

UNIVERSITAT POLITÈCNICA DE CATALUNYA

Programa de Doctorado

AUTOMÀTICA, ROBÒTICA I VISIÓ

Tesis doctoral

**Contribución al análisis del movimiento humano aplicado a la  
identificación de posturas y bloqueos de la marcha en pacientes con  
Parkinson**

**Daniel M. Rodríguez Martín**

Director: Andreu Català i Mallofré

Abril 2014

*A mi familia, en especial a mis padres, de los que siempre he recibido todo el apoyo que he necesitado y gracias a ellos he llegado hasta aquí. También a Laura, mi mujer, con la que he compartido toda esta fase de nuestras vidas y ha sido el sostén en todos los momentos buenos y malos. Gracias.*



# Abstract

The following dissertation presents the contributions of the author in the field of human movement analysis and, specifically, in Parkinson's disease.

Recent technologies have allowed developing reduced inertial sensors capable of monitoring human movement. This, along with the reduced prices of these inertial sensors, the so-called inertial measurement units, which consists in small devices capable to measure movement by means of inertial sensors, have widely spread. Inertial measurement units have been employed among others, in fields such as medicine, sports, automotive and gaming.

In the first part of the present thesis, a wearable long-term monitoring inertial measurement unit is presented as the first main contribution in human movement analysis. The unit is capable of acquiring data and provides the possibility of implementing artificial intelligence-based classifiers in real time. A specific hardware and firmware has been developed in order to implement both operations. This tool has been validated in different European projects and studies carried out in the Technical Research Centre for Dependency Care and Autonomous Living of the Universitat Politècnica de Catalunya (CETpD-UPC).

The second part of the thesis addresses the analysis of human posture based on accelerometry measurements. To this end, data acquired from the inertial system described at the first part of the thesis have been used. Two methodologies are presented that have been validated on healthy people and patients with Parkinson's disease. The algorithms developed are focused on the detection of positions with a single inertial system located at the waist thereby achieving an enhanced comfort and

acceptance by the users. A key contribution is the methodology provided to detect postural transitions, which consist in the movement performed to achieve a position from another one. The algorithm is based on support vector machines applied to the inertial data coming from a single measurement unit. Basic activity recognition is performed recognizing static postures such as sitting, standing, or lying with a hierarchical classification system. Moreover, dynamic postures such as walking and different postural transitions are also recognized.

Finally, the posture detection methodologies are employed to enhance the identification of one of the most annoying symptoms of Parkinson's disease, the so-called Freezing of Gait. This contribution relies on the posture algorithm which has been validated in Parkinson's disease patients. Furthermore, it is shown how the introduction of the posture detection improves the evaluation values of the FOG algorithms.

# Resumen

La siguiente disertación presenta las aportaciones del autor en el campo de la monitorización del movimiento humano y, especialmente, en la enfermedad del Parkinson.

Las recientes tecnologías han permitido desarrollar sensores inerciales de tamaño muy reducido para monitorizar el movimiento humano. Estos sensores se emplean en las llamadas unidades de medida inercial, que son unos dispositivos de pequeño tamaño capaces de medir el movimiento, se ha extendido ampliamente empleándose, entre otros, en campos como la medicina, el deporte, la automoción o los videojuegos.

En la primera parte de la presente tesis, se describe el desarrollo de una unidad de medida inercial optimizada para realizar la adquisición y el tratamiento de los datos con un mínimo consumo y, de esa forma, conseguir una larga autonomía. La principal novedad aportada consiste en la posibilidad de implementar en tiempo real clasificadores basados en inteligencia artificial a través de un hardware y un firmware diseñados específicamente para que el sistema inercial sea flexible y capaz de implementar las dos operaciones, captura de datos y ejecución de algoritmos. Esta herramienta se ha validado en diferentes proyectos europeos y diferentes trabajos llevados a cabo en el Centro de Estudios Tecnológicos para la Atención de la Dependencia y la Vida Autónoma de la Universidad Politécnica de Catalunya (CETpD-UPC).

En la segunda parte de la tesis se describen dos algoritmos para identificar diferentes tipos de posturas. Los datos empleados para poder desarrollar los algoritmos se han adquirido con el sistema inercial presentado en la primera parte de

la tesis. Los algoritmos desarrollados se han validado en personas sanas y en pacientes con la enfermedad del Parkinson. Estos algoritmos se focalizan en la detección de posturas con un único sistema inercial localizado en la cintura. Esta localización permite una mayor comodidad para los usuarios, entre otras ventajas. Una aportación importante es la metodología utilizada para poder detectar transiciones posturales (movimiento para pasar de una postura a otra). Se ha empleado el paradigma de las máquinas de vectores soporte para poder distinguir las diferentes posturas del usuario o paciente. La detección de transiciones posturales se integra en un sistema jerárquico de clasificación, al cual se añade un detector de actividades básicas donde se identifican posturas estáticas, como estar sentado, de pie, o tumbado, y posturas dinámicas, como caminar.

En la parte final de la tesis se presenta una aportación a la identificación de uno de los síntomas de la enfermedad del Parkinson más incapacitantes: el bloqueo de la marcha. El algoritmo de posturas se aplica en señales captadas por la unidad inercial descrita en la primera parte de la tesis para complementar a los algoritmos actuales de detección de bloqueos de la marcha. Además, se demuestra cómo los valores de evaluación del algoritmo de detección del bloqueo de la marcha mejoran al aplicar el algoritmo de posturas. De esta forma, el nuevo algoritmo contextualiza la detección del bloqueo de la marcha, omitiendo los casos positivos que ocurran en situaciones donde no es posible que un bloqueo de la marcha ocurra.



# Agradecimientos

Todo logro requiere un esfuerzo, pero este logro no es solo mío, sino el resultado de un esfuerzo de todo un grupo. Es por eso que quiero agradecer muy sinceramente el apoyo que he recibido a lo largo de estos años.

Primeramente, me gustaría mostrar mi agradecimiento al Dr. Albert Samà. A pesar de que no se aceptara como co-director de esta tesis, pienso que su trabajo de dirección y supervisión ha sido excelente, y por supuesto, esta disertación no se habría presentado sin su ayuda. Su colaboración ha estado presente en casi todos los artículos así como en el desarrollo de todos los algoritmos, además, ha prestado su ayuda en la supervisión de la redacción del presente documento.

La dirección de esta tesis corresponde al Dr. Andreu Català, cuya incondicional ayuda ha sido crucial para poder elaborar la tesis doctoral. Su gran guía, apoyo y los recursos que ha ofrecido cuando los he necesitado han sido muy importantes para el desarrollo de este trabajo. Especial mención debo hacer a Carlos Pérez, coordinador de proyectos del centro. Sus ideas, consejos y su extensa colaboración en el desarrollo del sistema inercial presentado en este documento han hecho posible que todo esto se llevara a cabo con éxito. Además, también me gustaría agradecer todo el soporte recibido en el centro y a través del proyecto en el cual se enmarca esta tesis del cual el responsable de que se haya podido realizar ha sido el Prof. Joan Cabestany. Finalmente, me gustaría agradecer a las personas que en algún momento han podido colaborar mediante sus conocimientos y consejos: Boris Takač, Jaume Romagosa, Xavi Pérez, José Juan Guirao, Wilbert Aguilar, Jorge Luis Reyes, Taufique Sayeed, Òscar Franco, Diego Pardo y John N.A. Brown.



# Glosario

- ***PD (Parkinson's Disease)***: La enfermedad del Parkinson.
- ***PT (Postural Transition)***: Transición postural, movimiento por el cual se pasa de una postura a otra (tumbado a sentado, sentado a de pie...).
- ***FoG (Freezing of Gait)***: el Bloqueo de la Marcha, es uno de los trastornos más molestos de la enfermedad del Parkinson. Provoca caídas debido a la pérdida de equilibrio durante la marcha.
- ***IMU***: Unidad de medida inercial. Es un dispositivo compuesto por sensores inerciales + microcontrolador + sistema de comunicación.
- ***Clasificador***: Es una entidad que en función de una entrada no etiquetada es capaz de etiquetar y, por lo tanto, clasificar dicha entrada mediante una serie de reglas de decisión y algoritmos.
- ***Online***: Se entiende por clasificador 'online' cuando el clasificador es capaz de determinar una clase inmediatamente después de haber obtenido los datos.
- ***Offline***: Los clasificadores 'offline' clasifican entradas que se han obtenido de una base de datos en un proceso de recogida anterior.
- ***Escala Hoehn and Yahr***: Esta escala se utiliza para medir el estadio de una persona con la enfermedad del Parkinson. La escala comprende estados del 0 al 5 donde 0 es una persona sana y 5 es el máximo

estadio alcanzable por una persona con la enfermedad del Parkinson.

- ***BD y BU (Bend Down y Bend Up)***: Transición postural de 'Bend Down' (inclinarse hacia adelante) y 'Bend Up' (reincorporarse de estar inclinado).
- ***LS y SL (Lying to Sit y Sit to Lying)***: Transición postural de 'Lying to Sit' (tumbado a sentado) y 'Sit to Lying' (sentado a tumbado).
- ***SiSt y StSi (Sit to Stand y Stand to Sit)***: Transición postural de 'Sit-to-Stand' (levantarse) y 'Stand-to-Sit' (sentarse).
- ***STFT (Short-Time Fourier Transform)***: La Transformada de Fourier de Tiempo Reducido deriva de la transformada de Fourier, aunque esta modalidad se efectúa entre dos instantes de tiempo, que marcan el tiempo de ventana.
- ***Gold Standard***: Procedimiento o test de referencia con el cual se comparan nuevos test para diagnosticar una enfermedad o evaluar alguna actividad.

# Índice general

<b>Capítulo 1 Introducción .....</b>	<b>1</b>
1.1 Marco de trabajo de la tesis	2
1.2 Motivación de la tesis	4
1.2.1 El Parkinson .....	5
1.2.2 El Bloqueo de la Marcha.....	7
1.3 Objetivos	10
1.4 Estructura de la tesis	12
<b>Parte I: La Unidad de Medida Inercial: El 9x2 .....</b>	<b>15</b>
<b>Capítulo 2 Unidades de Medida Inercial .....</b>	<b>17</b>
2.1 Unidades de Medida Inercial en la actualidad	17
2.2 Los sensores inerciales: el acelerómetro, giroscopio y magnetómetro.	19
2.2.1 Acelerómetros .....	19
2.2.2 Giroscopios .....	21
2.2.3 Magnetómetros.....	22
2.3 Estado del arte de Unidades de Medida Inercial	23
2.3.2 Unidades de medida inercial para la elaboración de bases de datos.....	25
2.3.3 Sistemas inerciales con procesamiento en tiempo real .....	28
2.4 Conclusiones acerca de los IMUs	29
<b>Capítulo 3 Unidad de Medida Inercial para monitorización de larga duración.....</b>	<b>30</b>
3.1 Requerimientos para el IMU 9x2	30
3.2 Hardware del 9x2	32
3.2.2 Sensores inerciales del 9x2.....	35
3.2.3 Calibración de los sensores .....	36
3.2.4 Microcontrolador .....	39

3.2.5	Gestión de potencia .....	42
3.2.6	Módulos de comunicación .....	45
3.3	Firmware del sistema .....	46
3.3.1	Proceso principal .....	46
3.3.2	Proceso de captura .....	50
3.3.3	Conexión Bluetooth.....	51
3.3.4	Comunicación con la tarjeta $\mu$ SD.....	51
3.3.5	Proceso algorítmico.....	53
3.3.6	Aplicación 'online' .....	54
3.4	Conclusiones del 9x2 .....	55

***Parte II: Algoritmos de análisis de señal de acelerómetros para la detección de posturas y Bloqueo de la Marcha en pacientes con Parkinson ..... 57***

**Capítulo 4 Metodología de evaluación de la monitorización de actividad.....59**

4.1	Reconocimiento de patrones .....	59
4.2	Las 'Máquinas de vectores soporte' .....	63
4.3	Evaluación de los algoritmos .....	68
4.4	Conclusiones sobre la metodología de evaluación de algoritmos de la monitorización de actividad .....	69

**Capítulo 5 Estado del Arte en detección de actividad..... 71**

5.1	Estado del arte en reconocimiento de actividad .....	71
5.1.1	Sistemas inerciales para el estudio de posturas.....	72
5.1.2	Estado del arte en reconocimiento de posturas con Unidades de Medida Inercial basados en MEMS .....	74
5.2	Conclusiones acerca del estado del arte en detección de actividad .....	80

**Capítulo 6 Detección e identificación de posturas con el algoritmo A45 .....81**

6.2	Algoritmo para la detección de posturas A45 .....	82
6.3	Experimentos de evaluación del algoritmo A45 .....	88
6.4	Resultados y discusión del algoritmo de posturas A45 .....	89
6.5	Conclusiones del algoritmo A45 .....	91

**Capítulo 7 Detección e identificación de posturas con el algoritmo A90 .....93**

7.2	Descripción del algoritmo A90 .....	95
7.3	Umbrales del algoritmo A90 .....	98
7.4	Diseño del clasificador SiSt-StSi en el algoritmo A90 .....	100
7.5	Experimentos de evaluación del algoritmo A90 .....	102
7.6	Resultados y discusión .....	105
7.7	Conclusiones sobre el algoritmo A90 .....	109

<b>Capítulo 8 Estado del arte en el Bloqueo de la Marcha .....</b>	<b>111</b>
8.1 Primeras tentativas para identificar el FoG .....	111
8.2 Hacia una identificación óptima del FoG .....	113
8.3 Conclusiones del estado del arte de FoG .....	115
<b>Capítulo 9 Mejora de la detección del Bloqueo de la Marcha mediante contexto de postura .....</b>	<b>116</b>
9.1 Método de evaluación del algoritmo de detección del bloqueo de la marcha .....	117
9.2 Contextualización del algoritmo de detección de Bloqueo de la Marcha .....	121
9.2.2 Evaluación del algoritmo de detección de Bloqueo de la Marcha con contextualización mediante posturas .....	123
9.3 Conclusiones acerca de la contextualización del algoritmo de detección de FoG .....	127
<b>Parte III: Observaciones finales.....</b>	<b>131</b>
<b>Capítulo 10 Conclusiones, Perspectivas de Futuro y Publicaciones .....</b>	<b>133</b>
10.1 Discusiones y Conclusiones .....	133
10.1.1 Conclusiones acerca del IMU 9x2 .....	134
10.1.2 Conclusiones acerca del análisis de posturas .....	135
10.2 Trabajo Futuro .....	136
10.2.1 El sucesor del 9x2 .....	136
10.2.2 Hacia una generalización del algoritmo de posturas.....	137
10.3 Publicaciones .....	139
<b>Referencias .....</b>	<b>142</b>

# Índice de figuras

Figura 1.1. Relación de la ventana terapéutica y la evolución de la PD	7
Figura 2.1. Principio de funcionamiento del acelerómetro	20
Figura 3.1. El sensor 9x2 y su diseño específico con el cinturón de neopreno	33
Figura 3.2. Diagrama de bloques general del 9x2	34
Figura 3.3. Sistema de magnetómetros del 9x2	36
Figura 3.4. Posiciones de calibración del acelerómetro	38
Figura 3.5. Microcontrolador dsPIC33FJ128MC804, fuente: Microchip Inc.	40
Figura 3.6. Curva de calibración, estabilidad de la frecuencia vs temperatura, fuente: Abracon, Inc.	41
Figura 3.7. Curva de calibración para la frecuencia interna del MCU, fuente: Microchip Inc. 2012.	41
Figura 3.8. Diagrama de bloques de la gestión de potencia del 9x2	43
Figura 3.9. Interacción de los procesos del firmware	47
Figura 3.10. Secuencia de firmware	49
Figura 4.1. Método clásico de clasificación	60
Figura 4.2. Implementación del filtro Butterworth IIR de 2º orden	61
Figura 4.3. Señal filtrada con un filtro IIR de 2º orden	62
Figura 4.5. Hiperplano que maximiza el margen de clasificación entre clases	64
Figura 4.6. Parámetro $\xi$ dentro del problema de clasificación	65
Figura 4.7. Fronteras de decisión de acuerdo con el tratamiento del balanceo de datos	66
Figura 5.1. Respuesta inercial de movimientos estáticos y dinámicos	75
Figura 5.2. Posturas y respuesta inercial con un acelerómetro en la cintura	76
Figura 5.3. Dos casos conflictivos en el reconocimiento postural con análisis en estática con un acelerómetro triaxial	77
Figura 6.1. Ubicación del sistema inercial en el algoritmo A45	81
Figura 6.2. Orientación de los ejes del acelerómetro en la posición anterior-lateral	82

Figura 6.3. Respuesta frecuencial en una transición de postura	84
Figura 6.4. Respuesta de la característica $\Delta(XW - ZW)$	85
Figura 6.5. Algoritmo de identificación de posturas A45	87
Figura 7.1. Ubicación del sistema inercial en el algoritmo A90	93
Figura 7.2. Respuesta inercial de dos PT en dos posiciones diferentes	94
Figura 7.3. Algoritmo de posturas A90	97
Figura 7.4. Análisis de la transición de posturas mediante el DT	101
Figura 7.5. Relación entre precisión, DT y P	106

# Índice de tablas

Tabla 2.1. Comparativa de los principales sensores inerciales del mercado	25
Tabla 3.1. Características del 9x2	34
Tabla 3.2. Autonomías para diferentes modos de operación del MCU	45
Tabla 3.3. Tiempos de cómputo del MCU	55
Tabla 6.1. Resultados del algoritmo A45 para voluntarios sanos	90
Tabla 6.2. Resultados del algoritmo A45 para pacientes con PD	90
Tabla 7.1. Número de episodios registrados para la segunda base de datos con voluntarios sanos	103
Tabla 7.2. Número de episodios registrados para la base de datos de pacientes con la PD	104
Tabla 7.3. Resultados de Sensibilidad y Especificidad de voluntarios sanos	107
Tabla 7.4. Matriz de confusión para los voluntarios sanos	107
Tabla 7.5. Resultados de Sensibilidad y Especificidad para pacientes con PD	108
Tabla 7.6. Matriz de confusión para pacientes con PD	108
Tabla 7.7. Matriz de confusión para pacientes con Parkinson con umbral específico para caminar	109
Tabla 9.1. Evaluación de algoritmos, tabla de episodios de FoG etiquetados	119
Tabla 9.2. Evaluación de algoritmos, tabla de episodios de FoG detectados	119
Tabla 9.3. Evaluación de algoritmos, tabla de periodos de 'sentado' detectados	123
Tabla 9.4. Sensibilidad del algoritmo de detección de FoG	124
Tabla 9.5. Especificidad del algoritmo de detección de FoG	125
Tabla 9.6. Sensibilidad del algoritmo de detección de FoG + Posturas	125
Tabla 9.7. Especificidad del algoritmo de detección de FoG + Posturas	126





# Capítulo 1

## Introducción

El análisis del movimiento humano mediante sistemas inerciales tiene, en la actualidad, gran trascendencia en muchos campos: medicina, deporte y ocio son ejemplos de ello. A través del análisis del movimiento humano es posible diagnosticar o hacer un seguimiento de la evolución de enfermedades como la enfermedad del Parkinson (PD) [1,2] o la epilepsia [3]. En el campo de la rehabilitación se utiliza para valorar la evolución de la ejecución de los movimientos a lo largo de la recuperación de la lesión del paciente [4–6]. En el deporte, además de evaluar la rehabilitación de las lesiones [7] se utiliza también para monitorizar el rendimiento de los deportistas, por ejemplo, para medir la potencia de salto [8], actividad muscular [9], e incluso en modalidades como golf [10,11] o natación [12]. Por otro lado, es bien conocido el uso a nivel doméstico del análisis del movimiento para videojuegos en consolas<sup>12</sup>.

El análisis del movimiento humano se ha beneficiado recientemente de la aparición de la tecnología basada en Sistemas-Micro-Electro-Mecanizados (Micro-Electro-Mechanized-Systems, MEMS). Estos sistemas se han extendido ampliamente en los mercados en sectores como la automoción, la medicina y la industria. Los MEMS inerciales son sistemas que proporcionan información inercial con precisión pero

---

<sup>1</sup> <http://playstationmove.com/index.html>

<sup>2</sup> <http://www.nintendo.com/wii>

también son dispositivos de muy bajo coste y miniaturizados, lo que favorece su uso cada vez más [13,14].

La presente tesis se centra en el análisis del movimiento humano mediante sensores MEMS para su aplicación en el ámbito clínico, especialmente en el campo de la dependencia. Con este fin, se ha desarrollado un dispositivo vestible capaz de adquirir, almacenar y tratar señales inerciales proporcionadas por sensores inerciales basados en MEMS, con el cual se permite desarrollar algoritmos para analizar el movimiento humano de forma prolongada en el tiempo. Este tipo de dispositivos es conocido comúnmente como ‘unidad de medida inercial’ (IMU) y, además de capturar los datos inerciales, es capaz de procesar y enviar los datos, sea en bruto o ya tratados, a otras plataformas para la monitorización del movimiento. Este dispositivo se ha utilizado para desarrollar algoritmos capaces de identificar la postura de un paciente con la PD. En esta tesis, la postura del paciente se emplea para dar contexto a uno de los síntomas más problemáticos de la enfermedad del Parkinson, el Bloqueo de la Marcha (Freezing of Gait, FoG). El FoG es causa directa de caídas, y además provoca depresiones y angustia al paciente. Gracias a la contextualización, es posible aumentar la eficacia de la detección de este síntoma y, por tanto, mejorar la monitorización de la PD, i de esta forma optimizar la pauta terapéutica de los pacientes.

### ***1.1 Marco de trabajo de la tesis***

Esta tesis se enmarca en la línea de investigación sobre la PD, que se está desarrollando en el Centro de Estudios Tecnológicos para la Atención de la Dependencia y la Vida Autónoma (CETpD) de la Universitat Politècnica de Catalunya (UPC).

El CETpD es un centro de investigación multidisciplinar que trabaja en colaboración con diferentes centros médicos de reconocido prestigio mundial como son la Fondazione Santa Lucia (Roma, Italia), el Hospital de Maccabi (Tel Aviv, Israel) y la Fundación Teknon (Barcelona, Catalunya, España). Cabe mencionar también la estrecha colaboración con la Fundació Sant Antoni Abat (Vilanova i la Geltrú, Catalunya, España), centro con amplio prestigio en el campo de la geriatría. Desde el CETpD se trabaja en diversas líneas de investigación: robótica asistencial, inteligencia ambiental y

tecnología asistencial entre otras. Una de las líneas está dedicada a estudiar el movimiento de las personas con dependencia, en particular los síntomas de la PD. Se han realizado diferentes proyectos relacionados con esta enfermedad:

- El proyecto de ámbito nacional ‘Monitorización de la movilidad de enfermos de Parkinson con fines terapéuticos’ (MoMoPa) [15], empezó en 2009 y acabó a mediados del 2011. En este proyecto se analizaron las señales inerciales proporcionadas por un dispositivo vestible en 35 pacientes con la PD. Con las señales inerciales se estudiaron diferentes parámetros relacionados con la enfermedad con el fin de realizar algoritmos inteligentes capaces de poder detectar sintomatología relacionada con la PD.
- El proyecto de ámbito internacional Home-based Empowered Living for Parkinson’s Disease (HELP) [16] se empezó a mediados del 2009 y finalizó en Marzo del 2011. En este proyecto se estudiaron diferentes síntomas de la PD junto con caídas, movimientos involuntarios y parámetros de la marcha en pacientes con la PD. Los algoritmos se implementaron en tiempo real para proporcionar información clínica a médicos y mediante una bomba de infusión subcutánea se administraba la medicación al paciente de acuerdo a los síntomas mostrados por el paciente. Este proyecto recibió el premio de la Asociación Europea de Proyectos (European Project Association, EPA) al mejor proyecto europeo concluido en el año 2013 [17].
- En la actualidad se está llevando a cabo un proyecto europeo coordinado por el CETpD (Personal Health Device for the Remote and Autonomous Management of Parkinson’s Disease, REMPARK) [18], en el cual la tesis se encuentra enmarcada. En este proyecto se ha obtenido una base de datos de señales inerciales con más de 90 pacientes con la PD. Los algoritmos diseñados servirán para poder actuar sobre el paciente en función de la sintomatología manifestada. Este proyecto empezó a finales del 2011 y prevé su finalización en 2015.

## ***1.2 Motivación de la tesis***

Los motivos por los que se realiza la tesis están marcados por las líneas de investigación y los diferentes proyectos que se realizan en el CETpD-UPC. La motivación principal de esta tesis es poder contribuir a la mejora de la evaluación de la calidad de vida de pacientes con la PD. Esta mejora podrá aportar información útil a los clínicos para dar soporte en la realización de los diagnósticos y también para que puedan ajustar las medicaciones con más precisión.

El Parkinson es la segunda enfermedad neurodegenerativa más común, después del Alzheimer. Esta enfermedad tiene como principal característica la alteración del control motor de los pacientes que la sufren. Además, frecuentemente la evolución o el estado del paciente se hace solamente a través de la evaluación subjetiva, como por ejemplo la escala de Hoehn & Yahr [19] o la UPDRS [20,21]. Una evaluación objetiva de la progresión de la enfermedad, sin la necesidad de que los clínicos estén con el paciente todo el día, se ha de realizar a través de la observación, análisis y cuantificación de movimientos específicos de la enfermedad. Por esa razón, es necesario poder diseñar un dispositivo que pueda capturar los movimientos de un paciente con la PD de forma ambulatoria. El dispositivo debe ser capaz de recolectar esa información durante un largo periodo de tiempo. Además, ha de ser capaz de incorporar algoritmos para que pueda detectar los trastornos motores que presente el paciente. El dispositivo por tanto debe ejecutar algoritmos en tiempo real simultáneamente con la recogida de los datos inerciales.

