	0	99,727
	n_NuSVC_pca.pkl	151	577	7	0	99,047

5.3. Modelos de sujetos

Las Tablas D.1 y D.2 muestran los resultados de los modelos entrenados con los datos de cada sujeto por separado y testeados con los datos totales. Para el primer sujeto, se emplean 342988 datos en crudo y 2384 datos de indicadores en entrenamiento, para el segundo sujeto, se emplean 265219 de datos en crudo y 2022 de indicadores en entrenamiento y, en ambos casos, se emplean 101368 datos en crudo y 735 datos de indicadores en test. Como es de esperar, la exactitud obtenida en los modelos son peores que en el caso anterior ya que están entrenados con datos de un solo sujeto y testeados con datos de ambos. Además, se obtienen mejores resultados con los modelos del segundo sujeto debido a que en la base de datos hay mas ensayos de éste. Se ha observado que al aplicar el análisis PCA en el caso de los modelos de indicadores éstos mismos no convergen, el entrenamiento se detiene por llegar al máximo de iteraciones. En cuestiones de exactitud, el mejor resultado se obtiene mediante el modelo de vectores de soporte con kernel de función de base radial (SVC_rbf) con un 95,01 % de exactitud media y un número de FP de 1393. En cuestión de tasa de FP, el mejor resultado se obtiene mediante el modelo de vectores de soporte con kernel polinómico entrenado con indicadores (n_SVC_poly) con un número de FP de 1 y una exactitud media de 78,503 % .

Las Tablas D.3 y D.4 muestran los resultados de los modelos entrenados con los datos de un sujeto y testeados con los dato del otro sujeto, con el fin de estudiar la variabilidad entre sujetos. Para el primer sujeto, se emplean 342988 datos en crudo y 2384 datos de indicadores en entrenamiento y, 44204 datos de en crudo y 338 datos de indicadores en test. Para el segundo sujeto, se emplean 265219 datos en crudo y 2022 datos de indicadores en entrenamiento y, 57165 datos en crudo y 398 datos de indicadores en test. La Tabla D.3 muestra los resultados de los modelos entrenados con los datos del primer sujeto y testeados con los datos del segundo, sucede lo contrario en la Tabla D.4. En cuestiones de exactitud, el mejor resultado se obtiene con el modelo de vectores de soporte con kernel polinómico (SVC_poly) entrenado con datos en crudo del primer sujeto y testeado con datos del segundo, obteniendo una exactitud media de 94,35 % pero un número de FP de 775. En cuestión de tasa de FP, el mejor resultado se obtiene con el modelo de vectores de soporte con kernel polinómico (n_SVC_poly) entrenado con indicadores del primer sujeto y testeado con los del segundo, obteniendo una tasa de FP nula y una exactitud media de 79,88 %.

Estos resultados indican que no existe apenas variabilidad entre sujetos y, además, se mantiene una exactitud alta (entorno al 80 %). Las tasas de variabilidades del modelo

S2 respecto del S2, y viceversa, encuentran en un rango 0,9 y 1,085. La mayor de ellas se obtiene mediante el modelo SVC.sig.pca.

5.4. Modelos Reducidos

Las Tablas D.5 y D.6 muestran los modelos entrenados y testeados con las características obtenidas de aplicar los métodos de reducción de características RFE y FI, explicados en el capítulo anterior. El número de datos empleados en entrenamiento y test es el mismo que en los modelos totales, en este caso, el número de variables es menor. Los resultados de los modelos indican que mediante el método *Feature Importance* se obtienen mejores resultados que mediante el método *Recursive Feature Elimination*. En cuestión de exactitud, el mejor resultado se obtiene con el modelo de perceptrón multicapa entrenado y testeado con el análisis PCA de los indicadores (n_MLP_pca), con una exactitud media de 97,959 % y un número de FP de 4. En cuestión de tasa de FP, el mejor resultado se obtiene con el modelo de vectores de soporte con kernel polinómico entrenado y testeado con el análisis PCA de los indicadores (n_SVC_poly), con una número de FP de 1 y una exactitud media de 97,41 %.

5.5. Modelos máquina estados

La Tabla 5.2 muestra los resultados obtenidos (totales y por tipo de caída) con la máquina de estados para umbrales de aceleración total y ángulo *roll*. El porcentaje de exactitud obtenido es menor que en los algoritmos basados en *machine learning*, esto se debe a que este algoritmo solo utiliza datos de dos variables para la detección de caídas, es decir, contiene menos información que los algoritmos de *machine learning*, los cuales manejan un número mayor de variables y, por lo tanto, la exactitud obtenida respecto a éstos es menor. Se consigue exactitud del 84,649 % y un número de FP de 27.