Un sistema de estas características también se puede utilizar para realizar diversos tipos de análisis del movimiento humano. De esta manera, se puede emplear para otros usos como análisis de caídas en gente mayor, epilepsia, rehabilitación y deporte. En esta tesis sin embargo se trata específicamente el análisis de la enfermedad del Parkinson y su contexto en el FoG.

### 1.2.1 El Parkinson

La enfermedad del Parkinson (PD) es una enfermedad crónica neurodegenerativa que afecta a un total de 150.000 personas en España [22] siendo la segunda más frecuente sólo por detrás del Alzheimer. Según la European Parkinson's Disease Association (EPDA)<sup>3</sup>, hay 1.2 millones de casos en Europa, de los cuales, 120.000 son de Reino Unido, 260.000 en Alemania, y 117.000 en Francia. En Estados Unidos hay 1.000.000 de casos. En el mundo se estima que pueden haber unos 10.000.000 millones de afectados según la 'Parkinson's Disease Foundation' <sup>4</sup>, aunque la EPDA estima esta cifra en 6.3 millones.

La PD está causada por una pérdida progresiva de neuronas dopaminérgicas y otras neuronas subcorticales situadas en la 'substancia negra' (Substantia Nigra) en el encéfalo [23]. Estas neuronas tienen la función de controlar el movimiento y la coordinación de la persona. A medida que las neuronas mueren y las conexiones entre ellas van desapareciendo, los trastornos de un paciente con la PD se hacen cada vez más notables [24,25].

Los trastornos más comunes en la enfermedad del Parkinson son los siguientes:

- **Bradicinesia.** La Bradicinesia es uno de los principales síntomas de la PD. Está caracterizada por la lentitud del movimiento. Es probablemente el mejor marcador para observar la evolución de la enfermedad de la PD. Una de las consecuencias en la marcha ocurre cuando el paciente inclina ligeramente su tronco adoptando una postura hacia adelante perdiendo frecuentemente el centro de gravedad del cuerpo y provocando una sensación de caída, que produce festinaciones en la marcha para recuperar el equilibrio [26,27].
- **Discinesia.** Este síntoma aparece cuando hay exceso de medicación (levodopa o agonistas) en el paciente, éste realiza movimientos rítmicos

---

<sup>3</sup> <http://www.epda.eu.com/>

<sup>4</sup> <http://www.pdf.org/>

involuntarios en cualquier postura [28,29].

- Hipocinesia. La principal característica de la hipocinesia es la reducción de la amplitud del movimiento, haciendo que el paciente se mueva con pasos muy cortos [29,30].
- Temblores. Son una alteración del movimiento involuntaria que se manifiesta con movimientos cortos y rápidos en las manos, brazos y piernas. Es muy molesto puesto que el paciente no puede coger objetos con seguridad y firmeza [29].
- Bloqueo de la marcha (Freezing of Gait, FoG). El FoG está definido por los mismos pacientes “como si los pies se quedaran pegados en el suelo” [31]. Este síntoma consiste, formalmente, en una incapacidad repentina para realizar pasos eficientes durante el proceso de la marcha [32].

A excepción de las discinesias, y en algunos pacientes el FoG, los demás síntomas se alivian mediante un fármaco llamado levodopa o L-dopa, o bien a través de agonistas de la L-dopa [33,34]. Sin embargo, el paciente no responde bien a la medicación en estadios avanzados de la PD, sufriendo discinesias como se ha comentado anteriormente [35]. Se ha visto también que el efecto de la levodopa no alivia el FoG en algunos pacientes, provocándoles en ocasiones episodios de FoG cuando se les trata con este fármaco [36].

El efecto de la medicación puede durar entre una 1 y 3 horas. El paso en el cual la medicación ejerce un efecto terapéutico en el estado psicomotor del paciente se llama fluctuación ON-OFF. Los estados ON y OFF son los estados en los cuales el paciente muestra un estado psicomotor particular en función del efecto de la medicación que ejerce sobre el paciente. En estado ‘ON’ el paciente muestra una movilidad normal, casi idéntica a una persona sana. En el estado ‘OFF’ el paciente muestra los síntomas más característicos de la PD. Ajustar la medicación a la ventana terapéutica en función del estadio de la enfermedad del paciente es uno de los mayores problemas de prescripción que se enfrentan los neurólogos (Figura 1.1).

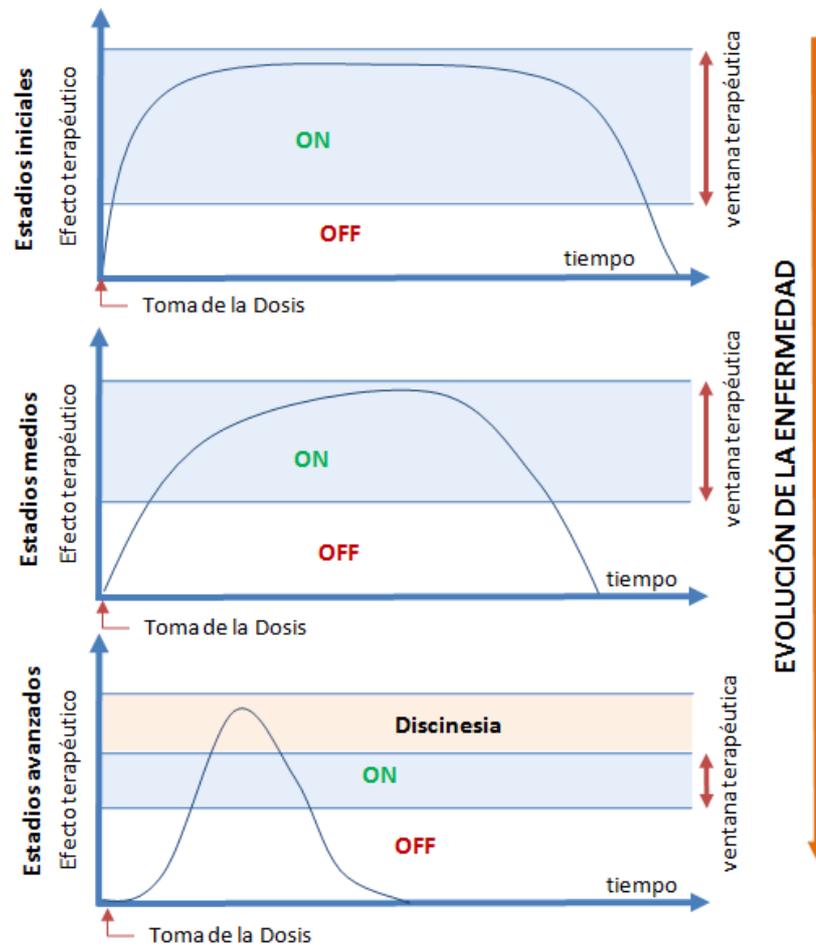


Figura 1.1. Relación de la ventana terapéutica y la evolución de la PD

Gran parte de los proyectos que se han realizado en el CETpD tienen como objetivo ayudar al ajuste de la medicación para maximizar el tiempo en el que el efecto de ésta se encuentre en la ventana terapéutica particular de cada paciente. Para ello, se han desarrollado dispositivos para medir parámetros de la marcha, posturas y síntomas de la PD. Estos parámetros se han asociado con el estado terapéutico actual del paciente. El correcto ajuste de la medicación permitirá al paciente estar en estado de ON durante más tiempo sin llegar al estado de sobremedicación donde se producen las típicas discinesias.

### 1.2.2 El Bloqueo de la Marcha

El Bloqueo de la Marcha o FoG es uno de los síntomas más incapacitantes de la PD. Este síntoma consiste en una parada repentina de la capacidad motora en aspectos

relacionados especialmente con la marcha.

El FoG es causa directa de caídas en enfermos con PD. Los pacientes, al tener “los pies pegados en el suelo”, pierden el equilibrio con frecuencia, pues su instinto les ordena caminar pero sus pies no reaccionan [37,38]. Estos episodios duran menos de 10 segundos aunque, en ocasiones, pueden durar incluso más de 30 segundos. El FoG, además, produce varios problemas psicológicos como frustración o angustia. En episodios avanzados impide hacer movimientos básicos o provoca que su marcha quede repentinamente bloqueada durante muchos segundos. Además, hay pacientes que sienten miedo por quedar mal en una situación delante de la sociedad. Bajo presión, se puede producir un bloqueo como, por ejemplo, al cruzar la calle en un semáforo. Los cuidadores, asimismo, también ven incrementado su estrés al soportar depresiones de los pacientes y evitar o paliar caídas [39].

El FoG es uno de los principales síntomas en pacientes con la PD avanzada [40], sin embargo, es posible que también se manifieste en episodios tempranos de la PD. También se ha observado que ocurre con más frecuencia en estado de ‘OFF’, aunque también ocurre con una frecuencia no menospreciable en ‘ON’ [36,41].

Se ha comprobado en estudios previos que es posible interrumpir los bloqueos mediante la aplicación de un estímulo sensorial en forma de señales auditivas rítmicas, hápticas (vía tónica, eléctrica) o visuales [42,43]. Mediante esta técnica o ‘truco’ se puede ‘desbloquear’ a los pacientes o reducir el riesgo de sufrir un episodio de FoG y, de esta forma, seguir su ritmo de vida natural [44].

El FoG se puede clasificar en función de su contexto, es decir, en la situación en la que ocurre este síntoma en un paciente. Según Schaafsma, hay 5 tipos en las que la principal característica es la duda, vacilación o indecisión del paciente al pasar de una actividad a otra [41]:

- Al inicio de la marcha justo antes de ponerse a caminar, frecuentemente tras estar sentado, levantarse y disponerse a caminar.
- Durante la marcha, al encontrarse a un obstáculo (mueble, persona, animal de compañía...) y tener que girar para esquivarlo.
- Durante la marcha, en zonas estrechas, pasillos o puertas, muebles bajos (entre una mesa y un sofá)

- Al final de la marcha, vacilación al llegar al destino.
- Durante la marcha, hesitación en espacios abiertos.

Okuma et al. reporta en su trabajo que la hesitación en espacios abiertos está asociada a evitar colisionar con personas en lugares abiertos concurridos. La clasificación realizada por Schaafsma, podría modificarse juntando la hesitación en espacios abiertos y encuentros con obstáculos [45]. Por otro lado, el estrés [46], la ansiedad y la realización de dos tareas simultáneas, así como distracciones también son causas de un episodio de FoG [47]. También se distinguen distintos tipos de FoG en función de su forma de manifestarse [41]:

- Tipo acinético. En tipo de FoG la persona permanece inmóvil, rígida, totalmente quieta, pero con capacidad para hablar.
- Arrastrando los pies o “shuffling”. El paciente se ve incapaz de levantar el pie en el proceso de la marcha para realizar eficientemente un paso. En este caso, el paciente intenta avanzar y lo logra arrastrando los pies, a la vez que temblando.
- Temblor estático. En este tipo de bloqueos el paciente sufre un temblor estático en la pierna, de forma que la persona intenta avanzar sin llegar a realizarlo [38,48].

Hay varios grupos investigando la detección del FoG. Los resultados publicados son, hasta el momento, en ámbitos laboratorios de forma ambulatoria [2,49–52] y se hacen en entornos muy controlados. Un gran porcentaje de pacientes afirma que no sufren los síntomas del FoG cuando están bajo supervisión en la consulta [53]. Por esta razón, los resultados de las pruebas hechas en el laboratorio se complementan con cuestionarios que se les realiza a los mismos pacientes. Pese a realizar cuestionarios a los pacientes, las respuestas de éstos son difusas puesto que a veces no están en condiciones cognitivas para contestar de forma objetiva [40,54,55]. Los episodios de FoG, además, se pueden confundir con la bradicinesia o incluso con la acinesia [36]. Sus movimientos son tan heterogéneos, que los resultados de los análisis que realizan los neurólogos e ingenieros muchas veces no son concluyentes. Este hecho, junto con el de la dificultad de inducir el

FoG a un paciente en una clínica, hace que la investigación en este campo se haya frenado en los últimos años [31].

A pesar de las dificultades obtenidas en los análisis de este síntoma, existe un algoritmo de detección de FoG aceptado por la comunidad de neurólogos para evaluar este trastorno. A través de señales inerciales es posible determinar con precisión si se presencia un episodio de FoG o no. Sin embargo, el algoritmo solo se ha evaluado en laboratorios bajo la supervisión de clínicos y en protocolos de pruebas muy controlados. En la vida diaria, el algoritmo está sujeto a situaciones que puede provocar falsos positivos, y en consecuencia, empeorar los resultados obtenidos en la detección del FoG [2,56].

La contextualización del FoG permitirá aportar una mejora significativa en la detección del FoG, evitando falsos positivos. Además, conocer el contexto, la postura en la que ha ocurrido un episodio (por ejemplo justo después de levantarse), aporta información útil a los neurólogos para realizar un seguimiento más completo de la enfermedad.

Por otro lado, dado que el problema principal del estudio del FoG es que los pacientes no manifiestan los síntomas en la consulta clínica, portar en sus casas un sistema inercial cómodo, portable, vestible y capaz de monitorizar la enfermedad permitiría adaptar tratamientos a los pacientes para que sean mucho más efectivos. Para poder realizar un seguimiento objetivo de los trastornos motores del FoG y realizar una contextualización del FoG se requiere una herramienta capaz de almacenar los movimientos que ha realizado el paciente en forma de señal inercial. En consecuencia, poder utilizar estos datos capturados para poder realizar algoritmos que permitan identificar posturas y, de esta forma, aporten una contextualización dentro del algoritmo de detección del FoG. Este dispositivo deberá ser ligero y de reducido tamaño para que pueda ser vestible, y además ha de incorporar la posibilidad de integrar algoritmos para que puedan ejecutarse en tiempo real.

### ***1.3 Objetivos***

El objetivo principal de esta tesis es contribuir a la mejora de la detección de la

sintomatología de la PD, tratando particularmente el síntoma del FoG. Tal como se ha visto, la detección ambulatoria y continua de síntomas de la PD permitirá ajustar los tratamientos a los enfermos para, así, reducir los síntomas adversos de la enfermedad. Se han definido diferentes sub-objetivos para llevar a cabo la tesis:

- *Diseño de un sistema inercial para la monitorización ambulatoria en el campo de la dependencia:* El primer paso en la mejora de la detección de síntomas basada en el análisis de señales inerciales consiste en el desarrollo de un dispositivo capaz de poder almacenar señales inerciales y, a su vez, capaz de poder ejecutar en tiempo real clasificadores que permitan determinar la presencia de un síntoma o el estado motor de los pacientes en función de las señales inerciales analizadas. El dispositivo debe cumplir con unos requisitos determinados para poder cubrir todas las necesidades de monitorización que requieran los proyectos y las diferentes investigaciones que se realicen desde el CETpD. Tal como se detallará a lo largo de la tesis, entre los requisitos principales consta la autonomía y la multifuncionalidad del dispositivo (captura y ejecución online de clasificadores).
- *Diseño de un algoritmo de identificación de posturas y detección de transiciones entre éstas mediante un sólo acelerómetro triaxial:* Una vez se disponga de un dispositivo capaz de monitorizar el movimiento humano en periodos de larga duración, una de las partes más importantes de la tesis es la de poder diseñar clasificadores capaces de poder detectar transiciones posturales a través del sistema inercial localizado en la cintura. La contribución principal viene dada por ser capaz de determinar la postura de la persona que lleva el dispositivo con sólo un punto de referencia (cintura), a diferencia de trabajos anteriores donde se necesitaron diferentes sistemas inerciales para determinarla. El algoritmo permitirá realizar un seguimiento de la postura y la actividad en personas con edad avanzada o pacientes con la PD. Los algoritmos desarrollados contribuyen al análisis del movimiento humano permitiendo realizar una evaluación de la calidad de vida de los

pacientes con un sistema de máxima usabilidad, es decir, con sólo un dispositivo pequeño localizado en la cintura.

- *Contextualización del FoG mediante el algoritmo de posturas validado:* Poder monitorizar posturas y actividad es útil para poder hacer un seguimiento en pacientes en proceso de rehabilitación, evaluar actividades deportivas o se puede aplicar en otros campos como los videojuegos. Sin embargo, una de las aportaciones principales de la tesis es poder contextualizar el FoG con el fin de poder mejorar la detección en términos de especificidad. Añadir contexto en un paciente con Parkinson puede ayudar a la creación de un gold estándar (una referencia para el diagnóstico del FoG) para los clínicos, y sobre todo, mejorar la monitorización del FoG.

## 1.4 Estructura de la tesis

La tesis se divide en dos grandes partes:

- En la Parte I se presentan las aportaciones relacionadas con la elaboración del dispositivo inercial y está dividida en 2 capítulos. En el Capítulo 2 se realiza un estado del arte de los actuales sistemas inerciales disponibles, sean sensores inerciales basados en MEMS o bien dispositivos que usen otras técnicas como electromiografía. A continuación, en el Capítulo 3 se describe el dispositivo inercial realizado, el cual está basado en MEMS. Se describen cada una de sus partes, haciendo hincapié en las mejoras y ventajas del sistema con respecto otros mecanismos que se utilizan en el ámbito clínico o deportivo para fines similares. A su vez, se especifican las características de microcontrolador, de los propios sensores inerciales y de los módulos de comunicaciones, junto al proceso de calibración de los sensores y de los sistemas de reloj del microcontrolador. Por otro lado, se describe el firmware general y la gestión de prioridades de los procesos que intervienen. Finalmente, se muestran las experimentaciones llevadas a cabo, tanto en

autonomía del dispositivo adquiriendo datos continuamente como los análisis temporales con los clasificadores en tiempo real.

- En la Parte II de la tesis se describen las aportaciones relacionadas con los dos clasificadores para detectar posturas. Esta parte está dividida en 5 capítulos. El Capítulo 4 describe una breve introducción referente a los clasificadores basados en inteligencia artificial y además se detallan los indicadores para poder evaluar la validez de los algoritmos diseñados. En el Capítulo 5 se realiza un estado del arte explicando las diferentes técnicas que se han utilizado para estudiar las posturas. Además, se hace especial énfasis en las transiciones posturales de 'sentarse' y 'levantarse'. El Capítulo 6 y el Capítulo 7 describen las dos principales aportaciones de esta parte de la tesis. Están constituidos por la descripción de los algoritmos de posturas, con datos entrenados con gente sana, y evaluados tanto en gente sana como con pacientes con la PD. Finalmente se concluye con una aplicación del algoritmo de posturas para mejorar un algoritmo de detección del bloqueo de la marcha. El Capítulo 8 describe un estado del arte acerca de la detección del Bloqueo de la marcha y el Capítulo 9 describe el método de evaluación y los resultados del algoritmo descrito en el Capítulo 7 aplicado a la detección del Bloqueo de la Marcha. Dentro del capítulo se realiza una comparativa entre el algoritmo original y contextualizado con el algoritmo de posturas.

Finalmente, se incluye la Parte III, donde se describen las conclusiones, el trabajo futuro y se reportan las diferentes publicaciones de revistas y conferencias relacionadas con la presente tesis.



*Parte I: La Unidad de Medida*

*Inercial: El 9x2*



# Capítulo 2

## Unidades de Medida Inercial

En este capítulo se introduce el concepto de Unidad de Medida Inercial (Inertial Measurement Unit, IMU) y su aparición fruto de la tecnología MEMS. Además, se describe brevemente cada uno de los componentes inerciales del IMU junto a sus principios de funcionamiento. Finalmente, se describen y comparan las IMUs más utilizadas en los estudios del movimiento humano. Del análisis realizado en este capítulo, tal como se verá, se extrae la falta de un dispositivo capaz de realizar las funciones de recolectar datos inerciales y, a la vez, de implementar clasificadores en tiempo real. La falta de un dispositivo con estas características justifica la IMU presentada en el Capítulo 3, donde se detallarán a nivel de hardware y firmware todas sus características.

### *2.1 Unidades de Medida Inercial en la actualidad*

Los recientes desarrollos tecnológicos en el campo de la automoción, las telecomunicaciones y la electrónica han permitido una mayor evolución en las posibilidades para la medición y monitorización del movimiento humano [5].

Uno de los aspectos de mayor interés en el campo de la monitorización del

movimiento humano se encuentra en aplicaciones para el deporte [11,57–59] y la salud [3,56,60–62]. Dentro del área de la atención a la dependencia y la telemedicina, la evaluación y monitorización de la actividad de la vida diaria a través del análisis del movimiento humano es de gran interés. Se puede aplicar en la evaluación de la calidad de vida [63–65]. Por ejemplo, Brandes et al. usaba un acelerómetro para visualizar la cantidad de movimiento que efectuaba un paciente de osteoartritis. En función de la cantidad de movimiento realizado a lo largo del día se determina la calidad de vida del paciente. Por tanto, realizar muy poca actividad durante un periodo prolongado durante varios días, es considerado un indicativo del deterioro de la calidad de vida del paciente [66].

También se ha aplicado para analizar la marcha. Auvinet et al. describen como la longitud del paso, la velocidad y otros parámetros son dependientes de la edad y otros parámetros son dependientes del género [67]. Por otra parte, el análisis del movimiento humano permite caracterizar aquellos movimientos que son propios de una sintomatología, como por ejemplo la PD. Cuando se analizan los movimientos en una persona con PD, se pueden determinar o diagnosticar algunos síntomas como la severidad del temblor o como la bradicinesia en una persona con PD [61], detectar la aparición de episodios de FoG [49], o bien caracterizar las discinesias[68].

Los acelerómetros y los giroscopios basados en MEMS se han convertido en los dispositivos más utilizados en el estudio del movimiento humano [69]. Las ventajas respecto otras tecnologías son principalmente el reducido tamaño y peso que facilita la no invasividad [70]. Los MEMS se emplean junto a un microcontrolador que procesa los datos suministrados. También se emplean junto a módulos de almacenaje de memoria de datos como puede ser una tarjeta  $\mu$ SD o bien junto a un módulo que permita enviar la información hacia algún agente exterior (PC, tablet, teléfono móvil). Los protocolos de comunicación pueden ser inalámbricos (Bluetooth o Zigbee), o bien, a través de comunicaciones cableadas así como por UART, CAN, etc. Estos módulos de comunicación se encuentran frecuentemente integrados dentro del microcontrolador. Estos sistemas, en su conjunto (sensores inerciales, microcontrolador y módulos de comunicación), se denominan IMUs. En la actualidad, los IMUs están siendo ampliamente empleados para el análisis del movimiento humano debido a la facilidad

para capturas de datos inerciales en periodos largos y, gracias a su reducido tamaño, les permiten ser vestibles y de sencilla utilización [65,71–75].

## ***2.2 Los sensores inerciales: el acelerómetro, giroscopio y magnetómetro.***

En esta sección se detallan las características de los sensores inerciales más comunes en un IMU, que consisten en acelerómetros, giroscopios y magnetómetros basados en MEMS.

### ***2.2.1 Acelerómetros***

Los acelerómetros basados en MEMS son uno de los componentes más empleados en la actualidad. Por ejemplo, es posible encontrar acelerómetros en un disco duro de ordenador o un portátil para detectar caída libre (gravedad cero). Como consecuencia, el sistema se desconecta antes de que el dispositivo choque contra el suelo y se pueda dañar. En otras aplicaciones de uso doméstico, se pueden encontrar acelerómetros dentro de los teléfonos móviles para múltiples aplicaciones (navegación, juegos, calibración de cámara...). Desde hace unos pocos años, es muy frecuente encontrarse acelerómetros en mandos de videoconsolas. Además, se pueden emplear también en la estabilización de videocámaras, equipamientos deportivos, robótica, monitorización de vibraciones en aplicaciones industriales y para medir el impacto recibido de objetos o productos para análisis de calidad. También son utilizados en los automóviles, por ejemplo, en sus sistemas de seguridad, como airbags o en sistemas de estabilidad del vehículo. En el ámbito aeronáutico, son empleados para estabilización de aeronaves y navegación. Dentro de la sismografía, se emplean en sistemas relacionados con la extracción de petróleo o la monitorización de terremotos [13].

Para el estudio del movimiento humano el acelerómetro se ha convertido en el sensor más utilizado debido a las ventajas que proporciona, entre otras, la información inercial dinámica (la señal proporcionada cuando hay movimiento), pero también ofrece

información inercial estática (cuando hay ausencia de movimiento), por ejemplo, la orientación relativa respecto a la gravedad [69].

Los acelerómetros se pueden clasificar de acuerdo a su principio de funcionamiento como: mecánicos, de efecto Hall, piezoeléctricos, piezoresistivos, y capacitivos, siendo estos dos últimos los más utilizados. Los acelerómetros más antiguos, los piezoresistivos, aparecieron por los años 80, aunque durante los 70 ya se emplearon estos sistemas con sensores de presión. Sin embargo, aún se sigue usando esta tecnología puesto que estos acelerómetros son baratos e inmunes a interferencias electromagnéticas [76]. Los acelerómetros capacitivos son los que presentan mayores prestaciones y, en consecuencia, son los más extendidos hoy en día. Presentan mayor sensibilidad, son más robustos frente a cambios de temperatura, tienen derivas muy reducidas y su consumo es menor. Sin embargo, son bastante susceptibles a las interferencias electromagnéticas [77].

El principio de funcionamiento de este tipo de sensores consiste en modificar la capacitancia de dos condensadores variables a través del movimiento de dos placas que realizan la función del condensador. La Figura 2.1 muestra gráficamente el comportamiento de las placas y el cambio de capacitancia al moverse debido a una aceleración externa.