Tabla 5.2: Resultados Máquina de estados

Modelo	TP (<i>True positives</i>)	TN (<i>True Negatives</i>)	FN (<i>False Negatives</i>)	FP (<i>False Positives</i>)	Exactitud total(%)
ME_tot	161	407	76	27	84,649
ME_Backwards	34	0	29	0	53,968
ME_Forwards	98	0	33	0	74,809
ME_LateralStand	29	0	14	0	67,441
ME_LateralWalking	0	16	0	26	38,095
ME_Sitting	13	6	45	0	29,6875

5.6. Discusión de resultados

Los mejores resultados se obtienen mediante el modelo de *machine learning* perceptrón multicapa, entrenado con el análisis PCA de los indicadores (n_MLP_pca), con una tasa de FP nula y una exactitud media del 99,72 %. Superando a (Montanini y cols., 2018), con una exactitud media del 90 % y una tasa de FP nula, y a (Shi y cols., 2015), con una exactitud media del 98,8 %.

Por otro lado, los resultados de los modelos de los sujetos individuales indican que apenas existe variabilidad entre sujetos, manteniendo una alta exactitud (entorno al 80 %). La variabilidad de los modelos S2 respecto del S1, y viceversa, se encuentran en un rango de tasas de 0,9 y 1,085.

Finalmente, los resultados de los modelos reducidos indican que, aún reduciendo el número de variables de entrenamiento, de 16 a 12 en datos de las variables y de 112 a 6 en indicadores, se consiguen exactitudes medias del 97 %.

Capítulo 6

Conclusiones y líneas futuras

6.1. Introducción

En este capítulo se comentan las conclusiones extraídas tras el análisis de los resultados obtenidos.

6.2. Conclusiones

En este trabajo fin de máster se han desarrollado algoritmos de detección de caídas basados en técnicas de complejidad computacional baja-media, como los basados en umbrales y en *machine learning*, con el objeto de que sean implementables en microcontroladores de recursos limitados, con el fin de incorporados en las plantillas sensorizadas. Pese a ello, los resultados obtenidos son buenos. Por ello, en este trabajo no se ha planteado el uso de otros algoritmos computacionalmente más complejos, como puedan ser los *deep learning*.

Se obtienen mejores resultados con los modelos del algoritmo de *machine learning* que mediante el algoritmo basado en umbrales. En concreto, se obtiene mayor exactitud si se utiliza datos de entrenamiento y test del análisis PCA de los indicadores. Por otro lado, se consigue el principal objetivo: una tasa nula de FP con una exactitud alta (99,72 %), superando a (Montanini y cols., 2018), con una exactitud media del 90 % y una tasa de FP nula, y a (Shi y cols., 2015), con una exactitud media del 98,8 %. Finalmente, se observa que apenas existe variabilidad entre sujetos, esto indica que tanto la definición de ensayos como construcción de la base de datos han sido realizadas correctamente.

Mediante el modelo basado en umbrales se consigue una exactitud del 94,649 % pero un número de FP de 27, esto se debe a que el compromiso entre exactitud y tasa de FP es mayor al utilizar solamente dos variables. Por otro lado, este algoritmo ocupa mucha menos memoria y es mucho más rápido.

En vista de estos resultados, la implementación de uno de estos algoritmos en un microcontrolador dependerá de las características del mismo. En un microcontrolador de pocas prestaciones se optará por implementar el algoritmo basado en umbrales ya que, es lo suficientemente preciso (84,649 %) para realizar la detección de caídas y mucho más rápido y sencillo que los modelos de *machine learning*. Sin embargo, si se dispone de un microcontrolador de prestaciones suficientes y adecuadas, se optará por la implementación de algoritmos basados en *machine learning* ya que con estos se consigue el mejor resultado. Aproximadamente, se necesitan unos 100-200KB de memoria flash para almacenar el modelo y 70KB de memoria RAM para almacenar los datos de las variables de una ventana temporal.