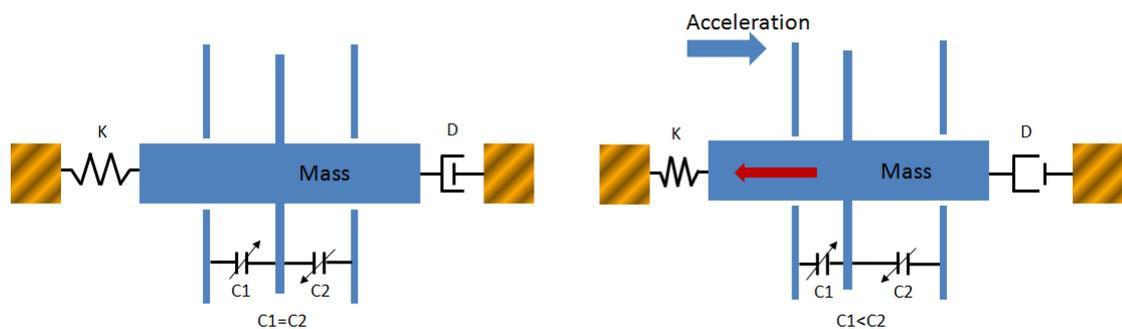


Figura 2.1. Principio de funcionamiento del acelerómetro

La función de transferencia de cualquier acelerómetro se puede obtener siguiendo la segunda ley de Newton y el modelo del acelerómetro clásico: masa-resorte amortiguador [13].

$$H(s) = \frac{x(s)}{a(s)} = \frac{1}{s^2 + \frac{D}{M}s + \frac{K}{M}} = \frac{1}{s^2 + \frac{\omega_r}{Q}s + \omega_r^2} \quad (2.1)$$

donde  $a$  es la aceleración a la que es sometida la masa  $M$ ,  $x$  es el desplazamiento de la masa y  $D$  y  $K$  son las constantes de amortiguamiento y resorte respectivamente.  $\omega_r$  es la frecuencia de resonancia natural del sistema que viene dada por  $\sqrt{K/M}$  y  $Q$  es el factor de calidad dado por  $\sqrt{KM/D}$ .

Una de las características del acelerómetro relacionada con la calidad de la medida es el *off-axis*. El *off-axis* es el error que sufre una medida del acelerómetro en uno de sus ejes suponiendo que el acelerómetro tiene más de un eje de medida. En otras palabras, el *off-axis* indica la correcta alineación de los ejes del acelerómetro para que la fuerza aplicada en un eje no influya en otro eje.

El acelerómetro utilizado en esta tesis es del tipo capacitivo, apto para detectar movimiento humano [78]. Se describe con más detalle en el apartado 3.2.2.

### 2.2.2 Giroscopios

El giroscopio mide la velocidad angular de un objeto y se emplea, al igual que el acelerómetro, en múltiples aplicaciones. Por ejemplo se puede encontrar en la estabilización de cámaras de fotografía y videocámaras a la hora de compensar el movimiento efectuado. En los automóviles también se utilizan para detectar vuelcos, y para la estabilización del vehículo. También se pueden encontrar en ratones de PC, en robótica, en sistemas de navegación de aviones y para uso militar [13]. El principio básico de funcionamiento se basa en la medida del efecto Coriolis. El efecto de Coriolis causa que la estructura mecánica del giroscopio haga vibrar a una segunda estructura. Esta vibración es directamente proporcional a la velocidad de rotación del sistema y se puede medir a través de la capacitancia variable debido a la vibración entre la segunda estructura mecánica y unos electrodos fijos [79][80].

Entre los trabajos realizados con giroscopios para el análisis del movimiento humano destaca el análisis de la marcha [81], transiciones de postura [82] o caídas [83]. Debido a

su amplio uso en la industria de los videojuegos y aplicaciones para teléfonos móviles, se han convertido en dispositivos de muy bajo coste.

A diferencia del acelerómetro, el uso del giroscopio en el estudio del movimiento humano es más limitado debido a sus características implícitas. Una de ellas es el hecho de no aportar información inercial añadida respecto del acelerómetro cuando hay ausencia de movimiento. El giroscopio no proporciona ningún tipo de medida más que el ruido blanco y funciones propias de la fabricación del dispositivo detalladas en las hojas de datos de cada uno de los dispositivos. En los giroscopios, a pesar de que la información relevante en este caso podría ser que hay ausencia de movimiento, el acelerómetro ya nos proporciona esta información, añadiendo además la inclinación respecto del eje de la gravedad. El giroscopio es propenso a sufrir derivas debido a cambios de temperatura a lo largo del tiempo. Por tanto, se ha de recalibrar con frecuencia en el caso de tomar medidas en periodos largos.

### *2.2.3 Magnetómetros*

Los magnetómetros miden el campo magnético en un punto determinado. Existen dos tipos básicos de sensores magnetómetros, los que miden el campo magnético absoluto, y los que miden el campo magnético vectorialmente. Este último, se emplea para poder orientarse en un punto en el espacio. Puesto que la dirección y amplitud del campo magnético de la Tierra es conocido en cualquier punto del planeta gracias a la base de datos del 'National Ocean and Atmosphere Administration'<sup>5</sup> (NOAA), se puede determinar la orientación de un objeto a través de un magnetómetro triaxial.

Dentro de los sensores que miden campo magnético vectorialmente, se encuentran entre otros los magnetómetros inductivos, de núcleo saturado (fluxgate), superconductores, los de efecto Hall, los magnetoresistivos, etc. [84]. Uno de los más usados para poder medir movimiento humano es el magnetoresistivo, en particular el magnetómetro con magnetoresistencia anisotrópica (AMR). En este tipo de magnetómetro de la resistencia que se mide es directamente proporcional al ángulo

---

<sup>5</sup> <http://www.noaa.gov>

entre la magnetización de la resistencia y la dirección del campo magnético que circula por ésta [85,86].

Los magnetómetros se emplean para determinar la orientación de un objeto, por lo que tienen múltiples aplicaciones relacionadas con la navegación, estabilidad y seguridad, en automóviles, robótica y ámbitos militares. Además se emplea para la detección de objetos metálicos, así como para minería [87]. Sin embargo, estos sensores son susceptibles a ruidos, además, el valor de la resistencia en los sensores AMR pueden variar con mucha facilidad al detectar un objeto ferromagnético en su cercanía. Dado que la orientación con magnetómetros se determina a través del campo magnético de la Tierra, no conviene estar cerca de elementos ferromagnéticos al realizar una medida, ya que alteran considerablemente las medidas, y se obtendría el campo magnético de la Tierra sumado al campo magnético que fluye por el elemento ferromagnético [84].

### ***2.3 Estado del arte de Unidades de Medida Inercial***

En este apartado se introducen los IMUs. Entre varias clasificaciones, se ha optado por clasificar a los IMUs por su capacidad para computar un algoritmo o por su capacidad de almacenaje de datos inerciales. Para ello se realiza una breve introducción de los IMUs dentro de la inteligencia artificial, y dentro del campo de la atención para la dependencia.

Los IMUs se han utilizado, dentro del campo de la investigación, para diferentes aplicaciones, tales como la medida de cantidad de movimiento en actividades de la vida diaria [88] o para la obtención de variables de rendimiento en el campo del deporte [89]. En el campo de la atención para la dependencia, los IMUs se utilizan para el seguimiento de alteraciones motoras y para la evaluación de la calidad de vida [63–65]. Algunas investigaciones realizadas donde se monitorizan actividades y se realizan diagnósticos a partir de la respuesta de las señales inerciales dependen de métodos de aprendizaje supervisados. En el campo de la Inteligencia Artificial, los métodos de aprendizaje supervisado se basan en aprender las características de las muestras seleccionadas para entrenar el algoritmo en función de una etiqueta conocida, mientras que los no supervisados, los algoritmos aprenden en función de la entrada de nuevas muestras sin

conocer la etiqueta. Dentro del campo de estudio de la PD , se han utilizado árboles de decisión [1], clasificadores lineales [61] y ‘Máquinas de vectores soporte’ (Support Vector Machines, SVM) [68,90,91] para determinar los síntomas específicos de la enfermedad. Los métodos de aprendizaje supervisado también se han empleado para la clasificación de episodios de epilepsia [3] y para el análisis de actividad en pacientes con enfermedades cerebrovasculares [6]. El algoritmo supervisado que resulta después de un proceso de entrenamiento y que, dentro del campo del análisis del movimiento humano, determina la presencia de síntomas o la realización de actividades se denomina, en este documento, clasificador ‘offline’ puesto que depende de datos previamente recolectados y no ofrecen detección en tiempo real. El algoritmo ‘offline’ requiere un proceso de entrenamiento que implica que los datos estén etiquetados. Por tanto, es necesario elaborar una base de datos a través de las señales inerciales a través de la IMU.

Por otra parte, el clasificador ‘online’, dentro de un modelo de aprendizaje supervisado, reúne los parámetros del modelo previamente entrenado y clasifica las muestras de entrada del modelo del clasificador en tiempo real.

Se distinguen dos grupos entre las IMUs, por una parte aquellas IMUs que sólo proporcionan y guardan la información inercial de sus sensores y, por la otra parte, aquellas IMUs que proporcionan resultados de algún clasificador ‘online’ implementado. Sin embargo, ninguno de los sensores inerciales presentados en este capítulo pertenece a ambas clases a la vez. La Tabla 2.1 muestra la relación de IMUs que existen a día de hoy en el mercado.

Los IMU’s correspondientes a la primera clase se caracterizan por permitir la captura y almacenaje de datos sin capacidad de analizar las señales en tiempo real. De esta manera, el microcontrolador envía los datos a una unidad de almacenamiento integrada en el mismo sistema o a un terminal (PC, tablet) mediante una conexión, ya sea cableada (SPI, UART...) o inalámbrica (Bluetooth, ZigBee...). Otra manera de poder comunicarse a través de un terminal sin la necesidad de cableado, es a través de alguna comunicación inalámbrica. Sin embargo, esta tecnología, si se usa para confeccionar bases de datos, tiene un consumo de energía muy alto.

Nombre del sensor	Fabricante	Freq.	Info	Tamaño(mm <sup>3</sup> )	Peso(g)	Capacidad	Unidad	Wireless	Acc	Giro	Magn	GPS
		muestreo(Hz)	Autonomía			Datalog	Almacenaje					
Mtw	Xsens	120	3,5 horas	34.5x58x14.5	27	Sí	No	Sí	Sí	Sí	Sí	No
Mti-G	Xsens	120	610 mW	58x58x28	68	Sí	No	No	Sí	Sí	Sí	Sí
Main Unit+Wireless 9DoF	Shimmer	50	450 mAh	53x32x25	22	Sí	Sí	Sí	Sí	Sí	Sí	No
KineO	Technoconcept	100	4 horas	49x38x19	25	Sí	No	Sí	Sí	Sí	Sí	No
Physilog 3	EPFL	200	71 mA	50x40x16	36	Sí	Sí	No	Sí	Sí	No	No
3DM-GX1	MicroStrain	350	65 mA	64x90x25	74.6	Sí	No	No	Sí	Sí	Sí	No
UAV V3	SparkFun	40	420 mW	38x70x25	34	Sí	No	No	Sí	Sí	No	Sí
IDEEA	MiniSun	32	48 horas	70x54x17	59	No	No	No	Sí	No	No	No
Vitaport activity monitor	Temec	32	12 horas	90x45x15	1360	No	Sí	No	Sí	No	No	No
DynaPort	mroberts	100	72 horas	64x62x13	78	No	Sí	No	Sí	No	No	No
activPAL	paltechnologies	10	7 días	53x35x7	15	No	No	No	Sí	No	No	No
RT3	Stay healthy	1	21 días	97x109x51	65	No	Sí	No	Sí	No	No	No

Tabla 2.1. Comparativa de los principales sensores inerciales del mercado

### 2.3.2 Unidades de medida inercial para la elaboración de bases de datos

A continuación se describen algunos de los sistemas inerciales comerciales que corresponden al grupo considerado para elaborar bases de datos.

- **MTw y MTi-G de Xsens (Enschede, Países Bajos):**

La empresa Xsens ha desarrollado uno de los sensores más dedicados a aplicaciones de investigación [40,92–95]. Entre los sensores desarrollados por Xsens, se encuentra el MTw, el cual es un IMU inalámbrico de 10 ejes, que incluye un sensor de presión, además de 3 sensores triaxiales: acelerómetro, giroscopio y magnetómetro. Su tamaño es de 34.5x57.8x14.5 mm<sup>3</sup> y su peso, con batería, de 27 g. Dado que su tamaño es reducido y hace uso de una comunicación inalámbrica,

su capacidad es de tan sólo 3.5 horas muestreando a 120 Hz. Su autonomía hace pensar que el uso de este IMU es para tomas de datos en periodos de muy corta duración. Este dispositivo no dispone de una unidad de almacenaje, por lo que los datos sólo se pueden tratar con un terminal externo que recibe los datos inalámbricamente. Entre los muchos sensores desarrollados por Xsens, un IMU interesante para seguimiento al aire libre es el MTi-G, cuya principal característica es la inclusión de un módulo GPS. Sin embargo el MTi-G tiene un consumo de 610-690 mW y picos de 910 mW. Aunque no se informa de la autonomía, se estima algo mayor que el MTw, puesto que no dispone de módulo de radio frecuencia para transmitir los datos continuamente. Tampoco tiene capacidad de almacenamiento de datos, por lo que es necesario conectar un cable para poder capturar los datos a través de la comunicación RS-232 [96–98].

- ***Shimmer, (Shimmer sensing, Dublin, Irlanda):***

Otro sensor inercial destacado en el mercado es el Shimmer, cuyo acrónimo proviene de ‘Sensing Health with Intelligence, Modularity, Mobility and Experimental Reusability’. Este IMU tiene 9 ejes de medida, provenientes de un acelerómetro, giroscopio y magnetómetros triaxiales. Este IMU está formado por dos módulos: la plataforma de la unidad central del IMU, y la plataforma donde está el sensor de 9 ejes y el módulo para establecer comunicaciones inalámbricas con otro terminal [99]. En este módulo, se incluye un conector para poder usar la tarjeta  $\mu$ SD para realizar bases de datos además de un módulo Bluetooth. Su frecuencia de muestreo es programable para cada sensor independientemente entre 5-50 Hz aunque, si sólo se usa el acelerómetro, su frecuencia de muestreo alcanza los 100 Hz. La autonomía no se indica, aunque la hoja de datos aclara que se incluye una batería de 450 mAh de capacidad [99,100].

- ***KineO, Technoconcept (Mane, Francia):***

El KineO también proporciona 9 ejes de medida como el Shimmer, sin embargo su autonomía es de 4 horas muestreando a 100 Hz y enviando continuamente los datos a través de Bluetooth a otro terminal [101].

- *Physilog, de EPFL (Lausanne, Suiza):*

Uno de los sensores con más prestaciones y utilizado para capturas de larga duración es el Physilog en su tercera versión. Es un IMU de 6 ejes (3 de acelerómetro y 3 de giroscopio) capaz de capturar datos a 200 Hz. Tiene un consumo medio de 71.9 mA, lo que significa que con una supuesta batería de 1130mAh de capacidad, el IMU lograría una autonomía de 15.9 horas [102,103].

- *Vitaport Activity Monitor (Temec, Kerkrade, Países Bajos):*

El Vitaport Activity Monitor tiene una frecuencia de muestreo de 32 Hz y su tamaño es de 90x45x15 mm<sup>3</sup> [42,104,105]. Tiene un peso de 1.36 Kg con todo el equipo, que consta del sensor inercial, además del grabador de datos externo que junto a la batería hace que sea un sistema bastante incómodo para ser portable y para ser instalado en personas con problemas de movilidad. Además la autonomía que ofrece no es significativa siendo de 12 horas, y superada por ejemplo por el Physilog.

- *IMUs en placas de desarrollo:*

Más ejemplos de IMUs son el 3DM-GX1 (MicroStrain, Williston, Vermont, EEUU) y el UAV V3 (SparkFun, Boulder, Colorado, EEUU), que son placas de desarrollo que necesitan una conexión no inalámbrica a un terminal con el fin de poder capturar y elaborar una base de datos [106,107]. Además, estos sensores están pensados para laboratorio y, por tanto, para ser alimentados a través de una fuente de potencia, lo que limita la usabilidad del sistema. Se puede insertar una batería, no obstante, el sistema se debería mecanizar de alguna forma para que se pudiera usar de forma portable.

Todos estos sistemas inerciales, tienen en común que son capaces de capturar datos inerciales, y su principal función es la de poder elaborar bases de datos para poder estudiar a posteriori el comportamiento de estas señales y poder elaborar clasificadores 'offline'. No obstante, en el caso de las placas de desarrollo es difícil poder implementar

código eficientemente para poder desarrollar clasificadores 'online'. En el resto de IMUs, los sistemas son cerrados y no se puede siquiera programar los microcontroladores, ya que su uso es exclusivo para desarrollar bases de datos.

### ***2.3.3 Sistemas inerciales con procesamiento en tiempo real***

El segundo grupo está compuesto por aquellos IMUs que proporcionan información ya procesada procedente de los sensores inerciales. En este caso, los datos inerciales originales no son accesibles [65,108–114]. En este grupo, los IMUs están exclusivamente diseñados para analizar una actividad específica, así como la determinación de actividad física (caminar, correr, saltar...) o gasto energético o la cantidad de movimiento que se realiza en un periodo de tiempo.

- ***IDEEA (MiniSun, Fresno, California, EEUU):***

Por ejemplo, IDEEA es una unidad con un microprocesador donde convergen 5 acelerómetros satélites de doble eje conectados mediante cable. La unidad central analiza los datos y envía los resultados a través de RS-232 o USB a un ordenador. La unidad principal mide 70x54x17 mm<sup>3</sup> y pesa 59 g. El sistema completo recoge los datos de los 5 sensores a una frecuencia de 32 Hz [108,109]. El sistema IDEEA no se utiliza como un IMU para elaborar bases de datos ya que su única función es la de poder determinar la actividad física que se realiza.

- ***Dynaport (McRoberts, La Haya, Países Bajos):***

Otro dispositivo que mide la actividad física en forma de gasto energético es el Dynaport, que entre otras características, su frecuencia de muestreo es de 100 Hz y tiene una autonomía de 72 horas [110,111].

- ***activPAL (PAL Technologies, Glasgow, Reino Unido):***

Un IMU ultraligero es el activPAL, que pesa 15 g y guarda información de la actividad física hasta 7 horas con una frecuencia de muestreo de 10 Hz [65,112].

- ***RT3 (StayHealthy, Monrovia, California, EEUU)***

Un sensor de monitorización de largos periodos es el RT3. Este dispositivo es el más grande de los mencionados antes debido a su batería con un tamaño de 97x109x51 mm<sup>3</sup>. Este sensor puede durar 21 días, aunque se reporta que esta información se proporciona cada minuto en estas condiciones y sólo tiene un acelerómetro triaxial. Sus funciones son entregar la información del módulo de los 3 ejes de acelerómetro o bien el valor de ellos cada segundo o cada minuto [113,114].

Estos IMUs no se pueden emplear para implementar clasificadores 'online' ya que son sistemas comerciales cerrados y el microcontrolador incorporado no se puede programar.

## ***2.4 Conclusiones acerca de los IMUs***

Los IMUs son dispositivos capacitados para poder capturar información inercial a través de sensores inerciales, por ejemplo, acelerómetros, giroscopios y magnetómetros. Además, los IMUs son capaces de poder transmitir esta información a través de módulos de comunicación, ya sea cableada (RS-232 o SPI) o inalámbrica (Bluetooth o Zigbee).

Entre otras clasificaciones, se puede clasificar a los IMUs por su capacidad de almacenaje, o bien por su capacidad de computación. Los primeros están focalizados a desarrollar clasificadores 'offline' a través del posterior análisis de los datos capturados. El segundo grupo de IMUs son capaces de poder proporcionar una información que proviene de un cálculo realizado inmediatamente después de capturar los datos inerciales. Con esta información es posible clasificar el comportamiento de la señal inercial en tiempo real (clasificadores 'online').

# Capítulo 3

## Unidad de Medida Inercial para monitorización de larga duración

En este capítulo se detallan las características del hardware y firmware del sistema inercial desarrollado en esta tesis que permite realizar bases de datos e implementar clasificadores online para la monitorización del movimiento. Previamente se presentan los requerimientos necesarios que este dispositivo debe cumplir y que han permitido llevar a cabo investigaciones del movimiento humano en estudios y proyectos tanto europeos como nacionales [15,16,18,115].

### *3.1 Requerimientos para el IMU 9x2*

En este capítulo se presenta el IMU desarrollado que permite tanto realizar bases de datos de señales inerciales, con el fin de analizar y diseñar algoritmos de procesamiento, como ofrecer procesamiento online para implementar clasificadores online. Este IMU, llamado 9x2, ha sido utilizado en diversos estudios clínicos en los cuales se tratan tanto los síntomas de PD como el análisis en tiempo real de caídas. En el primero de ellos se reunieron y analizaron señales inerciales de 35 personas con la PD con el fin de caracterizar la sintomatología asociada [15]. El siguiente estudio se realiza en el marco del proyecto europeo ‘Home-based Empowered Living for Parkinson’s disease’ (HELP)

y se estudian trastornos de la marcha junto caídas y síntomas de la PD con el 9x2 [16]. Finalmente, el 9x2 se ha utilizado para recolectar señales inerciales de 90 pacientes con PD en 4 países diferentes en el proyecto de ámbito europeo REMPARK [18,116]. Finalmente, el 9x2 se está validando como parte del proyecto europeo 'Fall Detector for the Older' (FATE) en el cual el 9x2 forma parte de un sistema detector de caídas en un test piloto con 175 pacientes [117,118].

Los requerimientos del IMU surgen de la necesidad no sólo de trabajar como herramienta para desarrollar bases de datos, sino además, para implementar clasificadores 'online' basados en algoritmos inteligentes. En consecuencia, los principales requisitos para el IMU es que sea multifuncional: a) este dispositivo ha de registrar señales inerciales con una frecuencia de muestreo estable de hasta 200 Hz (para poder estudiar apropiadamente el movimiento humano [119] y b) el firmware que incorpora el sistema debe de permitir implementar algoritmos de aprendizaje supervisado. Este último requerimiento supone solapar la ejecución de los clasificadores en tiempo real con la recogida de datos para poderlos analizar. Además, los procesos de los periféricos, como el Bluetooth o la tarjeta  $\mu$ SD, deben intervenir en momentos determinados. Todo ello dificulta la implementación del firmware para optimizar el rendimiento del mismo.

Para las aplicaciones de monitorización de movimiento humano y de acuerdo con los requerimientos de usabilidad, el IMU debe tener una larga autonomía y por tanto un consumo bajo. Más específicamente, dado que interesa monitorizar el movimiento humano, el sensor debe durar aproximadamente un día como mínimo. En el caso de que la monitorización se prolongue durante varios días, el sujeto al que se le realiza el test puede cargar el IMU mientras duerme. Finalmente, una de las premisas más importantes es que el sensor sea vestible y pequeño, por ejemplo del tamaño de un smartphone.

Con respecto a los requerimientos de las señales inerciales, el sensor debe tener 3 sensores triaxiales para poder formar un IMU de 9 ejes. Debe tener un acelerómetro, un giroscopio y un magnetómetro triaxiales, además, debe incluir un sensor de temperatura para poder calibrar las medidas de los MEMS más susceptibles al cambio de temperatura cada determinado periodo de tiempo. La frecuencia de muestreo aconsejable para poder medir el movimiento humano es de 40 Hz [119]. Sin embargo, es apropiado que el IMU

tenga una frecuencia de muestreo de hasta 200 Hz siendo esta frecuencia ajustable por el usuario y por tanto se abre la posibilidad de mejorar la precisión o de ampliar el abanico de aplicaciones.

Con respecto a las capacidades de implementar clasificadores ‘online’, el IMU debe disponer de un controlador de señal digital (Digital Signal Controller, DSC) para reducir la carga de cómputo del microcontrolador y de esta forma incrementar la autonomía. Este módulo debe garantizar una reducción del tiempo empleado en los cálculos de los algoritmos supervisados y, por tanto, permitir al microcontrolador estar más tiempo en modos de operación de bajo consumo. La detección realizada por clasificadores ‘online’ de determinada sintomatología en el caso de la PD, puede enviarse a otros dispositivos, por ejemplo a un teléfono móvil, con fines informativos o de activación de otros sistemas actuadores. (i.e. ajustar las dosis de apomorfina administradas por una bomba de inyección). Para el proceso de comunicación con el móvil es necesario por tanto, precisar de algún módulo inalámbrico en el IMU. Finalmente, y con respecto a la confección de algoritmos ‘offline’ se debe de disponer de una unidad de almacenaje suficientemente grande para poder almacenar los datos inerciales capturados en periodos largos.

En resumen, para poder realizar todos estos procesos se precisa de un firmware que los gestione de manera eficiente. Además el firmware ha de ser flexible para poder ajustar diferentes parámetros como la frecuencia de muestreo o el tipo de modo de operación, ya sea para almacenar datos o ejecutar clasificadores ‘online’.

### ***3.2 Hardware del 9x2***

De acuerdo con los requerimientos presentados en el apartado 3.1, es necesario que los sensores seleccionados tengan un ancho de banda mínimo de 400 Hz (el doble que la frecuencia de muestreo máxima). Los sensores incluidos deben de tener la posibilidad de poder ser deshabilitados mediante el firmware del sistema para evitar consumos no deseados. Además, los módulos de transmisión de datos o almacenaje de datos deben de poder deshabilitarse en función del modo de operación del sistema, ya sea para un comportamiento ‘online’ u ‘offline’. Para ello, se han incluido diferentes reguladores lineales de tensión que tienen la función de suministrar potencia a diferentes partes del

circuito pero con una entrada que es modificada por el microcontrolador central para poder deshabilitarlos y por lo tanto, dejar de suministrar potencia a esa parte del circuito no necesaria en ese momento.

En esta sección, se resume el hardware del sistema de acuerdo con las decisiones tomadas que se han detallado. El sistema se compara con el resto de IMUs en el mercado mostradas en la Tabla 2.1. A continuación, se describe la arquitectura de hardware del 9x2, así como los sensores inerciales incluidos, su calibración, se detallan las características del microcontrolador del sistema, el sistema de alimentación del 9x2 y finalmente se explican los módulos de comunicación. En la siguiente sección se explica detalladamente el firmware.

El diseño del sistema final del IMU tiene un tamaño de  $77 \times 37 \times 21 \text{ mm}^3$ , y pesa 78 g, una reducción de peso de más del 30% respecto los principales smartphones que hay en el mercado actualmente, por ejemplo el HTC Desire X (137 g), Google Nexus 4 (139 g), Iphone5 (112 g). Tal y como se muestra en la Figura 3.1 el 9x2 es una plataforma vestible con la que el usuario puede efectuar sus actividades diarias con total normalidad. Es, por tanto, un sistema no invasivo.

La autonomía del sistema, que esta detallada en el punto 3.2.5 es de 36.81 horas, y tiene un consumo de 113 mW (30.7 mA con una batería de 3.7 V y 1130 mAh de capacidad). Estas condiciones de autonomía se dan cuando el sistema está escribiendo a 200 Hz en la tarjeta  $\mu$ SD. El módulo de Bluetooth está deshabilitado en este modo de operación. La Figura 3.1 muestra el diseño de un cinturón de neopreno, específico para que al usuario le resulte cómodo llevar el sensor inercial. Se muestra la localización del sensor y su orientación, la cual es un aspecto importante para la captura de datos.



Figura 3.1. El sensor 9x2 y su diseño específico con el cinturón de neopreno

La Figura 3.2 muestra la estructura principal del 9x2. Como se muestra, el 9x2 está controlado por un microcontrolador dsPIC33F, el cual tiene la principal función de administrar los procesos de los diferentes sub-sistemas que componen el 9x2 y de ejecutar los algoritmos programados. El microcontrolador también controla el sistema de control de potencia y la interfície de usuario. El 9x2 incorpora también un interruptor general con el fin de poder encender y apagar el IMU.

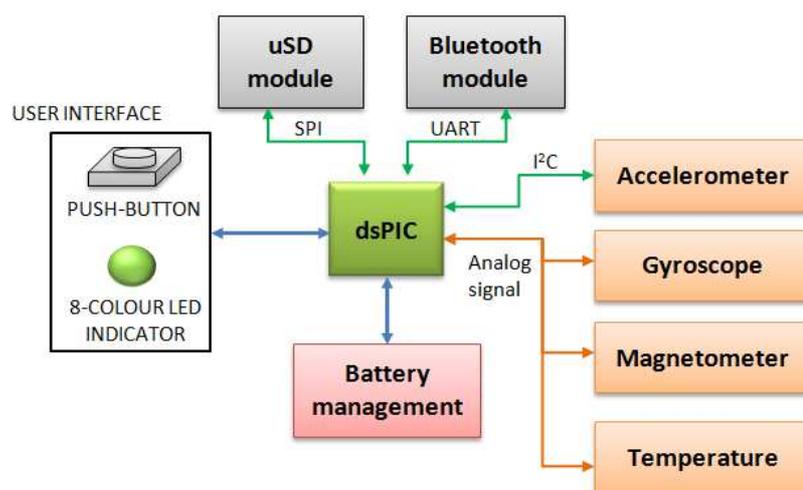


Figura 3.2. Diagrama de bloques general del 9x2

Las características del 9x2 se presentan en la Tabla 3.1 de un modo comparable a la Tabla 2.1. El 9x2 es el único sensor que reúne todas las características a excepción del GPS, el cual se considera un módulo con exceso de consumo y, por lo tanto, prescindible para las necesidades requeridas.

Nombre del sensor	Fabricante	Freq. muestreo(Hz)	Info Autonomía	Tamaño (mm <sup>3</sup> )	Peso(g)	Capacidad Datalog	Unidad Almacenaje	Wireless	Acc	Giro	Magn	GPS
9x2	CETpD	200	36.8 horas	77x37x21	78	Sí	Sí	Sí	Sí	Sí	Sí	No

Tabla 3.1. Características del 9x2

### 3.2.2 Sensores inerciales del 9x2

Los sensores inerciales son los componentes principales del 9x2 puesto que permiten suministrar información inercial para poder realizar los análisis. El 9x2 incorpora 3 sensores triaxiales: un acelerómetro, un giroscopio y un magnetómetro.

- Acelerómetro

El acelerómetro se considera el sensor más interesante en el sistema y por tanto, sus medidas deben de ser precisas y estables. El LIS3LV02DQ (STMicroelectronics, Ginebra, Suiza), de ahora en adelante LIS3, es el acelerómetro escogido para el 9x2. Ofrece una interfície digital con la información inercial tratada y acondicionada, además tanto el acondicionamiento de la señal como los 3 transductores están en el mismo encapsulado. De esta forma, es más robusto a interferencias electromagnéticas, ya que no hay pistas eléctricas a través de la PCB desde el transductor al acondicionador de señal. El LIS3 incorpora también un sensor de temperatura para poder calibrarlo cuando fuera necesario [78]. El LIS3 tiene un ancho de banda de 640 Hz, el cual es suficiente para poder operar a una frecuencia de muestreo de 200 Hz. El sensor ofrece la posibilidad de escoger dos fondos de escala programables,  $\pm 2$  G o  $\pm 6$  G. En los estudios realizados en la presente tesis, el sensor se ubica en la cintura, puesto que se considera el lugar más idóneo para poder realizar un análisis global del movimiento humano, tanto por sus características, como por su usabilidad [71,74,120]. En esta localización además, el rango de aceleraciones medidas alcanza como máximo  $\pm 6$  G [121]. Por esta razón, éste es el fondo de escala (FS) seleccionado para el LIS3. La sensibilidad del LIS3 en el rango  $\pm 6$  G es de 2.9 mG/bit donde mG es mili gravedad. Los datos son digitalizados y enviados al microcontrolador a través del bus I<sup>2</sup>C a 1 Mbps.

- Giroscopio

El giroscopio utilizado en el 9x2 tiene un rango de  $\pm 2,000$  °/s y una sensibilidad de  $0.5 \frac{mV \cdot ^\circ}{V}$ . Se han utilizado dos giroscopios diferentes para medir la rotación angular, un

biaxial y un uniaxial. Los dispositivos elegidos son el IDG650 (Invensense, San Jose, California, EEUU), un giroscopio biaxial que proporciona datos para el eje X y el eje Y [79], y el ISZ650 (Invensense), que proporciona los datos inerciales del eje Z [80]. Sus salidas son analógicas, lo que comporta una importante disminución del consumo respecto al tratamiento digital de la señal. También incorpora un sensor de temperatura para poder calibrarlo ya que este tipo de sensor es propenso a sufrir derivas en cambios de temperatura. Sin embargo la hoja de datos especifica que el encapsulado esta sellado para reducir efectos provocados por agentes externos, como la humedad y la temperatura.

- Magnetómetro

El 9x2 incluye un sistema triaxial de magnetómetros basado en 2 dispositivos, uno biaxial (HMC6042, Morristown, Nueva Jersey, EEUU) [85], y el otro uniaxial (HMC1041Z, Honeywell)[86]. Éste último, ofrece una señal diferencial que el sensor biaxial trata para poder ser trabajada al mismo nivel de tensión que sus dos salidas tal y como muestra la Figura 3.3. El magnetómetro tiene un FS de  $\pm 6$  Gauss, y una sensibilidad de  $1 \frac{mV \cdot Gauss}{V}$ .

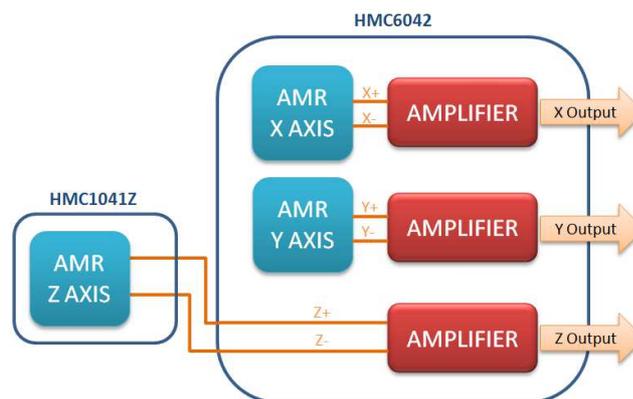


Figura 3.3. Sistema de magnetómetros del 9x2

### 3.2.3 Calibración de los sensores

Los sensores inerciales ofrecen medidas que suelen estar afectadas por offsets (nivel de tensión añadida a la salida) y derivas que están descritas detalladamente en cada una de las hojas de datos de cada dispositivo. La calibración realizada en el 9x2 se basa en la información de las hojas de datos, las notas de aplicaciones y métodos de mínimos cuadrados descritos seguidamente.

El fabricante del LIS3 ofrece información sobre curvas de calibración internas, las cuales compensan las derivas que aparecen debido a cambios en la temperatura. De cualquier forma, de acuerdo con las características del sensor, puede aparecer una medida de offset de 100 mG en cualquier eje de medida. También hay una no-linealidad de un 3% respecto al FS, y un cambio de la sensibilidad del sensor de 0.025 %/°C [78].

Los giroscopios seleccionados tienen una no-linealidad menor al 1% del FS. Tienen una deriva del 10% del FS cerca de los límites del modo de operación de las temperaturas especificadas por el fabricante y frecuencias intrínsecas mecánicas [79][80].

Los magnetómetros HMC6042 y HMC1041Z tienen una sensibilidad de cross-axis de  $\pm 0.2$  FS/ Gauss, una sensibilidad a la temperatura de -3100 ppm/°C y un offset de  $\pm 10$  ppm/°C. Los magnetómetros tienen un error de linealidad del 0.8% del FS, un error de histéresis del 0.15% y un error de repetibilidad del 0.11% del FS [85][86].

Para calibrar los sensores, se ha empleado un método de calibración estático, como el que emplea Giansanti et al. para calibrar acelerómetro y giroscopios [122]. El método de calibración consiste en comparar las medidas incorrectas del sensor con las medidas reales proporcionadas por un gold-estándar conocido y validado. Seguidamente, se aplica el método de mínimos cuadrados (LS) para obtener la matriz de calibración  $C_k$ . Una vez  $C_k$  se ha obtenido, los valores calibrados  $(x'_k, y'_k, z'_k)$  en cualquier posición se obtienen mediante  $(x'_k, y'_k, z'_k) = (x_k, y_k, z_k) \cdot C_k$ , donde  $x_k, y_k, z_k$  son las medidas obtenidas.

La matriz de calibración  $C_k$  está definida como:

$$C_k = (L_k)(S_k)^T [(S_k)(S_k)^T ]^{-1} \quad (3.1)$$

donde  $k$  indica el tipo de sensor inercial: :  $C_a, L_a, S_a$  para acelerómetro,  $C_g, L_g, S_g$  para giroscopio y  $C_m, L_m, S_m$  para magnetómetro.  $L_k$  es una matriz que contiene los valores

extraídos de un sistema de referencia conocido.  $S_k$  es la matriz donde se encuentran las medidas de los valores extraídos del 9x2 que se deben corregir.

La calibración del acelerómetro está basada en orientar en 6 posiciones tal y como muestra la Figura 3.4, de las cuales el valor que ofrece cada eje del acelerómetro es conocido. Estas posiciones corresponden con el alineamiento de los 3 ejes del acelerómetro con la gravedad en diferente sentido. Durante los alineamientos, se toman datos durante 6 segundos, se filtran a través de un filtro Butterworth de segundo orden a 5Hz.

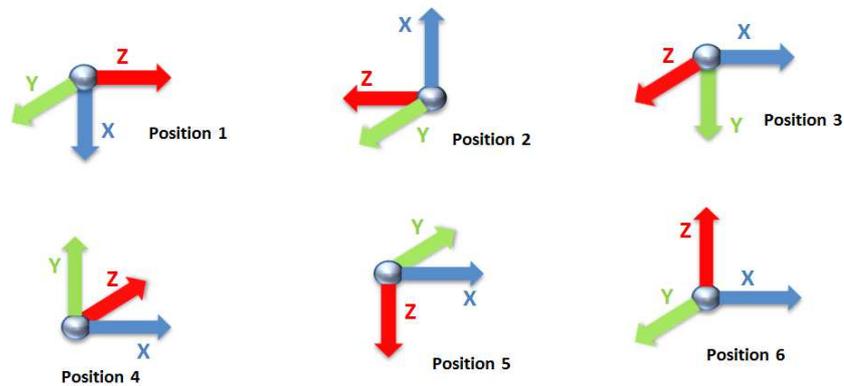


Figura 3.4. Posiciones de calibración del acelerómetro

Con estas 6 posiciones, se obtienen 18 medidas distintas que corresponden a los 3 ejes del acelerómetro. De acuerdo a estas medidas,  $S_a$  se completa como muestra la Ecuación 3.2.  $L_a$  contiene las medidas conocidas de gravedad tal y como muestra la Ecuación 3.3. Seguidamente se emplea el método de mínimos cuadrados para obtener  $C_a$  de acuerdo con la Ecuación 3.1.

$$S_a = \begin{pmatrix} x_1 & x_2 & x_3 & x_4 & x_5 & x_6 \\ y_1 & y_2 & y_3 & y_4 & y_5 & y_6 \\ z_1 & z_2 & z_3 & z_4 & z_5 & z_6 \end{pmatrix} \quad (3.2)$$

$$L_a = \begin{pmatrix} -G & G & 0 & 0 & 0 & 0 \\ 0 & 0 & -G & G & 0 & 0 \\ 0 & 0 & 0 & 0 & -G & G \end{pmatrix} \quad (3.3)$$

donde  $x_i, y_i, z_i$  son medidas obtenidas en la posición  $i$  de acuerdo con la Figura 3.4 y

$G=9.81 \text{ m/s}^2$ .

En el caso de los giroscopios, se ha utilizado un Mti de Xsens [98] con un certificado de calibración con el fin de obtener las medidas de referencia de velocidad angular de la matriz  $L_g$ . El Xsens y el 9x2 en un plato giratorio, el cual está alimentado por un motor de continua (DC) con una fuente de tensión de alta precisión conocida como QL355TP de Thurlby Thandar Instruments (Huntingdon, Reino Unido) [123]. Las matrices  $L_g$  y  $S_g$  se completan con las velocidades angulares obtenidas en las 6 posiciones de la Figura 3.4.

Finalmente, el sistema del magnetómetro se ha calibrado mediante la comparación de los valores del sensor dados completando la matriz  $S_m$  con los valores del campo magnético de la Tierra. Los valores a los que se compara  $S_m$  son los valores del Norte y Sur magnético que representan los valores máximos y mínimos. Estos valores son conocidos en cualquier lugar del planeta a través de la NOAA, la cual ofrece un servicio donde informa de la amplitud del campo magnético terrestre durante los próximos 5 años. Esta herramienta se utiliza como gold-estándar para la calibración del sistema y se compara con los valores reales del sensor capturados durante 6 segundos. Las medidas se deben obtener en un lugar aislado de materiales ferromagnéticos con el fin de obtener una lectura nítida del campo magnético de la Tierra. La matriz  $S_m$  se obtiene girando el sensor  $360^\circ$  respecto del plano terrestre, obteniendo así en esta medida un máximo y un mínimo correspondientes al norte y sud magnéticos. Estos son los valores que se comparan con la matriz  $L_m$ .

### **3.2.4 Microcontrolador**

El sistema está controlado por el dsPIC33FJ128MC804 (Microchip, Chandler, Arizona, EEUU) (Figura 3.5), un microcontrolador (MCU) cuya principal característica es la inclusión de un DSC interno. Este microcontrolador tiene una arquitectura Harvard modificada con 16 bits de datos y 24 bits para instrucciones. Tiene 128 KB de memoria Flash para memoria de programa y 16 KB de RAM. Los protocolos de comunicación que emplea este MCU son UART, I<sup>2</sup>C y SPI, que controlan el Bluetooth, acelerómetro y tarjeta  $\mu$ SD respectivamente. También tiene un controlador de conversión de datos digital-analógico (ADC) con 9 canales de entrada de 10 bits, lo cual es suficiente para digitalizar

las 7 señales que provienen de los sensores analógicos (3xGiroscopio, 3xMagnetómetro y 1xTemperatura).



Figura 3.5. *Microcontrolador dsPIC33FJ128MC804, fuente: Microchip Inc.*

El reloj contador de tiempo real (RTCC), es un periférico del MCU que permite contextualizar el tiempo en el que ocurren los eventos del MCU dentro de un sistema temporal amigable: año, mes, día de la semana, hora, minuto y segundo. El RTCC se puede calibrar con el fin de minimizar el error temporal acumulado. Según Microchip Inc., el MCU seleccionado, permite tener un error de menos de  $\pm 2.64$  segundos en un mes. Sin embargo y debido a los procesos intrínsecos de fabricación, la frecuencia de cristal de cuarzo puede ser diferente en cada dispositivo y por tanto, debe de ser calibrado ya que las derivas temporales entre un dispositivo y otro pueden ser largas en capturas de varias horas. Se ha utilizado un frecuencímetro universal llamado 53132 (Agilent, Santa Clara, California, EEUU) [124] donde se calibra el RTCC a su mínimo error. La temperatura de la calibración es de 25 °C para tener una referencia. La Figura 3.6 muestra la curva de las derivas de la frecuencia en función de la temperatura proporcionada por el fabricante del cristal ABS06 (Abracon, Rancho Santa Margarita, California, EEUU).

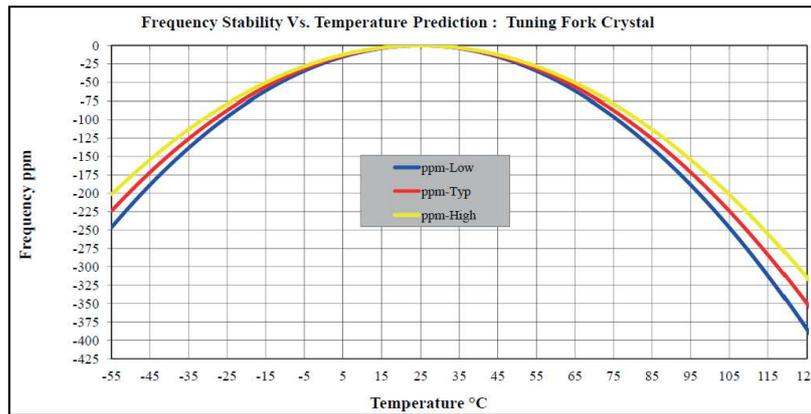


Figura 3.6. Curva de calibración, estabilidad de la frecuencia vs temperatura, fuente: Abracon, Inc.

Por otra parte, la frecuencia de la CPU del MCU también se debe calibrar. La frecuencia del MCU es de 80 Mhz, o bien en términos de ciclos de trabajo, de 40 MIPS. Esta frecuencia también se puede modificar mediante registros internos del MCU para lograr mayor precisión. Además, y considerando las derivas que se producen debido a los cambios de temperatura, se aplica una corrección a la frecuencia de acuerdo con la curva suministrada por la hoja de datos del dsPIC33F mostrada en la Figura 3.7 y con la temperatura proporcionado por el sensor de temperatura incluido en el 9x2.

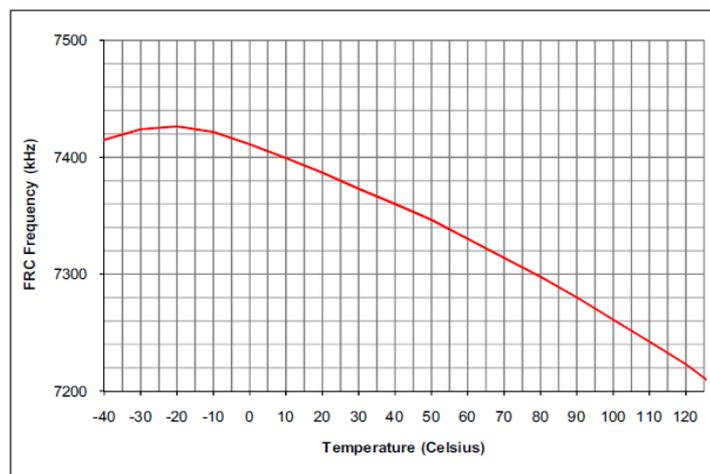


Figura 3.7. Curva de calibración para la frecuencia interna del MCU, fuente: Microchip Inc. 2012.

El 9x2 corrige las medidas del valor del RTCC y del valor del registro de ajuste de la frecuencia de acuerdo con la temperatura obtenida cada minuto. Consecuentemente, se

ha implementado la curva proporcionada por los fabricantes y se aplican los factores de corrección para la temperatura actual. El rango de curva implementado para ambos casos es de 0 a 60 °C.

El dsPIC tiene además un sistema de acceso a la memoria directo (DMA). Este periférico permite transferir datos desde los buffers de los periféricos hacia los buffers de la memoria RAM con una acción mínima del MCU. El DMA y los diferentes modos de operación de ahorro de energía del MCU permiten al 9x2 ser un sistema de muy bajo consumo. El dsPIC33F permite 3 modos de operación de ahorro de energía: modo operativo (Run), modo inactivo (Idle), modo dormido (Sleep). El modo Run es el modo de funcionamiento normal en el que la CPU y los periféricos trabajan en condiciones normales. El modo Idle ofrece la posibilidad de dormir a la CPU pero los periféricos que el usuario permite que funcionen permanecen activos. No se ejecuta ninguna instrucción interna, sin embargo, los periféricos pueden despertar al MCU a través de una interrupción debido a acontecimiento de un evento. El consumo del MCU puede reducirse de 63 a 34 mA [125]. Durante el modo Sleep, sólo una interrupción externa o bien entradas externas de reloj pueden despertar al MCU. No se alimenta ningún periférico y la CPU permanece inactiva. En este modo el consumo se reduce drásticamente hasta los 10  $\mu$ A.

### 3.2.5 Gestión de potencia

El 9x2 incluye un sistema de gestión de potencia que le permite al sistema ahorrar energía. Como muestra la Figura 3.8, hay 3 reguladores lineales de tensión de bajo *drop-out* (reguladores LDO) que permiten no alimentar diversas partes del 9x2 con el fin de ahorrar energía. El primer regulador LDO alimenta al MCU, que gobierna los otros dos reguladores. Los otros dos reguladores alimentan el circuito analógico y el circuito del módulo de Bluetooth.

El sistema está alimentado por una batería de litio-ion de 1130 mAh. La autonomía del sistema es de 36.8 horas aproximadamente cuando las condiciones son las siguientes: el sistema trabaja a una frecuencia de muestreo de 200 Hz mientras se almacenan los datos continuamente en la tarjeta  $\mu$ SD de todos los sensores inerciales, del sensor de

temperatura y del estado de la batería. El sistema permite enviar todos estos datos a través del Bluetooth a una frecuencia de entre 1 y 200 Hz también. Cuando el sistema envía los datos a 200 Hz vía Bluetooth, la autonomía decrece de 36.8 a 18 horas, ya que el consumo del Bluetooth es bastante más alto que el consumo exigido por la tarjeta  $\mu$ SD en el proceso de almacenaje de datos. Esta autonomía, sin embargo, es suficiente para cubrir las capturas de datos de todos los proyectos que se han llevado o se están llevando a cabo con el 9x2. De acuerdo con los requerimientos de los proyectos de investigación, el uso del IMU es similar al de un smartphone. Por tanto, el dispositivo puede cargarse un máximo de una vez por día y normalmente por la noche. De esta forma, 18 horas, o 36 horas son suficientes para cubrir ambos aspectos (captura de datos-evaluación en tiempo real).

El sistema incorpora un cargador de batería y un monitor de batería. El monitor de batería indica al usuario el estado actual de la batería a través de un LED-RGB. Cuando la batería está a un nivel muy bajo, se produce una interrupción en el sistema del 9x2. A continuación el sistema se va a dormir cerrando previamente todas las comunicaciones y periféricos para evitar pérdidas de información (ejemplo, cerrar archivos). Finalmente el MCU entra en modo Sleep.

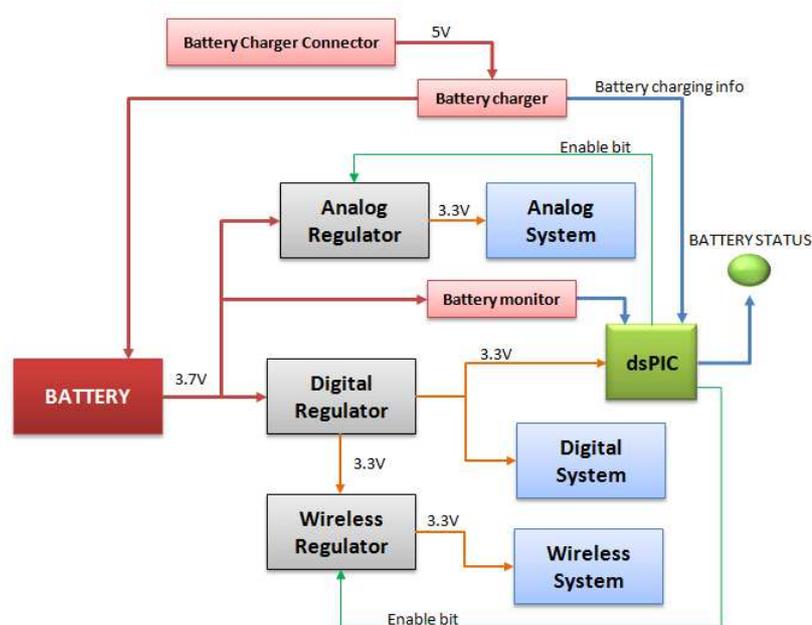


Figura 3.8. Diagrama de bloques de la gestión de potencia del 9x2

Con el fin de reducir consumo, el firmware puede habilitar y deshabilitar el regulador inalámbrico y/o el regulador analógico cuando fuese necesario. El sistema permanece en modo Run sólo cuando sea necesario capturar datos, cuando los datos se deban enviar, o cuando el clasificador 'online' se esté ejecutando.