6.3. Líneas futuras

El objeto de este proyecto da por finalizado el alcance del trabajo. Como consideraciones futuras, se propone lo siguiente:

- Implementar en un microcontrolador el algoritmo basado umbrales y/o *machine learning*, realizar ensayos con diferentes sujetos y obtener los resultados pertinentes.
- Tomar datos de otros sujetos para ampliar la base de datos de ensayos, con el objetivo de realizar modelos de *machine learning* más generalistas y fiables.
- Ajuste/análisis de hiper parámetros de los modelos del algoritmo *machine learning* y/o umbrales de la máquina de estados.
- Estudiar la variabilidad entre personas zurdas y/o diestras

Referencias

- Alves, A. H. C., Patrício, A. C. F. d. A., Albuquerque, K. F. d., Duarte, M. C. S., Santos, J. d. S., y Oliveira, M. S. d. (2016). Occurrence of falls among elderly institutionalized: prevalence, causes and consequences. *Revista de Pesquisa: Cuidado é Fundamental Online*, 8(2), 4376-4386.
- Chen, Y.-C., y Lin, Y.-W. (2010, Nov). Indoor rfid gait monitoring system for fall detection.
doi: 10.1109/ISAC.2010.5670478
- De Miguel, K., Brunete, A., Hernando, M., y Gambao, E. (2017). Home camera-based fall detection system for the elderly. *Sensors*, 17(12). Descargado de <https://www.mdpi.com/1424-8220/17/12/2864> doi: 10.3390/s17122864
- Dhargave, P., y Sendhilkumar, R. (2016). Prevalence of risk factors for falls among elderly people living in long-term care homes. *Journal of Clinical Gerontology and Geriatrics*, 7(3), 99 - 103. Descargado de <http://www.sciencedirect.com/science/article/pii/S2210833516300181> doi: <https://doi.org/10.1016/j.jcgg.2016.03.004>
- Gamage, N., Rathnayake, N., y Alwis, G. (2018, 5). Knowledge and Perception of Falls among Community Dwelling Elderly: A Study from Southern Sri Lanka. *Current Gerontology and Geriatrics Research*, 2018, 8. doi: 10.1155/2018/7653469
- Howcroft, J., Kofman, J., y Lemaire, E. D. (2017, Oct). Prospective fall-risk prediction models for older adults based on wearable sensors. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(10), 1812-1820. doi: 10.1109/TNSRE.2017.2687100
- Howlab. (2020).
- Lee, Chang Min, P., Jisu, P., Shinsuk, K., y Hyun, C. (2019, Dec). Fall-detection algorithm using plantar pressure and acceleration data. *International Journal of Precision Engineering and Manufacturing*. doi: 10.1007/s12541-019-00268-w
- Li, Y., Ho, K. C., y Popescu, M. (2012). A microphone array system for automatic fall detection. *IEEE Transactions on Biomedical Engineering*, 59(5), 1291-1301.
- Medeiros, E., Nóbrega, M. M., Pontes, M., Vasconcelos, M., Paiva, M., y Moreira, M. (2014, 12). Determinants of risk of falls among elderly: a systematic study. *Revista de Pesquisa: Cuidado é Fundamental Online*, 6, 11. doi: 10.9789/2175-5361.2014.v6i5.11-120
- Montanini, L., Del Campo, A., Perla, D., Spinsante, S., y Gambi, E. (2018, Feb). A footwear-based methodology for fall detection. *IEEE Sensors Journal*, 18(3), 1233-1242. doi: 10.1109/JSEN.2017.2778742
- Moraes, S. A. d., Soares, W. J. S., Lustosa, L. P., Bilton, T. L., Ferrioli, E., y Perracini, M. R. (2017, 10). Characteristics of falls in elderly persons residing in the community: a population-based study. *Revista Brasileira de Geriatria e Gerontologia*, 20, 691 - 701. Descargado de <http://www.scielo.br/scielo.php>