Se ha realizado un análisis preciso del 9x2 en diferentes modos de operación. El 9x2 puede funcionar en diferentes modos de trabajo. Por una parte puede trabajar con el Bluetooth encendido, o bien para enviar continuamente los datos, ya sean inerciales o los resultados de un algoritmo, o bien para recibir órdenes de un terminal externo. En este último caso podría estar realizando una captura de datos inerciales con la tarjeta  $\mu$ SD. Por otra parte el sistema puede trabajar sin necesidad de alimentar el Bluetooth, o bien sólo para cuando fuese necesario. En estos casos se utiliza cuando se está adquiriendo datos o bien cuando un clasificador 'online' se está ejecutando y se enciende el Bluetooth sólo para enviar un resultado cada cierto periodo de tiempo. Estos casos se reportan en la Tabla 3.2, donde las autonomías mostradas se han medido después de que el sistema estuviese operativo durante 2 minutos. Se ha medido el consumo medio durante 10 segundos y se ha calculado la autonomía teniendo en cuenta la capacidad de la batería usada en el 9x2 (1130 mAh). Este proceso se ha repetido 5 veces separando cada toma de datos un minuto aproximadamente. Cada modo de operación se ha repetido a diferentes frecuencias de muestreo para comparar los consumos en diferentes estados del IMU. Los resultados que se muestran en la Tabla 3.2 son la media y la desviación de las 5 muestras tomadas. Estos resultados muestran que el comportamiento clasificador 'online' tiene una autonomía de 41 horas a 40 Hz, la autonomía más alta después del modo de operación con captura de datos sin uso de Bluetooth, que es de 45 horas a 40Hz. Cuando el Bluetooth se usa, la autonomía decrece hasta la mitad de esa duración.

<i>Clasificador 'online' sin conexión Bluetooth</i>					
<i>Sampling Freq.(Hz)</i>	40	50	100	150	200
<i>Autonomy (h)</i>	41.09 ±0.2	40.07 ±0.2	35.99 ±0.4	31.22 ±0.15	27.63 ±0.1

<i>Captura de datos con <math>\mu</math>SD y sin conexión Bluetooth</i>					
<i>Freq. muestreo(Hz)</i>	40	50	100	150	200
<i>Autonomía (h)</i>	45.56 ±0.2	44.84 ±0.25	42.97 ±0.1	40.21 ±0.1	36.81 ±0.2

<i>Envío de datos continuo a través de Bluetooth</i>					
<i>Freq. muestreo(Hz)</i>	40	50	100	150	200
<i>Autonomía (h)</i>	19.12 ±0.35	18.96 ±0.2	18.80 ±0.1	18.28 ±0.0	17.94 ±0.2

<i>Captura de datos para clasificador 'offline' con conexión Bluetooth</i>					
<i>Freq. muestreo (Hz)</i>	40	50	100	150	200
<i>Autonomía (h)</i>	20.18 ±0.45	19.82 ±0.3	19.15 ±0.4	18.83 ±0.3	18.23 ±0.25

Tabla 3.2. Autonomías para diferentes modos de operación del MCU

### 3.2.6 Módulos de comunicación

De acuerdo con los requerimientos detallados en la sección 3.1, el 9x2 se debe comunicar inalámbricamente con, al menos, un teléfono móvil para proporcionarle los resultados de los algoritmos. Los teléfonos móviles actuales tan sólo ofrecen la tecnología Bluetooth como método de comunicación de bajo consumo con un ancho de banda y una transferencia de datos elevado. El Bluetooth tiene una velocidad de transferencia de 115200 bps en el 9x2 y un consumo de 31.5 mA de acuerdo con sus especificaciones [126].

Por otra parte, dado que el 9x2 se debe comportar también como un sistema de almacenaje de datos, es requerido que incorpore una unidad de almacenaje, para ello el 9x2 incorpora un conector para tarjeta  $\mu$ SD. El hecho de utilizar tarjeta  $\mu$ SD implica principalmente no utilizar el módulo de Bluetooth para recoger datos por lo que comporta ventajas notables en el consumo del dispositivo como se muestra en la Tabla 3.2.

Con el módulo de la tarjeta  $\mu$ SD se pueden construir bases de datos. Estos datos se utilizan para elaborar algoritmos que puedan ayudar a clasificar, en el caso de la enfermedad del Parkinson, diferentes síntomas, y de esta forma poder diagnosticar, o poder evaluar la calidad de vida de un paciente. En el proyecto REMPARK, los pacientes que participan en el proyecto realizan sus actividades diarias con el sensor localizado en la cintura de forma que se van recogiendo en la tarjeta  $\mu$ SD las señales inerciales correspondientes a los movimientos que el paciente esté realizando a lo largo del día. Estos datos son procesados y a posteriori se diseñan los algoritmos.

### ***3.3 Firmware del sistema***

El firmware es la parte más relevante del sistema ya que sus principales funciones son 1) gobernar los periféricos que intervienen en el sistema 9x2 para garantizar una frecuencia de muestreo precisa y estable, 2) supervisar el correcto funcionamiento de las comunicaciones, 3) controlar los procesos para almacenar datos inerciales capturados antes de enviarlos a un periférico mientras controla los estados de batería e interficie de usuario y 4) ejecutar clasificadores 'online'. Uno de los principales requerimientos del firmware es optimizar el consumo. Para este fin, un firmware específico se ha desarrollado evitando sistemas operativos en tiempo real para optimizar consumo y memoria. De esta forma, el firmware permite al MCU alternar de forma eficiente en diferentes modos de operación (Run, Idle, Sleep).

En esta sección, se presenta el proceso del programa principal y la máquina de estados asociada que gobierna el firmware, también se presentan los otros procesos internos que intervienen en el 9x2 asociados a los diferentes periféricos descritos en la sección previa (Sección 3.2).

#### ***3.3.1 Proceso principal***

Un aspecto importante del 9x2 es obtener un firmware en el cual el MCU sólo trabaje en modo Run cuando sea necesario y, por tanto, se mantenga en modo de bajo consumo

el máximo tiempo posible. Para ello, se deben asignar prioridades a los diferentes procesos que intervienen en el programa, la captura de datos, las comunicaciones, la gestión de batería, y los clasificadores 'online'.

La Figura 3.9 describe un diagrama en el cual se representan qué procesos independientes interactúan con el proceso principal y cuales interactúan con las interrupciones. El proceso principal inicializa los 6 otros procesos. Algunos procesos sólo se ejecutan después de una petición de interrupción. Por ejemplo, el proceso de capturar datos es ejecutado inmediatamente después de una petición de interrupción del temporizador asociado a la adquisición de datos. Los procesos de Bluetooth y la tarjeta  $\mu$ SD también se ejecutan después de una petición de interrupción del sistema. En el caso de la tarjeta  $\mu$ SD, cuando el buffer esté lleno, se lanza una interrupción de la DMA para empezar el proceso de almacenaje. En el caso del Bluetooth, una petición de interrupción en la recepción de mensajes a causa de un comando lanzado por el usuario hará ejecutar el proceso correspondiente del Bluetooth. Además, las interrupciones de los temporizadores también lanzan los procesos del Bluetooth para enviar datos, así como la salida del algoritmo calculado, o bien directamente los datos inerciales. El proceso de gestión de batería y los clasificadores se ejecutan dentro del proceso principal después de que los datos se hayan capturado y antes de que el MCU entre en modo Idle.

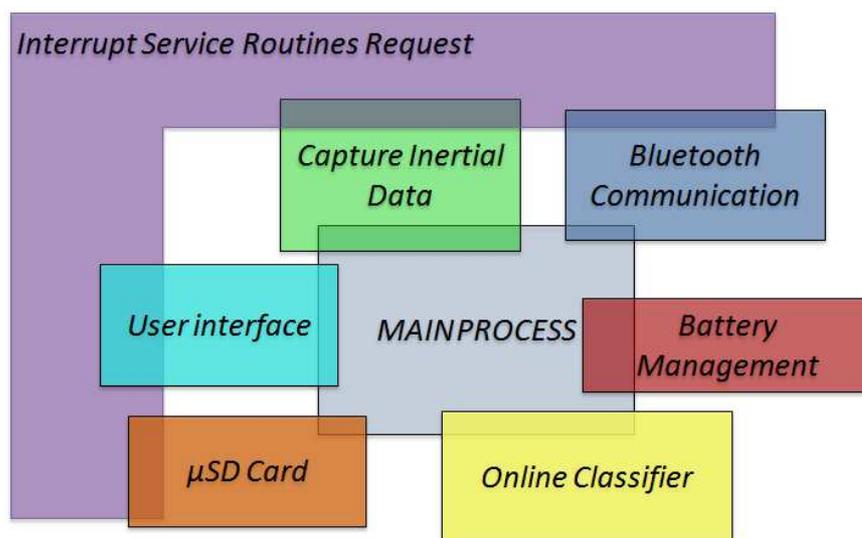


Figura 3.9. Interacción de los procesos del firmware

El proceso principal comprende de una fase de inicialización, en la cual los

periféricos se configuran y se asocian a los canales de la DMA correspondientes. Se habilitan las interrupciones y se le otorga una prioridad a cada uno de las interrupciones. La interrupción de captura inercial de datos es la interrupción de más prioridad, seguida de las comunicaciones, y finalmente la interrupción externa de la interfície de usuario. Los procesos de clasificadores ‘online’ y gestión de batería no tienen prioridad al no ser ejecutados a partir de interrupciones.

Después del proceso de captura de datos, los datos capturados en ADC son guardados en la memoria RAM. Estos datos son analizados, procesados y enviados dentro de una trama a un canal de la DMA. El firmware permite enviar todos los datos inerciales a través de Bluetooth y tarjeta  $\mu$ SD. Sin embargo, si un algoritmo es ejecutado, los datos enviados a través de los módulos de comunicación pueden ser los mismos resultados del algoritmo en vez de todos los datos inerciales. Este caso permite ahorrar energía, ya que los módulos de comunicaciones son los periféricos que mayor consumo reportan al 9x2.

Los clasificadores ‘online’, y la gestión de batería son los procesos de menor prioridad, y como tal sólo se pueden ejecutar cuando no haya que ejecutar ninguno de los procesos de mayor prioridad. Sin embargo, algunos algoritmos pueden asociarse a alguna interrupción y, por tanto, ejecutarse cuando haya alguna petición de interrupción de algún periférico sin tener que esperar a que no haya ningún proceso en cola.

La gestión de la batería consiste en controlar el monitor de batería. El MCU informa al usuario del estado de la batería a través de la interfície de usuario. Sin embargo, si se recibe una señal por parte del monitor de batería de “nivel muy bajo”, el sistema cierra todas las comunicaciones, cierra el archivo, en el caso que hubiese alguno escribiéndose, y envía al sistema a dormir. Este método permite no perder ningún tipo de señal, y nos garantiza la integridad de los datos en una captura cuando el sistema se apaga a causa de una bajada excesiva de la tensión de alimentación. Cuando el usuario decide cargar la batería del 9x2, se efectúa una interrupción externa que realiza el mismo proceso que cuando hay baja batería (cerrar comunicaciones e irse a modo ‘Sleep’). Se considera que no es necesario mantener al dispositivo despierto cuando la batería esté cargándose.

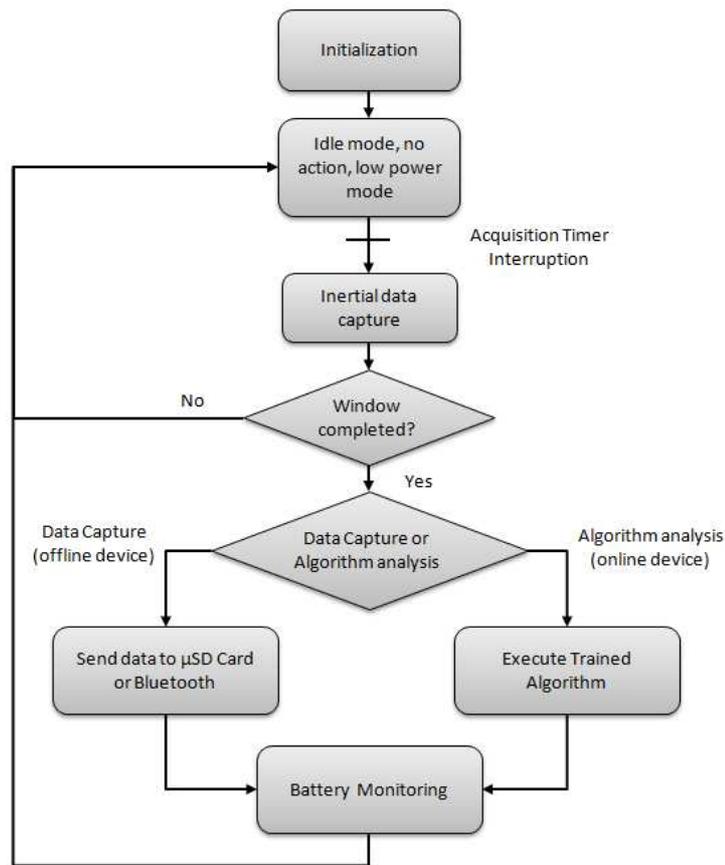


Figura 3.10. *Secuencia de firmware*

La función algorítmica se ejecuta en dos partes. En la primera de ellas se pre-procesan los datos obtenidos en el momento, por ejemplo los filtros de la señal, o bien características de muestras actuales respecto a las anteriores, por ejemplo los incrementos entre muestras. Por otra parte, ya que los clasificadores ‘online’ están basados en el análisis de ventanas de señal [127,128], cuando una ventana de señal se complete, se da lugar a la ejecución del cálculo del clasificador ‘online’. Cuando el sistema se programa sólo para capturar y almacenar datos, no se ejecuta ningún algoritmo ni se extrae ninguna característica. El sistema sólo funciona en Run durante el proceso de captura de datos y envío de los datos a los módulos de comunicación. La Figura 3.10 muestra la estructura básica del firmware resumiendo su comportamiento dual.

Con el fin de comprobar el rendimiento del 9x2, se han establecido 2 grupos de test, el primero el 9x2 realiza la tarea de enviar datos continuamente a la tarjeta  $\mu$ SD, el segundo, envía los datos a través del módulo Bluetooth. El sistema se ha testado

funcionando a una frecuencia de muestreo de 200 Hz y se ha ejecutado 10 veces para lograr datos precisos de rendimiento. Por una parte, la CPU del MCU permanece un total de un  $95.46\% \pm 2.03\%$  del total del tiempo de proceso en un estado de operación 'Idle' cuando se están enviando datos inerciales continuamente por Bluetooth. Por otro lado, cuando el sistema está escribiendo continuamente por Bluetooth, el sistema permanece un  $99.2\% \pm 0.01\%$  del tiempo total en estado 'Idle' cuando el sistema está escribiendo por tarjeta  $\mu$ SD sin tener conectado el módulo Bluetooth.

### ***3.3.2 Proceso de captura***

La principal prioridad del MCU es garantizar una frecuencia de muestreo estable y precisa. Para ello, los otros procesos que intervienen en el programa no deben tener nunca mayor prioridad, y todos ellos deben de ser interrumpidos, cuando se haga una petición de interrupción en el proceso de captura de datos.

Para conseguirlo, la frecuencia de muestreo está controlada por un timer que depende principalmente de la frecuencia propia del MCU, que está calibrada para conseguir la máxima precisión. La frecuencia de muestreo es, por defecto, de 200Hz, aunque el usuario puede modificar esta frecuencia a través de comandos enviados por el módulo de Bluetooth. Una vez se produce una petición de interrupción del proceso de captura, se avisa al módulo ADC con el fin de que recoja los datos analógicos a través del DMA. Paralelamente, mientras se recogen los datos del ADC por DMA, se recogen los datos por I<sup>2</sup>C del acelerómetro. Seguidamente los datos se ordenan y se almacenan en la RAM, listos para ser enviados a través del bus SPI hacia la tarjeta  $\mu$ SD o bien a través de del módulo UART hacia el módulo Bluetooth. Los datos enviados están compuestos por los datos inerciales (acelerómetro, giroscopio y magnetómetro), el valor del sensor de temperatura, los tiempos recogidos correspondientes a la duración del proceso de recoger datos, y el diferencial de tiempo con respecto a la última muestra enviada. Además se envía también el estado de la batería y códigos de identificación del dispositivo. Los valores de ciertos campos de la trama se pueden modificar, por ejemplo, en lugar de enviar los valores temporales de las muestras, se pueden enviar los valores del RTCC, en otras palabras, la hora y/o día actual registrado por el RTCC.

Los datos son almacenados en una RAM dedicada, que se actualiza en cada captura de datos. Puesto que los algoritmos trabajan con ventanas temporales de datos, es preciso guardar datos inerciales durante varios segundos, por tanto se han dedicado 5 KB de datos de RAM correspondientes a unos 10 segundos para almacenar datos inerciales con el fin de que el MCU pueda trabajar eficientemente.

### ***3.3.3 Conexión Bluetooth***

El módulo de Bluetooth realiza 2 funciones principales en el 9x2. La primera es recibir instrucciones de algún sistema externo (PC, tablet, teléfono móvil). La segunda es enviar las tramas descritas en el apartado 3.3.2 con el fin de que se puedan procesar o almacenar en un sistema externo. Hay una opción extra, la cual es muy útil para poder trabajar con dos sistemas inerciales simultáneamente. Se trata de recoger los datos de un dispositivo externo complementario. El MCU ordena estos datos en la trama y los guarda en la tarjeta  $\mu$ SD.

En el principio del programa, el sistema comprueba si hay conectada una tarjeta  $\mu$ SD, seguidamente el sistema espera las instrucciones de un sistema externo. En la base de datos realizada en el proyecto REMPARK, por ejemplo, un PC envía la hora actual al 9x2, la cual es almacenada en los registros del RTCC para poder mantener la hora correctamente. Otra aplicación del Bluetooth es, por ejemplo, recibir la frecuencia de muestreo a través de instrucciones antes de recolectar datos inerciales, por lo que la captura se puede hacer a cualquier velocidad entre 1 y 200 Hz. A través de este sistema, el IMU puede recibir la orden 'Pausa', la cual permitirá realizar una pausa en el proceso de captura de datos con el fin de evitar obtener datos innecesarios en la base de datos. Finalmente, en la aplicación realizada para pacientes con PD, los resultados de los algoritmos implementados son enviados a través del Bluetooth a un teléfono móvil.

### ***3.3.4 Comunicación con la tarjeta $\mu$ SD***

La memoria flash de la tarjeta  $\mu$ SD es esencial para almacenar datos inerciales. Este

módulo permite capturar datos sin la necesidad de una conexión inalámbrica. Las tarjetas  $\mu$ SD empleadas en el 9x2 tienen una capacidad de 2GB ya que funcionan a través de un sistema de archivos FAT16. Este sistema permite poder capturar datos a una frecuencia de muestreo de 200 Hz durante 3 días y 19 horas sin pausa. Si el sistema recoge datos a 40 Hz, el sistema nos permite guardar datos durante 19 días y 10 horas. Puesto que el sistema funciona con un sistema de archivos FAT16, los datos recogidos se organizan bajo una estructura de 32 bytes. En un sistema FAT16, un clúster equivale a 16KB de memoria, cada clúster contiene 32 sectores de 512 bytes de memoria cada uno. Cada sector contiene 16 tramas de datos inerciales (en el caso de estar operando como registrador de datos). Los procesos para gobernar los clústeres y los sectores se han realizado mediante un firmware específico basado en una máquina de estado que sólo se ejecuta cuando un sector ha recibido las 16 tramas de memoria. Si en ese momento el clúster se ha completado con los 32 sectores, se procede a escribir el clúster en la tarjeta  $\mu$ SD a través de la DMA, de otro modo sólo se aumenta el contador de sectores y se procede a dormir al sistema. La CPU sólo controla si el buffer para enviar los datos está lleno, en tal caso, se copian los datos de la RAM a la memoria asociada en el DMA y se envía una orden al DMA para empezar a escribir datos en la tarjeta  $\mu$ SD a través del bus SPI. Puesto que las tarjetas SD son dispositivos de memoria Flash, los procesos para escribir bloques de datos a través de la SPI hacia la tarjeta SD pueden tardar más de 250 ms. Cuando un clúster o sector se llena y por tanto se debe seleccionar uno nuevo, el MCU envía comandos a la tarjeta  $\mu$ SD, la cual necesita un tiempo extra para poder ejecutar tal operación con el fin de que se pueda escribir en nuevos rango de memoria[129]. Durante este tiempo, la RAM del MCU tiene que guardar los datos que se han muestreado cada 5 ms siendo la frecuencia de muestreo de 200 Hz. Puesto que cada trama es de 32 bytes, se pueden almacenar 160 tramas en una memoria de 5 KB. A una frecuencia de 200 Hz, el buffer de 5 KB se llena en unos 800 ms. Este periodo de tiempo es suficiente para garantizar que ningún dato se pierde puesto que la tarjeta  $\mu$ SD tarda 250 ms en escribir un bloque de su RAM a su memoria Flash.

### 3.3.5 Proceso algorítmico

Para analizar las medidas de los sensores en tiempo real, habitualmente los datos se disponen en ventanas de datos de periodos cortos [130,131]. Además, se solapan las ventanas un 50% con el fin de no perder información de eventos entre ellas [132,133]. En el sistema 9x2, también se siguen estos principios y estas ventanas de datos se guardan en la RAM del MCU puesto que estos datos se van actualizando continuamente a lo largo del tiempo. La memoria Flash contiene todas las constantes y parámetros de los modelos de los clasificadores calculados 'offline' y que son necesarios para el procesamiento en tiempo real.

Entre los procesos que administra el MCU, el proceso dedicado a ejecutar los clasificadores 'online' implementados, junto con el proceso de estado de batería, es el proceso con menos prioridad. Un proceso de algoritmia puede ser muy largo. Dado que una de las premisas es garantizar la precisión de la frecuencia de muestreo, y la transferencia correcta de datos entre periféricos, el algoritmo debe poder ser interrumpido por cualquiera de estos procesos para luego, continuar. Aunque la latencia del proceso es importante, en términos de movimiento, un retardo de varios microsegundos durante el cual el proceso de algoritmia se retrasaría no es relevante.

La gestión de la memoria en los clasificadores 'online' también es un aspecto relevante. Por una parte, cuando se guardan los datos en la tarjeta  $\mu$ SD, se forman ventanas de 512 bytes, siendo este el tamaño de un sector dentro del sistema de archivos FAT16. Por otra parte, se forman también las ventanas correspondientes al análisis del algoritmo. Sin embargo, la memoria es compartida y por tanto no se hace uso de un doble buffer. Un contador alerta al MCU de si la ventana de análisis está completa y, en consecuencia, preparada para ser analizada. Posteriormente, los datos de la ventana se filtran y las características se seleccionan y se extraen tal y como muestra la Figura 4.1. Inmediatamente después, se ejecutan los clasificadores que se hayan programado en el MCU, ya sean árboles de decisión, redes neuronales, modelos de Markov o SVMs. Los resultados de los algoritmos se pueden enviar a través del Bluetooth, o se pueden almacenar en la tarjeta  $\mu$ SD con fines de depuración de resultados. Estos resultados se pueden analizar para diagnosticar algunas enfermedades o síntomas y posteriormente

enviar estos resultados a otro módulo externo. Finalmente, el sistema entra en modo 'Idle' para poder ahorrar energía.

Dentro del desarrollo 'online', para el cálculo de algunas operaciones, se ha utilizado el controlador DSC para calcular multiplicaciones a gran velocidad.

### ***3.3.6 Aplicación 'online'***

En este apartado se presenta una aplicación 'online' del 9x2 que se realizó bajo el proyecto HELP. En esta aplicación se implementa un algoritmo de inteligencia artificial dentro del MCU para que el IMU se comportara como dispositivo 'online'. En esta aplicación se implementan SVMs y Transformadas de Fourier de Tiempo Reducido (Short Time Fourier Transform, STFT) en el DSC para reducir la carga computacional. Esta implementación ejecuta un clasificador de reconocimiento de la marcha en tiempo real [68].

Un pre-requisito para realizar un análisis de la marcha en el proyecto HELP fue identificar si un paciente con PD estaba caminando con el 9x2 localizado en la cintura. Para ello, se realizó una base de datos mediante las señales inerciales capturadas de los diferentes pacientes voluntarios con PD. Cada paciente realizaba un protocolo de pruebas que consistía en realizar diferentes actividades de la vida diaria con el sensor inercial. Esta base de datos se utilizó para entrenar una SVM con el fin de encontrar un modelo que distinguiera si la persona caminaba o no [68]. Se tuvo en cuenta que el modelo debería ejecutarse en un MCU, esto implica optimizar el modelo con el principal objetivo de minimizar el número de vectores de soporte. Se logró un modelo con 66 vectores de soporte, y se implementó dentro del MCU. Siguiendo la Figura 4.1, el dispositivo 'online' capturaba primero los datos inerciales y seguidamente, cuando la ventana estuviese completa, se calculaban las características extraídas de esta ventana. En concreto, tras realizar la Transformada de Fourier de Tiempo Reducido de esta ventana, se caracterizaba el espectro frecuencial a través de 2 valores. Ambas características se normalizan, siendo finalmente las 2 características de entrada del modelo entrenado de la SVM. La salida de este modelo indicaba si la persona estaba caminando o no.

Los tiempos de cada una de las fases descritas en la Figura 4.1 se muestran en la Tabla 3.3. Estos tiempos se obtuvieron a través de un osciloscopio conectado al 9x2 el cual activaba y desactivaba salidas cuando cada uno de los procesos de la Figura 4.1 empezaba o acababa. El tamaño de ventana es de 3.2 s de duración, y la frecuencia de muestreo de 40 Hz. Las ventanas se solapan al 50% y cada ventana contiene 128 muestras. Como muestra la Tabla 3.3, cada 1.6 s, el MCU se despertaba del estado ‘Sleep’ para empezar a calcular los procesos. Después de levantarse, se necesita un total de 44.86 ms para calcular la extracción de características, normalización de datos, y clasificación de SVM. Esto significa que el MCU permanece en modo ‘Idle’ o ejecutando otros procesos (Captura de datos, Bluetooth, tarjeta  $\mu$ SD, Gestión de Batería) durante un 97.2% del total del tiempo disponible.

<i>Eventos</i>	<i>Duración de los eventos</i>
Inicio del cálculo	Cada ventana (1.6 s)
Extracción de características	35.07 ms
Normalización de datos	0.04 ms
Clasificación con SVM	9.75 ms
<b>Tiempo total de cálculo</b>	<b>44.86 ms</b>

Tabla 3.3. *Tiempos de cómputo del MCU*

### **3.4 Conclusiones del 9x2**

En este capítulo se ha descrito el sistema del 9x2 tanto su hardware como su firmware. Además se ha incluido un breve estudio temporal de unas de las aplicaciones empleadas en uno de los proyectos europeos en el cual el 9x2 forma parte. Esta aplicación demuestra la capacidad del dispositivo para poder trabajar sólo en aquellos instantes que lo necesite. De esta forma, el resto de tiempo el 9x2 permanece en modo ‘Idle’, reduciendo el consumo y, por lo tanto, aumentando la autonomía.

Además de ejecutar clasificadores en tiempo real, cumple con los requisitos propuestos, y es capaz de capturar y almacenar datos a 200Hz de sus sensores inerciales (acelerómetro, giroscopio y magnetómetro), además de proporcionar la temperatura.



*Parte II: Algoritmos de análisis de  
señal de acelerómetros para la  
detección de posturas y Bloqueo de  
la Marcha en pacientes con  
Parkinson*



## Capítulo 4

# Metodología de evaluación de la monitorización de actividad

En este capítulo se describe la metodología empleada para analizar los algoritmos de detección de posturas y FoG que se detallan en los siguientes capítulos. Para ello, se parte de una descripción del proceso habitual para tratar y clasificar una señal. Se describe, posteriormente, la teoría básica de las máquinas de vectores soporte, y se concluye con la definición de elementos estadísticos para poder evaluar el funcionamiento de los clasificadores.

### *4.1 Reconocimiento de patrones*

Reconocer patrones es una operación muy sencilla para una persona (reconocer las llaves del coche con sólo tocarlas, saber si la fruta ha madurado con la vista, leer caracteres o reconocer palabras que ha dicho otra persona). En cambio, reconocer patrones automáticamente es una tarea compleja que ha sido aplicada en múltiples campos como la ingeniería, biología, medicina o economía [134]. Con el fin de reconocer patrones automáticamente, es necesario un sistema de aprendizaje automático. Según Simon, el aprendizaje “denota un cambio en un sistema por el cual, permite que la próxima vez se realice con mayor eficacia”[135].

El sistema clásico de reconocimiento de patrones automático aplicado a señales se puede dividir en diferentes partes como muestra la Figura 4.1: captura de datos, separación de ventanas o ventaneado de la señal, extracción de características y clasificación con sistema automático de aprendizaje [136].

Un clasificador es un elemento capaz de interpretar unas entradas (patrón de entrada) con el fin de obtener una salida. Las entradas del clasificador están constituidas por un vector de características que representan los parámetros de un dominio de una entrada.



Figura 4.1. Método clásico de clasificación

En el ventaneado de una señal se divide temporalmente una señal en partes iguales, de las cuales se extraen unas características. El preproceso de una señal es un tratamiento de la señal con el fin de poder eliminar el ruido y los errores aberrantes de una señal sin perder la información contenida en la señal original. Dado que los sensores inerciales contienen información frecuencial.

El movimiento humano puede ejercerse a una determinada frecuencia, sin embargo, solo es de interés por debajo 40 Hz [119]. Dado que el acelerómetro no proporciona una señal limpia, y contiene un cierto nivel del ruido, que está por encima de 40 Hz, se requiere de un filtro pasa bajos para eliminar las señales por encima de los 40 Hz. En esta tesis se aplica un filtro Butterworth IIR de 2º orden. La implementación realizada está representada en la Figura 4.2

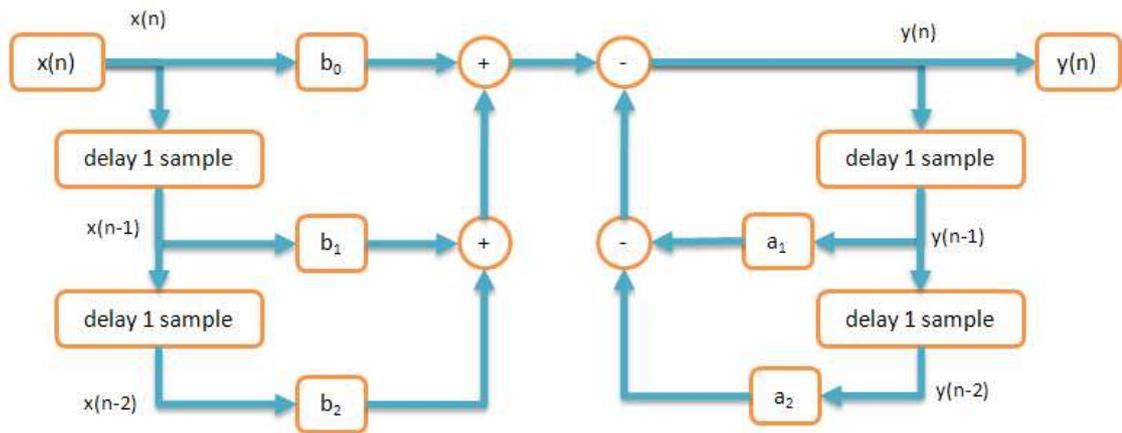


Figura 4.2. Implementación del filtro Butterworth IIR de 2º orden

La entrada  $x_n$  representa cualquiera de las 9 señales proporcionadas por el 9x2 (3 x acelerómetro, 3 x giroscopio, 3 x magnetómetro). La respuesta  $y_n$  viene dada por:

$$y_n = b_0 \cdot x_n + b_1 \cdot x_{n-1} + b_2 \cdot x_{n-2} - a_1 \cdot y_{n-1} - a_2 \cdot y_{n-2} \quad (4.1)$$

donde los coeficientes  $b_0, b_1, b_2, a_1, a_2$  están determinados en función de la frecuencia de muestreo de la señal inercial, y en función de la frecuencia de corte. La frecuencia de corte es aquella frecuencia a partir de la cual el filtro atenúa a  $20 \cdot k \text{ dB/década}$ , donde  $k$  es el orden del filtro.

Dado que es necesario capturar 3 muestras para poder determinar la muestra actual, se obtiene un pequeño retraso en la señal, sin embargo, es poco importante dada la respuesta del filtro que nos permite trabajar sin ruidos tal y como se muestra la Figura 4.3

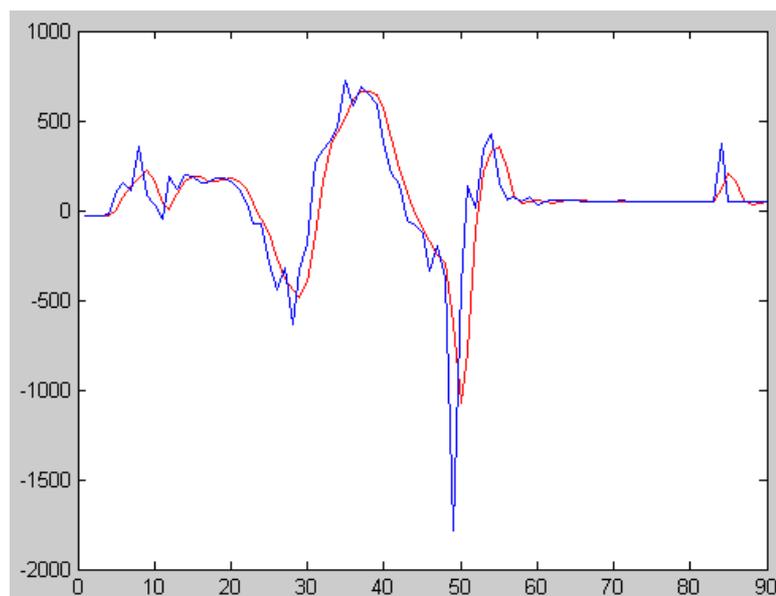


Figura 4.3. Señal filtrada con un filtro IIR de 2º orden

La selección de características permite escoger aquellas características más representativas de los patrones de entrada. Existen técnicas que permiten seleccionar características con ciertas propiedades o para obtener nuevas características reduciendo la dimensión del espacio de características (Analysis of Variance y Principal Component Analysis) [137] o ReliefF [138]. Una vez se conocen las características que mejor representan a los patrones de entrada, el clasificador sólo ha de extraer las características de la señal original construyendo un vector de características.

Dentro del proceso de clasificación con SVMs, la normalización de los datos permite comparar las diferentes características de la señal, que probablemente no compartan unidades físicas. Por lo tanto, es de suma importancia poder normalizar con el fin de tratar las características por igual antes de ser analizadas por el clasificador.

Existen diferentes taxonomías de clasificadores [73,134,136,139]. Los clasificadores se pueden distinguir por tres tipologías, apriorísticas, deterministas/no deterministas, o bien supervisados/no supervisados. En la presente tesis se emplea la clasificación supervisada, es decir, en la fase de entrenamiento del sistema, a diferencia de la clasificación no-supervisada, el sistema de aprendizaje automático aprende una serie de características ya etiquetadas. Otra taxonomía de clasificadores es: asociación de patrones, probabilístico y geométrico. El primero trata de clasificar en función de la similitud del dato observado y el patrón de entrada. Un ejemplo de este clasificador es el

clasificador k-Nearest Neighbour (k-NN), basado en la distancia que separa un patrón con una nueva muestra en el espacio de características. Los clasificadores probabilísticos, como el clasificador óptimo Bayesiano, se basan en la probabilidad de una muestra a pertenecer a una clase en función de unas condiciones. Los clasificadores geométricos se basan en la distancia de las muestras respecto de una o varias funciones discriminantes en el espacio de características. Un ejemplo son las redes neuronales artificiales (ANN), y las máquinas de vectores soporte. Este último paradigma es el método empleado en esta tesis debido a su gran capacidad de optimización. A diferencia de las redes neuronales, las máquinas de vectores soporte encuentran un mínimo global (Ecuación 4.4).

## 4.2 Las 'Máquinas de vectores soporte'

Las 'Máquinas de vectores soporte' fueron diseñadas, en su formulación original, para tareas de bi-clasificación. Séase un conjunto de entradas compuesto por  $x_i \in \mathbb{R}^2$  etiquetados como *Clase 1* y *Clase -1* ( $y_i \in \{1, -1\}$ ) y representado en la Figura 4.4, donde no existe posibilidad de separarlo a través de una frontera de decisión lineal.

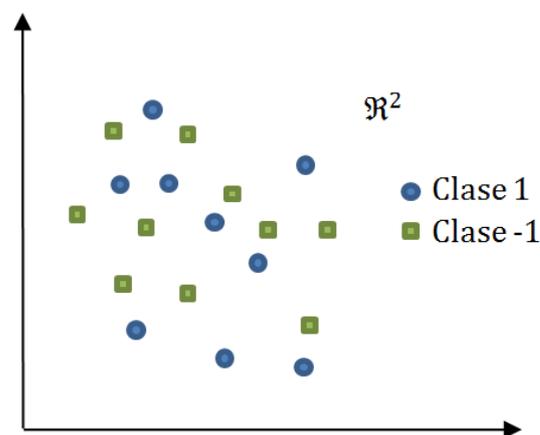


Figura 4.4. Conjunto de datos no linealmente separable

Las 'Máquinas de vectores soporte' mapean el conjunto de entradas a un espacio de características ( $Z$ ) de una dimensión más elevada a través de  $z_i = \varphi(x_i)$  [140]. En esa dimensión de mayor orden, un hiperplano separa las dos clases maximizando el margen

$m$  entre las clases tal y como muestra la Figura 4.5

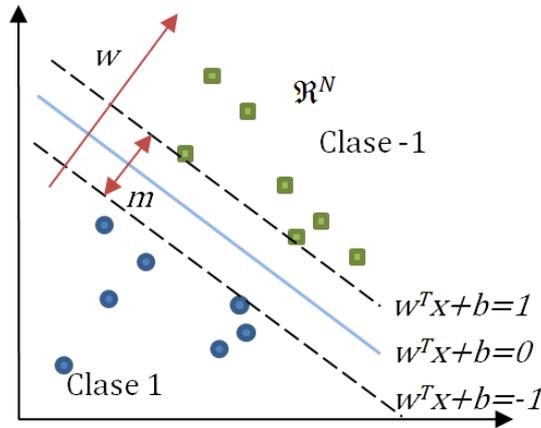


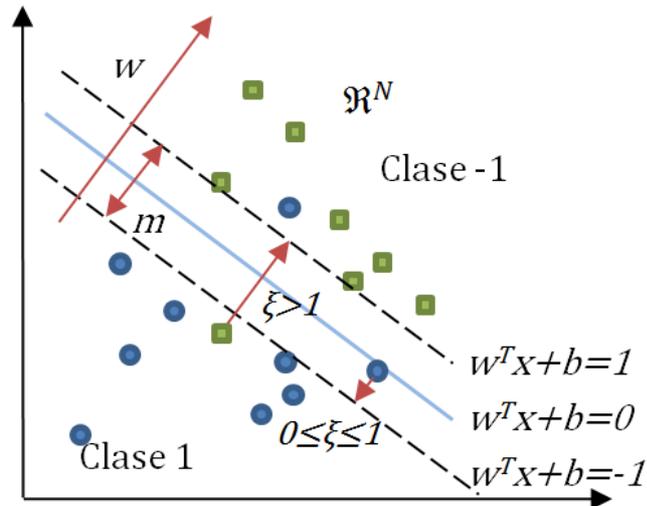
Figura 4.5. Hiperplano que maximiza el margen de clasificación entre clases

Las etiquetas de salida, correspondientes a la denominación de las clases, son definidas como  $y_i \in \{1, -1\}$ . El hiperplano trazado por la SVM, maximiza el margen de separación entre las 2 clases, el cual maximiza la dimensión Vapnik-Chervonenkis, una medida que mide la capacidad de generalización del algoritmo. Considerando los datos linealmente separables, el hiperplano es definido como un vector  $w \in Z$  y un escalar  $b \in \mathfrak{R}$  que cumplen  $w \cdot z + b = 0$  tal que las entradas  $x_i$  satisfacen:

$$y_i(w \cdot z_i + b) \geq 1, \forall i \quad (4.2)$$

Sin embargo, para los casos no linealmente separables, se introduce la variable  $\xi$  con el fin de permitir un error de clasificación (Figura 4.6). Esta variable se llama variable de holgura y expresa la distancia a la que puede estar un vector del lado contrario del hiperplano, de forma que satisface la Ecuación 4.3. Si  $\xi_i > 1$  la muestra se encuentra en la región de la otra clase, mientras que si  $0 \leq \xi_i \leq 1$  la muestra se dispone entre la frontera de decisión  $w \cdot z_i + b = 0$  y  $y_i(w \cdot z_i + b) = 1$ :

$$y_i(w \cdot z_i + b) \geq 1 - \xi_i, \forall i \quad (4.3)$$


 Figura 4.6. Parámetro  $\xi$  dentro del problema de clasificación

El hiperplano óptimo está definido de acuerdo al siguiente problema de optimización:

$$\text{minimizar } \left\{ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \right\} \quad (4.4)$$

$$\text{Sujeto a } y_i(w \cdot \varphi(x_i) + b) \geq 1 - \xi_i, \forall i \quad \xi_i \geq 0, \forall i$$

donde  $\frac{1}{2} \|w\|^2$  maximiza el margen de clasificación,  $C$  es el parámetro de regularización, y su función es balancear la maximización del margen y el error de clasificación. De ahora en adelante, se definen dos variables de coste  $C_1$  y  $C_{-1}$  para las 2 clases  $y_i = 1$  y  $y_i = -1$  respectivamente. La principal función es poder equilibrar las poblaciones. Dado que el algoritmo de entrenamiento tiende a minimizar el error de clasificación, una población muy alta de muestras de una clase en comparación con la otra clase induce a formar una frontera de decisión apropiada para la clasificación de las clases de la muestra con más población. El nuevo hiperplano óptimo se define de la siguiente forma:

$$\text{minimizar } \left\{ \frac{1}{2} \|w\|^2 + C^* \sum_{i=1}^l \xi_i \right\} \quad (4.5)$$

$$\text{Sujeto a: } y_i(w \cdot \varphi(x_i) + b) \geq 1 - \xi_i, \forall i$$

$$\xi_i \geq 0, \forall i$$

$$C^* = C_1 = C \cdot \rho_{-1} \text{ si } y_i = 1$$

$$C^* = C_{-1} = C \cdot \rho_1 \text{ si } y_i = -1$$

donde  $C_1$  y  $C_{-1}$  son los pesos que balancean el número de muestras de cada clase,  $\rho_{-1}$  es la proporción de datos de la clase 1 y  $\rho_1$  es la proporción de los datos de la clase -1.

La Figura 4.7 muestra dos fronteras de decisión obtenidas a través de un kernel lineal para separar un conjunto de datos. El modelo obtenido en la figura de la izquierda muestra la frontera de decisión obtenida con un modelo donde se han balanceado las muestras en la fase de entrenamiento. En el modelo de la derecha, en cambio, se ha mantenido el mismo valor  $C$  para cada una de las clases. El modelo de la derecha minimiza error de clasificación del problema clasificando correctamente las muestras de la clase más numerosa. En consecuencia, el error de clasificación de la clase menos numerosa es mayor. Es por eso que es importante balancear las muestras. En los capítulos posteriores, los algoritmos de clasificación emplean todos unos balanceos de las muestras.

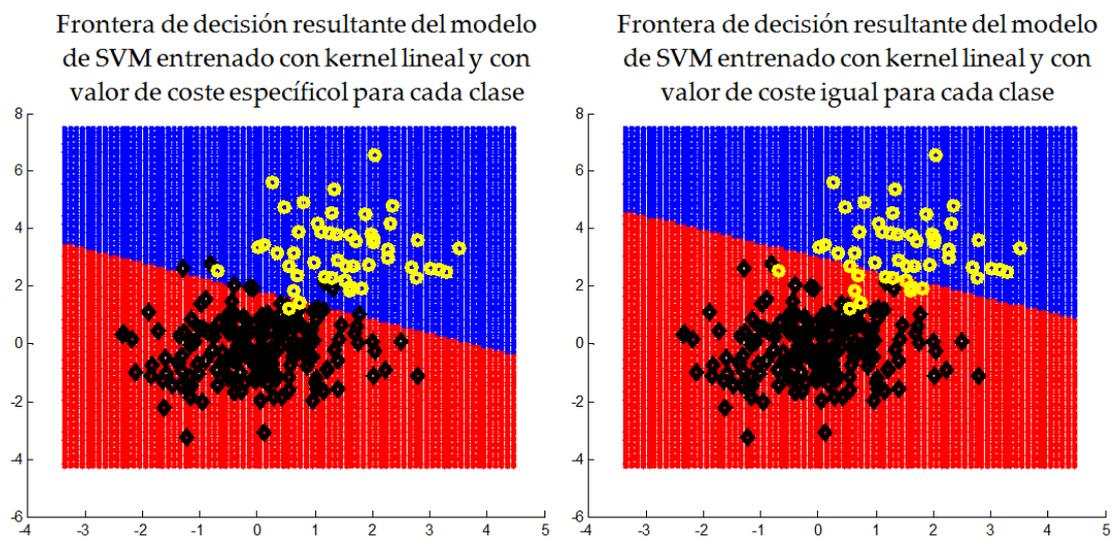


Figura 4.7. *Fronteras de decisión de acuerdo con el tratamiento del balanceo de datos*

Con el fin de poder solucionar la Ecuación 4.5, se obtiene su expresión en forma de multiplicadores de Lagrange y se simplifica, transformando el anterior problema de

minimización en el siguiente problema dual:

$$\begin{aligned}
 \text{maximizar } W(\alpha) &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l (\alpha_i \alpha_j y_i y_j \cdot K(x_i, x_j)) \\
 \text{Sujeto a } 0 \leq \alpha_i &\leq C_1, \quad \text{si } y_i = 1 \quad i = 1, \dots, l \\
 0 \leq \alpha_i &\leq C_{-1}, \quad \text{si } y_i = -1, \quad i = 1, \dots, l
 \end{aligned} \tag{4.6}$$

La función kernel  $K(x_i, x_j)$  sustituye al producto escalar  $\varphi(x_i) \cdot \varphi(x_j)$ . De esta forma, no es necesario conocer la representación de los vectores de entrada en el espacio de alta dimensionalidad, sino únicamente debemos conocer la expresión que nos relaciona los vectores de entrada con el producto escalar de los mismos dentro del espacio de mayor dimensionalidad. De acuerdo con el teorema de Kuhn-Tucker, los puntos del vector de características de entrada  $x_i$  cuyos multiplicadores satisfacen  $\alpha_i > 0$  son los llamados vectores de soporte (SV). En tiempo real, el clasificador deberá operar los vectores de soporte con el vector de características. Un número reducido de vectores de soporte reduce la carga computacional y por tanto aumenta la velocidad del proceso de clasificación. En el diseño del modelo de la SVM, uno de los objetivos más importantes es poder minimizar el número de vectores de soporte.

La clase de un nuevo patrón se obtiene mediante:

$$f(x) = \text{sign}(w \cdot \varphi(x) + b) = \text{sign}\left(\sum_{i=1}^l \alpha_i y_i \cdot K(x_i, x_j) + b\right) \tag{4.7}$$

En esta tesis se emplean kernels lineales  $K(x_i, x_j) = x_i \cdot x_j$  para fijar los diferentes umbrales que gobiernan el sistema jerárquico de clasificación. Para las PT de 'SiSt' y 'StSi' se emplea el kernel de función de base radial Gaussiana (RBF), dada su capacidad para generalizar la clasificación,  $K(x_i, x_j) = e^{\left(\frac{-\|x_i - x_j\|^2}{2\sigma^2}\right)}$ , donde  $\sigma$  es la varianza de la función gaussiana.

Las SVMs en definitiva, constituyen un modo de bi-clasificar óptimo, en otras

palabras, maximiza el margen entre las dos clases. Se ha visto que su rendimiento es muy alto en algoritmos aplicados a reconocimiento de actividad humana [141], y además son fáciles de implementar en un microcontrolador [142].

### ***4.3 Evaluación de los algoritmos***

Los clasificadores son capaces de determinar una salida en función de un vector de características de entrada. Sin embargo, se necesitan herramientas de evaluación para conocer el funcionamiento del clasificador. Además, para evaluar la salida del clasificador, se necesita una etiqueta o un gold-standard para saber si la clasificación es correcta o no.

En medicina, la utilización de valores estadísticos es útil para valorar la validez de un diagnóstico [143]. Para cada diagnóstico, se emplean los siguientes términos para determinar el resultado:

- Si el instrumento diagnostica correctamente como enferma a una persona se denomina un caso de verdadero positivo (TP).
- Si el instrumento diagnostica como enferma a una persona sana, es un caso de falso positivo (FP).
- Si el instrumento diagnostica correctamente como sana a una persona sana, se define como caso de verdadero negativo (TN).
- Si el instrumento diagnostica como sana a una persona enferma, es un caso de falso negativo (FN).

Estas designaciones, aplicadas a instrumentos de diagnóstico en medicina, se pueden extrapolar a los clasificadores obtenidos mediante técnicas de aprendizaje automático para valorar su funcionamiento [144]. Cada uno de los datos del conjunto de datos de entrada, tras ser evaluado por el clasificador, se distingue como uno de estos 4 casos

(TP,TN,FP,FN). A través de la frecuencia de aparición de cada uno de ellos se obtienen diferentes medidas para determinar el buen funcionamiento de un clasificador.

La sensibilidad nos muestra la capacidad de nuestro clasificador para dar como casos positivos los casos realmente positivos ( $Sensibilidad = \frac{TP}{TP+FN}$ ). La especificidad nos muestra la capacidad del clasificador para identificar los casos negativos ( $Especificidad = \frac{TN}{TN+FP}$ ).

La precisión (Accuracy en inglés) de un sistema de medida es la capacidad de un clasificador de determinar la proporción de resultados verdaderos (TN y TP) de una base de datos. Se define como  $Precisión (Accuracy) = \frac{TP+TN}{TP+TN+FP+FN}$ .

El uso de la sensibilidad y la especificidad es muy común en problemas de bi-clasificación para análisis de movimientos [82,130,133,141,145,146]. La precisión también se usa comúnmente, aunque puede ser confusa. Si la precisión es muy elevada, suele ser un indicador de que el clasificador identifica bien un conjunto de datos, sin embargo, es posible que no identifique bien alguna de las clases si ésta representa una proporción pequeña de los datos. Por ello, en esta tesis no se utilizará la precisión como medida de bondad de un clasificador sino que se empleará la especificidad y sensibilidad.