- ?script=sci_arttext&pid=S1809-98232017000500691&nrm=iso doi: 10.1590/1981-22562017020.170080
- Nguyen, H., Mirza, F., Naeem, M. A., y Baig, M. M. (2017). Detecting falls using a wearable accelerometer motion sensor. , 422–431. Descargado de <https://doi.org/10.1145/3144457.3144484> doi: 10.1145/3144457.3144484
- Nguyen, H., Zhou, F., Mirza, F., y Naeem, M. A. (2018, Oct). Fall detection using smartphones to enhance safety and security of older adults at home. , 1-2. doi: 10.23919/ICMU.2018.8653613
- Noury, N., Rumeau, P., Bourke, A., ÓLaghin, G., y Lundy, J. (2008). A proposal for the classification and evaluation of fall detectors. *IRBM*, 29(6), 340 - 349. Descargado de <http://www.sciencedirect.com/science/article/pii/S1959031808001243> doi: <https://doi.org/10.1016/j.irbm.2008.08.002>
- Otanaspas, N. (2016, Dec). Pre-impact fall detection based on wearable device using dynamic threshold model. , 362-365. doi: 10.1109/PDCAT.2016.083
- Ozturk, T. C., Ak, R., Akoglu, E. U., Onur, O., Eroglu, S., y Saritemur, M. (2017). Factors associated with multiple falls among elderly patients admitted to emergency department. *International Journal of Gerontology*, 11(2), 85 - 89. Descargado de <http://www.sciencedirect.com/science/article/pii/S1873959817301370> doi: <https://doi.org/10.1016/j.ijge.2016.05.009>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Podoactiva*. (2020).
- Rahmawati, F., Mustafidah, N., Pramantara, I., y Wahab, I. (2019). A study of psychoactive medicines and risk of falls among indonesian elderly patients. *Indonesian Journal of Pharmacy*, 30(3), 233. Descargado de <https://indonesianjpharm.farmasi.ugm.ac.id/index.php/3/article/view/1519>
- Rakhman, A. Z., Nugroho, L. E., Widayawan, y Kurnianingsih. (2014, Nov). Fall detection system using accelerometer and gyroscope based on smartphone. , 99-104. doi: 10.1109/ICITACEE.2014.7065722
- Reis, K. M. C. d., y Jesus, C. A. C. d. (2017, 00). Relationship of polypharmacy and polypathology with falls among institutional elderly. *Texto & Contexto - Enfermagem*, 26. Descargado de http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0104-07072017000200325&nrm=iso doi: 10.1590/0104-0707201700304001
- Ren, L., y Peng, Y. (2019). Research of fall detection and fall prevention technologies: A systematic review. *IEEE Access*, 7, 77702-77722. doi: 10.1109/ACCESS.2019.2922708
- Robinovitch, S. N. (2018). Falls experienced by older adult residents in long-term care homes. *Databrary*. Descargado de <http://databrary.org/volume/739> doi: <http://doi.org/10.17910/b7.739>
- Robinovitch, S. N., Feldman, F., Yang, Y., Schonnop, R., Leung, P. M., Sarraf, T., ... Loughlin, M. (2013). Video capture of the circumstances of falls in elderly people residing in long-term care: an observational study. *The Lancet*, 381(9860), 47 - 54. Descargado de <http://www.sciencedirect.com/science/article/pii/S014067361261263X> doi: [https://doi.org/10.1016/S0140-6736\(12\)61263-X](https://doi.org/10.1016/S0140-6736(12)61263-X)
- Ronthal, M. (2019). Gait disorders and falls in the elderly. *Medical Clinics of North America*, 103(2), 203 - 213. Descargado de <http://www>