Existen otros indicadores útiles, así como el Valor Predictivo Positivo (VPP), y el Valor Predictivo Negativo (VPN). El VPP indica la probabilidad de acierto de un clasificador cada vez que se clasifica un patrón como clase positiva. Está definido como  $VPP = \frac{TP}{TP+FP}$ . El VPN por el contrario es la probabilidad de acierto de un clasificador cada vez que se clasifica un patrón como clase negativa. Está definido como  $VPN = \frac{TN}{TN+FN}$ .

#### ***4.4 Conclusiones sobre la metodología de evaluación de algoritmos de la monitorización de actividad***

En este capítulo se ha realizado una introducción teórica acerca de la metodología que se ha utilizado para desarrollar los algoritmos y posteriormente, evaluarlos. Se ha empleado el paradigma de las máquinas de vectores soporte dada su alta capacidad de optimización mediante la maximización del margen de clasificación. El balanceo de

datos afecta de manera notable la clasificación de los datos, y, dado que en algunas pruebas se obtienen poblaciones de muestras desbalanceadas, se propone emplear un balanceo para obtener una función discriminante que no sólo minimice el error sino que sea capaz de separar correctamente las clases en el caso que las poblaciones estuviesen equilibradas.

Además, se han descrito los indicadores para los datos de salida del algoritmo con el fin de obtener información sobre el rendimiento del algoritmo.

# Capítulo 5

## Estado del Arte en detección de actividad

En este capítulo se describe el estado del arte en el campo de la detección e identificación de posturas y actividad desde dos puntos de vista: Los diferentes sistemas inerciales para estudiar el movimiento humano y a continuación, un estado del arte de reconocimiento de actividad donde se describen las metodologías empleadas con sensores inerciales basados en MEMS.

### *5.1 Estado del arte en reconocimiento de actividad*

La monitorización de actividad es de gran utilidad para evaluar la calidad de vida en personas mayores o en pacientes con movilidad reducida [5,60,64]. En pacientes con parálisis cerebral, por ejemplo, es de suma importancia la evaluación de la rehabilitación del paciente a lo largo del tiempo para supervisar la evolución de las mejoras que manifiesta el paciente cuando camina [4]. En el campo de la dependencia, analizar transiciones posturales es trascendental, puesto que están muy relacionadas con las caídas [147,148]. La PT de 'levantarse' está considerada como la PT que requiere más ejecución mecánica en el movimiento de una persona [149], en consecuencia en una persona mayor, puede causar pérdidas de equilibrio, provocando caídas. En pacientes

con PD, una de las principales consecuencias de las transiciones posturales como ‘levantarse’ o ‘sentarse’ son también las caídas, sin embargo, las caídas también están relacionadas con trastornos de la marcha y, más concretamente, con el FoG. Los episodios de FoG frecuentemente ocurren después de un ‘levantarse’ y antes de caminar [37,38]. Actualmente existe una prueba clínica llamada ‘timed up & go’ y que consiste en una prueba en la que una persona se levanta de la silla, a continuación camina, normalmente cruzando un espacio estrecho, y finalmente da la vuelta y se sienta [146]. El tiempo que tarda en realizar una persona esta prueba indica el grado de movilidad de una persona. En este sentido, tal como Salarian et al. indican, la evaluación objetiva de las transiciones posturales mediante un sistema ambulatorio puede ser clínicamente muy interesantes. En el caso de PD, durante el timed up & go, un paciente experimenta varias situaciones donde puede sufrir un episodio de FoG, entre las cuales, se encuentra justo el momento en el que el paciente se ha ‘levantado’ de la silla. Por tanto, en esta PT en particular es importante observar si ocurren episodios de FoG o de caídas.

En las dos siguientes secciones, se detallan los métodos que se han empleado para estudiar y analizar las posturas, cuáles son sus ventajas y desventajas. Tal y como se justifica en la Parte I de esta tesis, los sistemas inerciales basados en MEMS son los métodos que permiten una detección más cómoda y eficiente debido a su tamaño y prestaciones. A continuación, y tomando como referencia los sistemas inerciales basados en MEMS, se describen los métodos empleados para identificar las posturas a partir de la colocación del sistema inercial, empleando varios sensores, o haciendo uso de varios tipos de sensores inerciales.

### ***5.1.1 Sistemas inerciales para el estudio de posturas***

Existen muchos métodos y sensores para estudiar y analizar la actividad física y en general los movimientos humanos. Por ejemplo, Guzmán et al. utilizaron cámaras de video para analizar el momentum en las transiciones de ‘levantarse’ en pacientes con problemas de movilidad o bien con sujetos con antecedentes de caídas [150]. La fotografía también es un método que se utilizó para analizar transiciones mediante la relación tiempo-espacio de varias partes del cuerpo como la cabeza, cadera o rodilla

durante el proceso de 'levantarse' [151].

Otro sistema diferente a la captura de imagen fueron los goniómetros o electrogoniómetros. Estos sistemas fueron empleados por Kralj et al. y Piriyaaprasarth et al. para analizar ángulos entre diferentes tramos del cuerpo, principalmente las extremidades. Estos sistemas son muy interesantes en las transiciones de posturas, puesto que los goniómetros proporcionan una respuesta muy relevante en las rodillas y caderas cuando los pacientes ejecutan una transición postural de 'levantarse' o 'sentarse' [149,152]. Kralj et al., además de usar goniómetros y acelerómetros para analizar las transiciones, también utiliza una plataforma de presión para analizar la fuerza 'normal' que ejerce el suelo en una transición [149].

Kerr et al. utilizó una técnica llamada estereografía vectorial junto a electrogoniómetros y acelerómetros. Esta técnica consiste en monitorizar los desplazamientos lineales en 3 dimensiones a través de hilos provenientes de un cabrestante controlado por un potenciómetro [153]. Sin embargo, la técnica más utilizada hace unos años, y que aún se utiliza es la electromiografía. La electromiografía consiste en medir la tensión eléctrica producida por los músculos esqueléticos a través de electrodos [154]. Hay varios trabajos realizados acerca del análisis de las transiciones de posturas con electromiografía [155–157].

Unas de las desventajas principales de todos estos métodos (electromiografía, videocámara, electrogoniómetro, plataformas de presión y estereografía vectorial) es que son incómodos, pesados e invasivos para el paciente en la vida real [65]. Por eso sólo se utilizan en el estudio y análisis de los movimientos en condiciones de laboratorio [5]. Como ya se ha explicado en la Parte I de esta tesis, los MEMS constituyen una nueva forma de analizar el movimiento humano. El sujeto o paciente que porte un sensor inercial basado en MEMS puede realizar actividades cotidianas de forma confortable debido a su bajo peso y pequeño tamaño. En la actualidad, los sistemas inerciales basados en MEMS son los más empleados, debido a estas ventajas, y por lo tanto, hay muchos trabajos acerca del estudio de las posturas y de la marcha que los emplean. A continuación se detallan algunos de los trabajos más relevantes en este campo.

### *5.1.2 Estado del arte en reconocimiento de posturas con Unidades de Medida Inercial basados en MEMS*

El reconocimiento de posturas y de la marcha con sistemas inerciales basados en MEMS se efectúa mediante acelerómetros y en menor medida con giroscopios y magnetómetros [65].

El estudio del reconocimiento de posturas en una persona se ha estudiado extensamente [72,74,75] y es por eso que esta sección está estructurada en diferentes partes. Se describen los trabajos más relevantes de reconocimiento de posturas en función del número de sistemas inerciales, de la localización del sistema, la relación del análisis de movimiento estático y dinámico y, por último, se reportan algunos trabajos que se han realizado en función de los clasificadores. Además, dado que la marcha también se considera una actividad de vida diaria, se reportan algunos trabajos relacionados con el reconocimiento de la misma, ya que también está relacionado con las caídas y las transiciones de posturas, siendo esta última un pre-requisito para poder caminar [147,148].

El reconocimiento de posturas se podría clasificar en análisis de señal en posturas estáticas (sentado, tumbado y de pie), y análisis de señal de posturas dinámicas (caminar, o transiciones posturales). Dado que este estudio está focalizado a personas con la PD, se descarta clasificar actividades corriendo. Los análisis de señal estáticos, son aquellos que se basan en la extracción de características de una señal inercial solamente cuando la persona está quieta o en ausencia de movimiento. Por otro lado, el estudio dinámico implica estudiar las características dinámicas de una señal inercial donde se analiza el comportamiento de ésta a lo largo del tiempo. En la Figura 5.1 se observa la respuesta inercial de los dos estados, en ausencia de movimiento a la izquierda, y cuando hay una respuesta inercial importante, en el caso de la derecha, caminando.

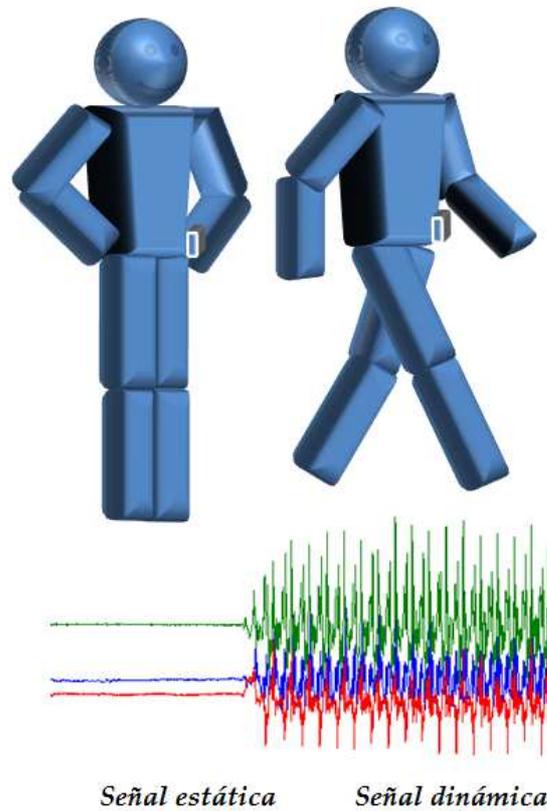


Figura 5.1. Respuesta inercial de movimientos estáticos y dinámicos

Cuando hay ausencia de movimiento, sólo se puede obtener el valor de la fuerza gravitacional a partir del módulo de la aceleración calculada según la siguiente expresión:

$$\sqrt{(a_x^2 + a_y^2 + a_z^2)} \Big|_{static} = G \quad (5.1)$$

En la Figura 5.2 se observa cómo los valores del acelerómetro varían en función de la inclinación del tronco respecto del eje de la gravedad si el acelerómetro está situado tal y como muestra la Figura 3.1, es decir en el lateral izquierdo de la cintura.

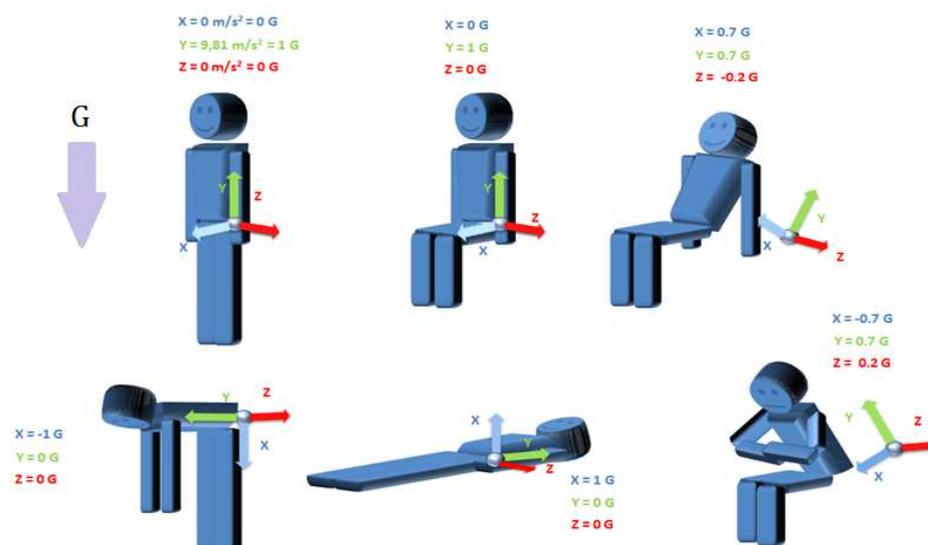


Figura 5.2. Posturas y respuesta inercial con un acelerómetro en la cintura

Algunos trabajos han estudiado reconocimiento de actividad física mediante análisis estático. Veltink et al. analizan la actividad estática mediante 3 acelerómetros uniaxiales, 2 de ellos en el pecho y otro en la pierna [158]. Sin llegar a evaluar el algoritmo, determinan que es posible distinguir diferentes actividades mediante la media de los valores que proporcionan los 3 acelerómetros usando la correlación de estos valores para cada actividad. Además realizan una distinción entre actividad estática y dinámica a partir de la desviación estándar de la media de los valores del acelerómetro. El grupo de Baek es capaz de distinguir actividades estáticas con una precisión del 100% a través de la inclinación relativa de un acelerómetro biaxial respecto la gravedad situando el acelerómetro en la cintura [159]. Por otra parte el grupo de Karantonis desarrolla un clasificador en tiempo real con la capacidad de distinguir varias actividades, entre ellas, actividades dinámicas. Las actividades estáticas identificadas por Karantonis, vienen determinadas por un descenso de la actividad proporcionado por la Signal Magnitude Area (SMA, véase Ecuación 7.1). Dentro de las actividades estáticas, Karantonis et al. obtiene de media un 94.1% de precisión [160]. Sin embargo, distinguir posturas sólo a través de la medición de la inclinación del acelerómetro respecto de la gravedad puede ser conflictivo puesto que es posible confundir con relativa facilidad posturas estáticas como estar de pie y sentado [71,133]. En la Figura 5.3 se muestran 2 casos conflictivos de medición del valor del acelerómetro en 2 posturas completamente distintas.

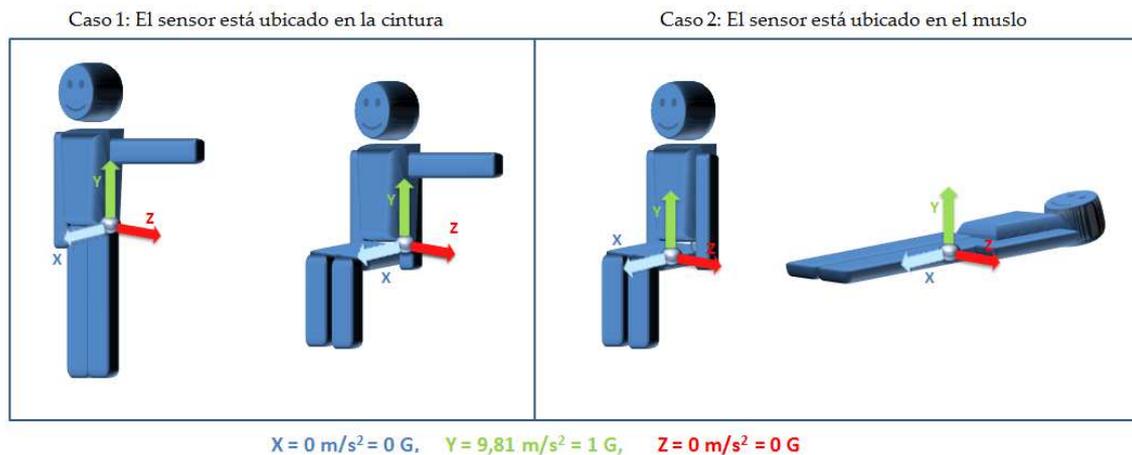


Figura 5.3. *Dos casos conflictivos en el reconocimiento postural con análisis en estática con un acelerómetro triaxial*

En el trabajo de Gjoreski et al. se describe cómo mejora notablemente el análisis estático de posturas mediante varios acelerómetros comparado con el uso de un sólo acelerómetro. Con un solo acelerómetro en la cintura y midiendo el valor del éste, Gjoreski et al. obtienen una precisión del 66% para la postura de 'sentado' y 84% para 'de pie', con 2 acelerómetros (cintura+pierna) obtienen 82% y 83% y con 4 acelerómetros (pecho+cintura+pierna+rodilla) obtienen 99% en cada una. Dado que el acelerómetro devuelve la inclinación relativa al eje de la gravedad de una parte del cuerpo, se pueden interpretar diferentes inclinaciones del cuerpo humano respecto de la gravedad. Por lo tanto, se puede conocer, por ejemplo, el ángulo que mantienen las piernas respecto de la gravedad y respecto el tronco si se hace uso de un acelerómetro en el tronco de la persona. Con más información, el análisis es más fiable. Sin embargo, el análisis estático implica el uso de varios sensores inerciales y, por tanto, pérdida de usabilidad [71].

Varios autores proponen diferentes análisis dinámicos para solucionar el problema de identificar posturas mediante un análisis estático de un único sensor. Sin embargo, antes se debe determinar cuál es el mejor lugar en el cuerpo para emplazarlo. Según Yang et al. y Gjoreski et al. la cintura es un lugar muy cercano al centro de masas del cuerpo humano [71,74] lo que proporciona una buena ergonomía para el paciente ya que el sistema inercial se puede introducir en un cinturón especial como el empleado en la Figura 3.1. Según una encuesta realizada por el grupo de Mathie, los voluntarios que

accedieron a realizar las pruebas encontraron que el lugar más adecuado para portar un sistema inercial de pequeño tamaño es en un lateral de la cintura, por encima de la espina ilíaca antero-superior [120].

Hay numerosos métodos para analizar las señales inerciales mediante análisis dinámico. Najafi et al. emplearon un sistema inercial basado en un giroscopio situado en el pecho. La señal inercial proporcionada era analizada a través de transformadas discretas wavelets (DWT) para poder detectar las posturas[82]. Este análisis frecuencial, junto con la información inercial de un acelerómetro, componían un reconocedor de actividad postural completo basado en árboles de decisión. Con las transiciones posturales obtienen un resultado de sensibilidad y especificidad de 93% y 82% respectivamente para 'sentarse' y un 82% y 94% respectivamente para 'levantarse'. Bidargaddi et al. usa un acelerómetro en la cintura para estudiar las transiciones posturales de 'sentarse' y 'levantarse' a través de las DWTs. El uso de las DWTs ofrece una respuesta relevante en las transiciones posturales que permite determinar la duración de las transiciones posturales. Bidargaddi et al. compara la duración de las PT entre una base de datos con gente sana y una base de datos con gente mayor [161].

Dentro de los estudios dinámicos, Bao y Intille estudiaron las actividades de la vida diaria (DLA) mediante transformadas de Fourier de tiempo reducido (STFT) [162]. Sin embargo emplearon 5 acelerómetros en diferentes partes del cuerpo (brazo, cintura, muñeca, pierna y tobillo) para determinar las DLA con un 84% de precisión. Otro algoritmo relevante es el alineamiento temporal dinámico (DTW). El DTW es un algoritmo que se emplea para cuantificar la semejanza de la forma de una señal con otra señal sin importar la duración que tenga cada una de ellas. Ganea et al., a través de DTW, comparan diferentes patrones de señales con las señales inerciales obtenidas en el tronco humano que desean analizar [163]. Mediante alineamientos temporales de la señal, se construye el 'camino de alineamiento' cuya información es la semejanza entre dos formas de onda sin importar la temporalidad de las señales para identificar 'sentarse' y 'levantarse'. Los resultados obtenidos oscilan entre un 74-96% en especificidad y entre un 30-69% en sensibilidad dependiendo de la selección de plantillas de señales a comparar y dependiendo de si el estudio se realiza en condiciones controladas o no-controladas. Este estudio se lleva a cabo como complemento y mejora

del estudio realizado por Najafi et al. en 2002 [73].

Además de la localización del sensor y la extracción de características, es importante escoger bien el clasificador para poder distinguir las diferentes posturas/actividades. Hay numerosos métodos para clasificar las PT y/o el movimiento humano: a través de algoritmos basados en umbrales, métodos jerárquicos, árboles de decisión, ANN, SVM, modelos Bayesianos, modelos ocultos de Markov, incluso métodos de aprendizaje no supervisado[72]. Dado que en esta tesis se emplean SVM, el estado del arte se enfoca más al reconocimiento de posturas mediante este clasificador. Las SVMs se han utilizado ampliamente en problemas de clasificación de reconocimiento de posturas o actividad con un buen rendimiento y además con la posibilidad de implementación 'online' de manera eficiente [141,142]. Por ejemplo Fleury et al. utilizan las SVMs para determinar algunas actividades de la vida diaria como dormir, descansar, vestirse, comer, uso de servicio, higiene y comunicación. Para ello, combinan la información proporcionada por un acelerómetro y un magnetómetro con varios sensores ubicados en diferentes partes de una casa inteligente. Para el experimento emplean 6 sensores de presencia infrarrojos, 7 micrófonos, 4 sensores de contacto para puertas, 5 cámaras con objetivo de gran angular y un sensor de temperatura y humedad. Los sensores se encuentran distribuidos en las diferentes habitaciones de la casa. A través de un entreno con un kernel polinomial-homogéneo y con un kernel RBF, obtienen resultados de 75.9% y 86.2% de media de precisión respectivamente para las diferentes actividades [164]. En el trabajo de Ataya y Jallon se identifican 6 actividades estacionarias en el tiempo con un 92% de precisión [165]. En este trabajo se pone de manifiesto la dificultad asociada a detectar la posición de 'de pie' y 'sentado', puesto que las señales son, en algunos casos, idénticas. Basándose en la hipótesis de que las personas suelen mantener ángulos en el tronco respecto a la gravedad distintos entre 'sentado y 'de pie', el resultado de estas dos posturas se mantiene en un 91% y 86% de precisión.

Una de las actividades de la vida diaria más habituales es la marcha o caminar. Caminar es una actividad que se puede caracterizar a través de la frecuencia, puesto que esta actividad tiene un comportamiento periódico. La respuesta frecuencial de una señal inercial se puede determinar a través de una STFT con ventanas temporales ajustadas a las frecuencias del caminar. Moore, Mac Dougall y Ondo, determinan que los armónicos

más representativos de la actividad caminar aparecen en el rango de frecuencias de 0.5 a 3Hz colocando un acelerómetro en el tobillo. Najafi, por ejemplo, define que las frecuencias de caminar se presentan entre 0.6 y 5Hz, portando el sensor inercial en el pecho. Barralon et al. por su parte define las frecuencias del caminar entre 0.6 y 2.5Hz con un acelerómetro en el pecho también.

## ***5.2 Conclusiones acerca del estado del arte en detección de actividad***

Existen muchos métodos para poder identificar posturas, y más genéricamente, actividad, como por ejemplo caminar, realizar determinadas tareas en casa o dormir. Entre las metodologías descritas, los sistemas inerciales basados en MEMS son los que proporcionan mayor ergonomía y proporcionan un menor consumo al sistema portable dado su pequeño tamaño.

Dentro del análisis de posturas con MEMS, existen básicamente dos estrategias. La primera consiste en medir la respuesta gravitacional en cada uno de los ejes del acelerómetro con el fin de obtener la orientación de alguna parte del cuerpo. Sin embargo, este método puede confundir posturas, dado que la respuesta puede ser similar en algunas posturas como estar sentado y de pie. Para ello se emplean varios sensores, aumentando los resultados de la identificación de posturas, pero, de lo contrario, disminuyendo la confortabilidad del sistema [71]. La segunda estrategia consiste en analizar las transiciones posturales para determinar la postura final. Dentro de los estudios descritos existen múltiples soluciones, entre las cuales, se emplean sensores en distintas partes del cuerpo, aunque según varios autores, la cintura es la mejor localización para poder ubicar un sistema inercial. Se han descrito algunos trabajos y tipos de clasificadores empleados para determinar posturas y, además, se han descrito algunos de los parámetros para detectar la marcha.

## Capítulo 6

# Detección e identificación de posturas con el algoritmo A45

En este apartado se detalla el algoritmo de transiciones posturales desarrollado bajo esta tesis con el sistema inercial situado entre la parte lateral y anterior de la cintura. Se entiende que en término angular, está situado a 45 grados respecto de la posición frontal de la persona, tal y como indica la Figura 6.1. Es por eso que el algoritmo se denomina 'A45'. Este algoritmo fue validado con pacientes con la PD en el proyecto MoMoPa.

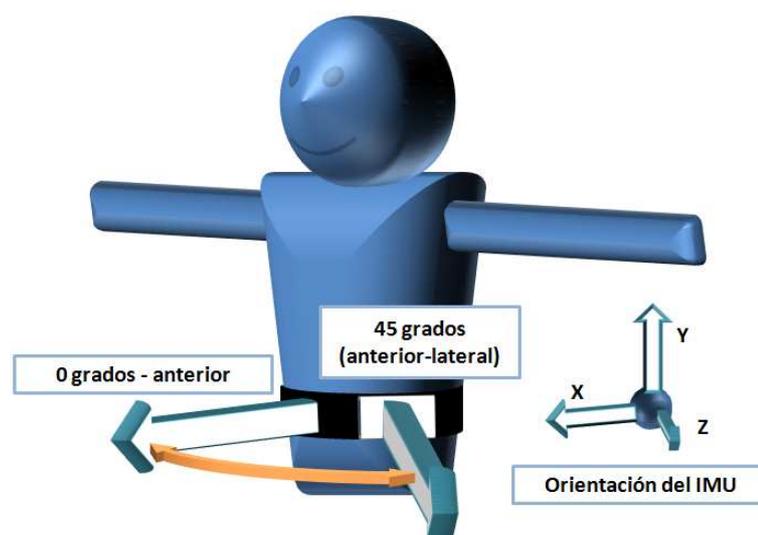


Figura 6.1. Ubicación del sistema inercial en el algoritmo A45

## 6.2 Algoritmo para la detección de posturas A45

Los ejes del acelerómetro están ubicados tal y como muestra la Figura 6.2.