- .sciencedirect.com/science/article/pii/S0025712518301329 (Neurology for the Non-Neurologist) doi: <https://doi.org/10.1016/j.mcna.2018.10.010>
- Rosa, M. D., Hausdorff, J. M., Stara, V., Rossi, L., Glynn, L., Casey, M., . . . Cherubini, A. (2017). Concurrent validation of an index to estimate fall risk in community dwelling seniors through a wireless sensor insole system: A pilot study. *Gait & Posture*, 55, 6 - 11. Descargado de <http://www.sciencedirect.com/science/article/pii/S0966636217301108> doi: <https://doi.org/10.1016/j.gaitpost.2017.03.037>
- Sharif, S. I., Al-Harbi, A. B., Al-Shihabi, A. M., Al-Daour, D. S., y Sharif, R. S. (2018, 09). Falls in the elderly: assessment of prevalence and risk factors. *Pharmacy Practice (Granada)*, 16. Descargado de http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1885-642X2018000300004&nrm=iso doi: 10.18549/pharmpract.2018.03.1206
- Shi, G., Zhang, J., Dong, C., Han, P., Jin, Y., y Wang, J. (2015, June). Fall detection system based on inertial mems sensors: Analysis design and realization. , 1834-1839. doi: 10.1109/CYBER.2015.7288226
- Shibuya, N., Nukala, B. T., Rodriguez, A. I., Tsay, J., Nguyen, T. Q., Zupancic, S., y Lie, D. Y. C. (2015, Jan). A real-time fall detection system using a wearable gait analysis sensor and a support vector machine (svm) classifier. , 66-67. doi: 10.1109/ICMU.2015.7061032
- Sim, S. Y., Jeon, H. S., Chung, G. S., Kim, S. K., Kwon, S. J., Lee, W. K., y Park, K. S. (2011, Aug). Fall detection algorithm for the elderly using acceleration sensors on the shoes. , 4935-4938. doi: 10.1109/IEMBS.2011.6091223
- Su, B. Y., Ho, K. C., Rantz, M. J., y Skubic, M. (2015, March). Doppler radar fall activity detection using the wavelet transform. *IEEE Transactions on Biomedical Engineering*, 62(3), 865-875. doi: 10.1109/TBME.2014.2367038
- Sun, J., Wang, Z., Pei, B., Tao, S., y Chen, L. (2015, Aug). Fall detection using plantar inclinometer sensor. , 1692-1697. doi: 10.1109/UIC-ATC-ScalCom-CBDCom-IoP.2015.308
- Tao, Y., Qian, H., Chen, M., Shi, X., y Xu, Y. (2011, Dec). A real-time intelligent shoe system for fall detection. , 2253-2258. doi: 10.1109/ROBIO.2011.6181633
- Teresa, R. (2020). *Tutoriales caídas y adl.* Descargado 18/07/2020, de <https://www.youtube.com/playlist?list=PL89111Ni2tJXpOREUAy01X89WhF119fo>
- Trkov, M., Chen, K., Yi, J., y Liu, T. (2015, July). Slip detection and prediction in human walking using only wearable inertial measurement units (imus). , 854-859. doi: 10.1109/AIM.2015.7222645
- Wang, L., Peng, M., y Zhou, Q. F. (2019, April). Fall detection based on convolutional neural networks using smart insole. , 593-598. doi: 10.1109/ICCAR.2019.8813332
- World health organization. fact sheets.* (Last update 16 Jan. 2018). Descargado de <http://www.who.int/news-room/fact-sheets/detail/falls>
- Yu, S., Chen, H., y Brown, R. A. (2018, Nov). Hidden markov model-based fall detection with motion sensor orientation calibration: A case for real-life home monitoring. *IEEE Journal of Biomedical and Health Informatics*, 22(6), 1847-1853. doi: 10.1109/JBHI.2017.2782079

Lista de Figuras

1.1.	HOWLab, Escuela de Ingeniería y Arquitectura de Zaragoza y Podoactiva	2
2.1.	Fases del procesado de datos	8
4.1.	Zonas caída	21
4.2.	Detección de la ventana deslizante para diferentes caídas y sujetos . . .	22
4.3.	Análisis PCA de variables	23
4.4.	Análisis PCA de indicadores	23
4.5.	<i>Feature importance</i>	24
4.6.	<i>Recursive Feature Elimination</i>	25
4.7.	Procesado de caída mediante ventana	25
4.8.	Diagrama de flujo del programa principal	26
4.9.	Diagrama de flujo de la obtención del vector de salidas de ventanas . .	27
4.10.	Diagrama de flujo del procesado de un ensayo	28
4.11.	Diagrama de flujo de la obtención del estado de la ventana temporal . .	30
4.12.	Diagrama de flujo de la obtención de la salida, caída o no caída	31
B.1.	Receptores <i>bluetooth</i>	105
B.2.	Plantillas	106
B.3.	Electrónica de plantillas	106
C.1.	Gráficas de variables de todas las caídas	108
C.2.	Diagrama flujo para el cálculo de tiempos de ventana deslizante	109
C.3.	Ejemplo de gráfica de datos en crudo de las variables	111
C.4.	Ejemplo de gráfica de indicadores de las variables	112
C.5.	Diagramas de caja para cada variable	113
C.6.	Correlaciones de variables en ADL	114
C.7.	Correlaciones de variables en caídas	115

Lista de Tablas

2.1.	<i>Set up</i> y Características de sensado	10
2.2.	Detección y Características de la base de datos	11
2.3.	Resultados	12
2.4.	<i>Set up</i> y Características de sensado	12
2.5.	Detección y Características de la base de datos	13
2.6.	Resultados	13
5.1.	Resultados modelos totales	35
5.2.	Resultados Máquina de estados	38
C.1.	SNR de aceleraciones	107
C.2.	SNR de presiones	107
C.3.	SNR de ángulos	107
C.4.	SNR de velocidades angulares	108
D.1.	Resultados modelo sujeto 1	117
D.2.	Resultados modelo sujeto 2	118
D.3.	Resultados de modelo sujeto 1, test sujeto 2	119
D.4.	Modelo sujeto 2, test sujeto 1	120
D.5.	Resultados modelos RFE	121
D.6.	Resultados modelos FI	122