Figura 6.2. Orientación de los ejes del acelerómetro en la posición anterior-lateral

Dado que en ausencia de movimiento no es posible determinar la postura de una persona, se deben detectar e identificar las transiciones posturales que se han hecho anteriormente. De acuerdo con el principio descrito por Najafi et al.[64], una transición postural viene descrita por una respuesta frecuencial elevada en la banda frecuencial entre 0Hz y 0.68Hz una vez eliminada la componente continua. Una opción para obtener la respuesta frecuencial de un tramo de señal es la STFT (Ecuación 6.1). La Figura 6.3 contiene un ejemplo de la respuesta frecuencial de una PT. La STFT está directamente relacionada con la transformada de Fourier clásica, con la diferencia de que la STFT se calcula con una función ventana que se desplaza en el tiempo  $t$ .

$$X(f, t) = \int_{-\infty}^{\infty} w(t - \tau)x(\tau)e^{-i2\pi f\tau} d\tau \quad (6.1)$$

donde  $x(t)$  es la señal que se desea transformar a dominio frecuencial. En este caso la señal de acelerometría entera,  $w(t - \tau)$  es una función definida de la siguiente forma:

$$w(t) = \begin{cases} 1, & t \in [0, \tau] \\ 0, & \text{resto} \end{cases} \quad (6.2)$$

donde  $\tau$  es el tiempo de ventana. En términos discretos, dado que el algoritmo se implementa en un microcontrolador, la STFT se define como:

$$X(m, w) = \sum_{n=-\infty}^{\infty} w[n - m]x[n]e^{-i2\pi fn} \quad (6.3)$$

donde  $n$  es la muestra en el cual se desea analizar la señal,  $m$  es la longitud de la ventana siendo  $x[n]$  la señal de la ventana discreta, y  $w[n - m]$  la función de ventana definida por:

$$w[n] = \begin{cases} 1, & n \in [0, m] \\ 0, & \text{resto} \end{cases} \quad (6.4)$$

Se considera que en una ventana ocurre una PT si:

$$\text{Evento de PT} = \begin{cases} 1, & \text{si } X(m, w)|_{0 < f < 0.68} > U_1 \\ 0, & \text{si } X(m, w)|_{0 < f < 0.68} \leq U_1 \end{cases} \quad (6.5)$$

De esta manera, se obtiene que una ventana de transición postural es aquella cuya potencia de los armónicos por debajo de 0.68Hz y descartando la componente continua ( $f = 0\text{Hz}$ ) es superior a un umbral previamente entrenado ( $U_1$ ), tal y como muestra la Figura 6.3 [166]. El método de entrenamiento de los umbrales se realiza a partir de una SVM con kernel lineal. Por ejemplo, para determinar  $U_1$ , se toman todas las ventanas de una señal de acelerometría que contenga diferentes transiciones posturales. Se le asigna una etiqueta diferente a las ventanas con PT de las ventanas que no contienen una PT. A través de un kernel lineal, se establece un hiperplano que separa las dos clases dentro del espacio de características. El hiperplano que separa las dos clases define el umbral  $U_1$  (Ecuación 6.5).

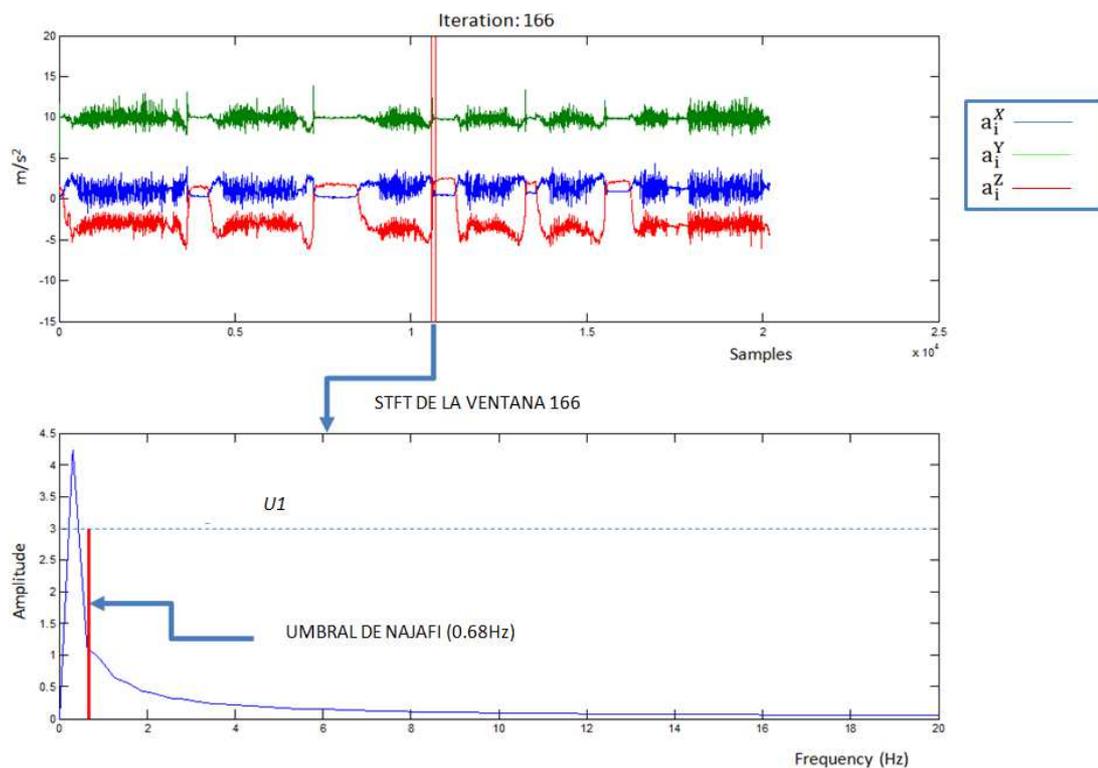


Figura 6.3. Respuesta frecuencial en una transición de postura

Tras detectar una PT, la fase de identificación de la PT se basa en el análisis de las medias de los valores de las señales de aceleración en una ventana. Las transiciones identificadas con el presente algoritmo son: levantarse (Sit to Stand, SiSt), sentarse (Stand to Sit, StSi), inclinarse hacia adelante (Bend Down, BD), reincorporarse de posición inclinada (Bend Up, BU), tumbarse (Lying from Sitting, LS) y reincorporarse de una posición tumbada (Sitting from Lying, SL). En especial, la siguiente condición, nos permite diferenciar un StSi de un SiSt, o bien un BD de un BU:

$$Postura = \begin{cases} StSi, BU & \text{si } \Delta(X_W - Z_W) < -U_2 \\ SiSt, BD & \text{si } \Delta(X_W - Z_W) > U_2 \\ Postura anterior & \text{si } -U_2 < \Delta(X_W - Z_W) < U_2 \end{cases} \quad (6.6)$$

donde  $X_W = \frac{\sum_{i=1}^n a_i^X}{n}$ , y  $Z_W = \frac{\sum_{i=1}^n a_i^Z}{n}$ .  $a_i^X$  y  $a_i^Z$  son los valores de las señales de aceleración en la muestra  $i$  del eje X y eje Z respectivamente.  $X_W$  y  $Z_W$  son los valores medios de la aceleración de la ventana número  $W$  del eje X y Z respectivamente del acelerómetro.  $n$

es el número de muestras que contiene la ventana.  $U_2$  es un umbral calculado a partir de un entrenamiento de datos con diferentes patrones pertenecientes a transiciones posturales y pertenecientes a otras posturas/actividades. La metodología se explica en la siguiente sección.

La Ecuación 6.6 se puede explicar por la interacción de los ejes con la gravedad y el cambio de orientación que éstos adaptan cuando la persona se sienta y se levanta. Superando el umbral  $-U_2$ , la persona realiza una transición de StSi o BU puesto que el eje Z del acelerómetro tiende a orientarse hacia arriba al final de la transición, opuesto a la gravedad. Este hecho hace que  $\Delta(X_W - Z_W)$  sea positiva al ser  $Z_W$  elevada respecto a la muestra  $Z_{W-1}$ . Lo contrario ocurre generalmente con  $X_W$ , sin embargo, el peso que recae sobre  $X_W$  depende de la anatomía de la persona, y de cómo esté orientado el sensor. En una persona obesa, los ejes X y Z tienden a orientarse hacia el suelo, mientras que en una persona delgada, los ejes X y Z tienden a estar perpendiculares al eje de la gravedad.

En la mayoría de personas el movimiento más relevante ocurre en  $Z_W$ , no obstante en algunas personas la variación o dinámica de la señal se reparte entre  $X_W$  y  $Z_W$ , siendo dinámicas opuestas y por lo tanto dando picos relevantes en  $\Delta(X_W - Z_W)$ . En la Figura 6.4 se muestra la respuesta de la característica  $\Delta(X_W - Z_W)$  donde una transición postural de sentarse y levantarse hace cambiar con relevancia a las señales  $a_i^X$  y  $a_i^Z$ .

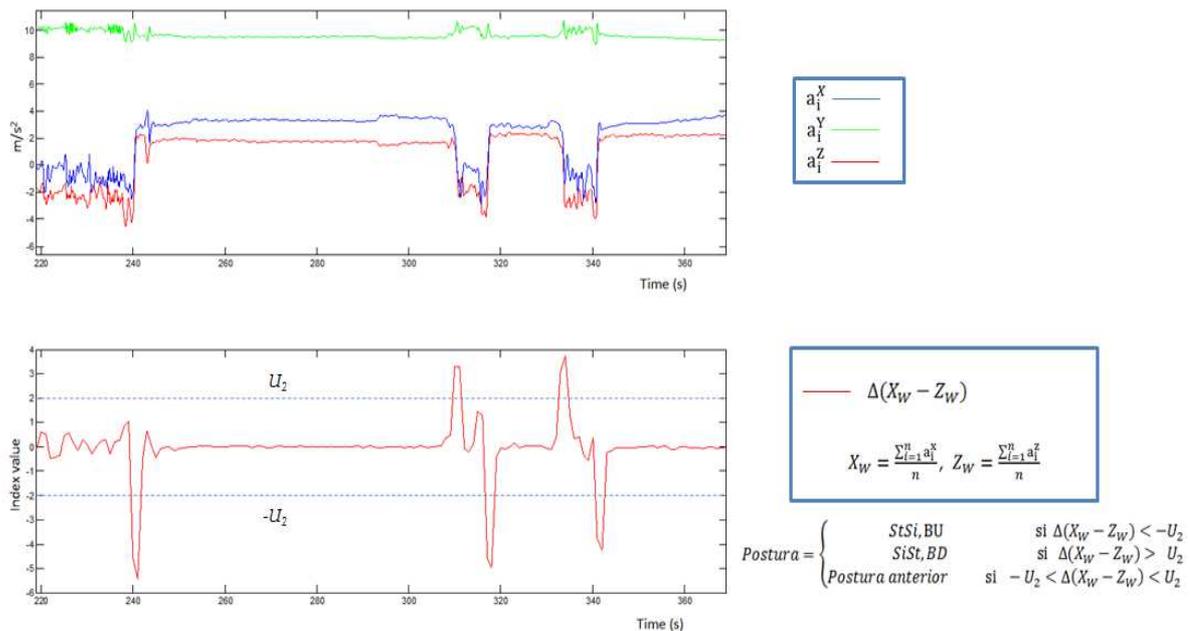


Figura 6.4. Respuesta de la característica  $\Delta(X_W - Z_W)$

Cuando se realiza la transición contraria (SiSt o BD), los movimientos que realiza la persona son opuestos a cuando se hace una PT de StSi o BU. En cualquier otro caso, ya sea un salto, movimiento brusco u otras actividades dinámicas como caminar o correr,  $\Delta(X_W - Z_W)$  se mantiene muy cerca de 0.

Para detectar la posturas ‘tumbado’, se observa la media de los valores del eje Y ( $a_1^Y$ ) dentro de una ventana, formalmente  $Y_W = \frac{\sum_{i=1}^n a_i^y}{n}$ . Si este valor sobrepasa un umbral previamente entrenado,  $U_3$  el algoritmo establece que la persona está tumbada. La condición para que el algoritmo determine que una persona está tumbada es que provenga del estado ‘sentado’. Si el estado anterior era ‘de pie’, se intuye que la persona solamente se ha inclinado hacia adelante.

Con las reglas de decisión definidas, se realiza una máquina de estados que se muestra en la Figura 6.5. En esta máquina de estados es muy importante conocer cuáles son las condiciones iniciales, puesto que de ello depende decidir entre una transición u otra de acuerdo con la Ecuación 6.6. Las condiciones iniciales vienen marcadas por una variable que cambia en función de los eventos que ocurren a lo largo del algoritmo. Esta variable, llamada ‘Postura’, puede tener 4 valores: 0=‘sentado’, 1=‘de pie’, 2=‘tumbado’, 3=‘inclinado’. A continuación, se hace la captura de la ventana. Hasta que no se complete no se puede realizar ninguna otra operación. En cada ventana capturada se efectúa una STFT que nos permite conocer, en primer lugar, si se ha realizado una PT en esa ventana de datos. En caso negativo, se espera y se realiza una nueva captura de ventana. Esta vez hay que esperar la mitad del tiempo, puesto que el ventaneado se realiza al 50%. En consecuencia, la mitad final de la ventana ya calculada pertenece ahora a la mitad inicial de la ventana que se va a calcular y sólo es necesario capturar media ventana más.

En caso de que se obtengan armónicos por debajo de los 0.68 Hz superiores a  $U_1$ , se observa  $Y_W$ , la cual nos permite conocer, por una parte, si la persona se ha tumbado o se ha reincorporado o, por otra parte, si ha realizado una PT de ‘sentarse’, ‘levantarse’, BU o BD. En el caso de que la dinámica de  $Y_W$  cruce el umbral  $U_3$  de forma ascendente y la persona estaba ‘tumbada’, se considera que la persona venía de una posición ‘tumbada’, y se ha reincorporado, quedando como postura final ‘sentado’. En el caso contrario, si se cruza el umbral  $U_3$  de forma descendente y la persona estaba sentada, se determina que

la persona se ha tumbado. Ahora bien, Si la persona se mantiene erguida y hay un evento de PT pueden haber pasado una de cinco acciones posibles, a) la persona se ha sentado, b) la persona se ha levantado, c) la persona se ha inclinado, d) la persona se ha reincorporado de inclinarse o e) la persona ha saltado. El caso e) se descarta, puesto que no forma parte del protocolo de pruebas, y dado que el algoritmo se valida con pacientes con la PD, no se considera una acción que efectúen en la DLA. En este instante, la relación de ejes del acelerómetro de la Ecuación 6.6 nos permite conocer si por una parte la persona se ha sentado o ha realizado una acción de BU, y por otra parte si la persona ha realizado una acción 'levantarse' o de BD.

Para discriminar un 'sentarse' de BU, al igual que 'levantarse' de BD se observa la variable 'Postura', que nos indica qué postura precede a la PT que se está analizando. Si se busca distinguir entre 'sentarse' y 'reincorporarse' ( $\Delta(X_W - Z_W) < -U_2$ ) y se viene de 'Postura' = 1 (la persona estaba 'de pie'), entonces se determina que la persona se ha sentado. De otra manera, se determina que la persona se ha reincorporado de estar inclinado (BU). Por otra parte, si se busca distinguir entre 'levantarse' y 'inclinarse' ( $\Delta(X_W - Z_W) > U_2$ ) y se viene de 'Postura' = 1, entonces se determina que la persona se ha inclinado. De otro modo se determina que la persona se ha levantado.

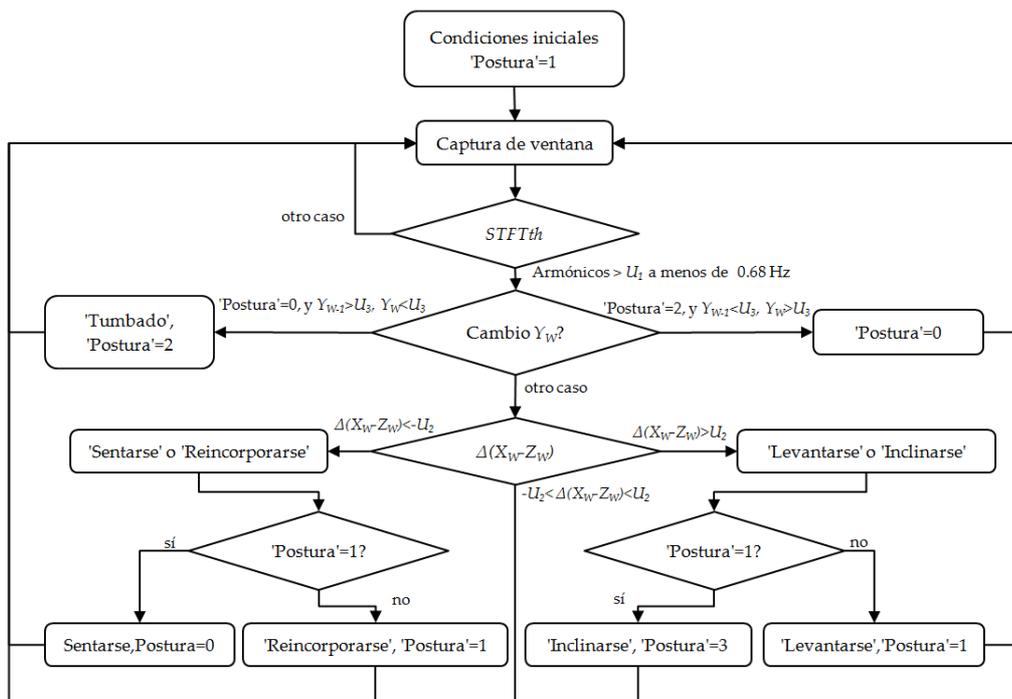


Figura 6.5. Algoritmo de identificación de posturas A45

### 6.3 Experimentos de evaluación del algoritmo A45

La validación del algoritmo descrito en el apartado anterior se ha realizado mediante 2 experimentos. Se han reunido 2 conjuntos de datos, el primero de ellos pertenecientes a personas sanas, y el segundo de ellos a pacientes con PD. Para elaborar la base de datos se ha empleado el IMU desarrollado para esta tesis y descrito en el Capítulo 3. Los datos se han guardado en una tarjeta  $\mu$ SD y se han tratado de forma *offline*.

El primer grupo de datos, con personas sanas, se ha realizado en el CETpD, y está formado por 36 personas (22 hombres y 14 mujeres, de entre 21 y 56 años, con 35.77 años de media y 9.58 años de desviación estándar. Todos los voluntarios se han sometido a una serie de pruebas que consistían en efectuar diferentes actividades de la vida diaria, así como caminar, sentarse, levantarse, tumbarse y estar de pie. Cada voluntario ha realizado el protocolo de pruebas 2 veces, retirando el cinturón con el sistema inercial al acabar la primera prueba, y colocándose él mismo de nuevo el cinturón para ejercer de nuevo la prueba. De esta forma el sistema inercial siempre estará como mínimo ligeramente orientado de otra forma. Cada una de las pruebas tuvo una duración aproximada de 3-4 minutos.

Todas las pruebas fueron grabadas con video-cámara, siendo éste el '*gold standard*' para etiquetar. En total se analizaron 625 transiciones, de las cuales 80 de ellas se emplearon para establecer los umbrales  $U_1$ ,  $U_2$  y  $U_3$ . Se han tomado 5 voluntarios al azar con el fin de obtener los umbrales mediante el proceso de entrenamiento. El resto se han empleado para evaluar el clasificador. De estas 80 transiciones, 40 pertenecen a SiSt y StSi, 20 pertenecen a inclinarse, y las otras 20 pertenecen a tumbarse. Por otro lado, de las 625 transiciones posturales, se han utilizado para evaluar 545 transiciones. 311 pertenecen a 'sentarse' y 'levantarse', 124 pertenecen a SL y LS, y las otras 110 pertenecen a BU y BD.

El segundo protocolo de test se ha empleado únicamente para evaluar el algoritmo. La base de datos se ha elaborado con datos inerciales pertenecientes a 8 pacientes con PD que colaboraron con el proyecto nacional MoMoPa [15]. Los pacientes efectúan la prueba estando en estado 'ON' y en estado 'OFF'. El protocolo consiste en realizar un pequeño

circuito, que consiste en una prueba ‘timed up & go’ [167], e incluye caminar, sentarse y levantarse. Toda la base de datos también fue grabada con video-cámara de forma que los clínicos lo emplearan como ‘gold standard’ para poder etiquetar las actividades y los trastornos motores que padecían los pacientes [133]. Se analizan un total de 176 transiciones, de las cuales 88 son SiSt, y las otras 88 son StSi. Además, los cinturones que llevan los pacientes incorpora dos sistemas 9x2, uno situado como marca la Figura 6.1 y el segundo como marca la Figura 7.1, para realizar comparaciones de señales en futuros experimentos.

Tanto en el primer grupo de datos como en el segundo se establecen unas directrices de análisis de la señal. Se parte de que el sensor está situado en la posición anterior-lateral (Figura 6.1). La señal se muestrea a 40 Hz, siendo suficiente para poder analizar las actividades y transiciones posturales básicas de la vida diaria [119]. Cada ventana temporal contiene 128 muestras por lo que la longitud de ventana es de 3.2 segundos, suficiente para cubrir las transiciones posturales las personas mayores [149]. En otro estudio, no obstante, se menciona que una transición postural puede ser de 2 segundos de duración para las personas mayores [153]. Finalmente para el análisis, las ventanas se solapan al 50% con el fin de no perder información relevante entre ventanas.

#### ***6.4 Resultados y discusión del algoritmo de posturas A45***

Una vez se establecen los umbrales  $U_1$ ,  $U_2$  y  $U_3$  a través de SVM con kernel lineal, se evalúa el algoritmo descrito en la Figura 6.5 con las 31 personas escogidas al azar para evaluar. En la Tabla 6.1 se muestran los resultados de sensibilidad y especificidad. Se han evaluado un total de 545 transiciones (156 SiSt y 155 StSi, 55 BU y 55 BD, 62 LS y 62 SL). Por otra parte, la Tabla 6.2 muestra los resultados de la evaluación del algoritmo de la Figura 6.5 para los 8 pacientes con PD. En total hay 88 episodios de SiSt y 88 episodios de StSi.

Transición Postural	Predicciones		N. Transiciones	Resultados		
Levantarse (SiSt)	TN	359	156	Sensibilidad	86.5	
	TP	135				
	FN	21			Especificidad	99.2
	FP	3				
Sentarse (StSi)	TN	359	155	Sensibilidad	87.1	
	TP	135				
	FN	20			Especificidad	98.6
	FP	5				
Reincorporarse de inclinado (BU)	TN	442	55	Sensibilidad	94.6	
	TP	52				
	FN	3			Especificidad	99.6
	FP	2				
Inclinarse (BD)	TN	446	55	Sensibilidad	87.3	
	TP	48				
	FN	7			Especificidad	99.6
	FP	2				
Estirarse (LS)	TN	432	62	Sensibilidad	100	
	TP	62				
	FN	0			Especificidad	100
	FP	0				
Reincorporarse desde tumbado (SL)	TN	432	62	Sensibilidad	100	
	TP	62				
	FN	0			Especificidad	100
	FP	0				

Tabla 6.1. Resultados del algoritmo A45 para voluntarios sanos

Transición Postural	Predicción		N. Transiciones	Resultados		
Levantarse (SiSt)	TN	214	88	Sensibilidad	93.2	
	TP	82				
	FN	6			Especificidad	96.3
	FP	8				
Sentarse (StSi)	TN	214	88	Sensibilidad	92	
	TP	81				
	FN	7			Especificidad	95.5
	FP	10				

Tabla 6.2. Resultados del algoritmo A45 para pacientes con PD

El algoritmo detecta las transiciones con una especificidad por encima del 95.5%. Sin embargo, las medidas de sensibilidad decrecen especialmente en BD, StSi y SiSt, cuyas sensibilidades son ligeramente inferiores respecto al resto de PT, siendo del 86.5% de

sensibilidad el resultado más bajo. Estos resultados se deben a que algunos pacientes no realizan la actividad de inclinarse con suficiente rapidez como para que la respuesta frecuencial alcance el umbral  $U_1$ . En este estudio se ha impuesto que la condición para considerar una PT de inclinarse es que la PT sea detectada por la STFT. Sin embargo, inclinarse puede detectarse también con  $a_i^y$  proponiendo el mismo  $U_3$  como umbral definido para detectar BU y BD. La bajada de los resultados en SiSt y StSi viene provocada porque los pacientes se han de sentar en la cama en una de las pruebas. Algunos voluntarios se dejan caer, provocando grandes rebotes en la señal y en  $\Delta(W_x - W_z)$ , provocando la no detección de la PT.

Un problema detectado en este algoritmo es la localización del sensor ya que depende fuertemente de la anatomía de la persona. Se han discriminado dos casos donde el voluntario no se ajusta adecuadamente el cinturón del sistema inercial. En estos dos casos el sistema quedaba orientado con el eje Y del acelerómetro perpendicular al eje de la gravedad cuando en realidad están orientados (idealmente) en la misma dirección. Este problema provoca que el algoritmo determine que una persona está ‘tumbada’, cuando la persona está en ese momento ‘de pie’.

En términos generales, el algoritmo responde muy bien tanto para pacientes con PD como para voluntarios, lo cual indica que las PT no dependen de I) el tipo de usuario (sano o con la PD) II) del estado terapéutico del paciente con PD, puesto que se ha realizado la base de datos con pacientes en distintos estados motores dentro de la PD dando resultados similares entre los estados motores del PD.

## 6.5 Conclusiones del algoritmo A45

El algoritmo A45 es una estructura jerárquica de clasificadores que determina las posturas de una persona mediante el análisis de transiciones posturales. El sistema inercial está localizado en la cintura, y se encuentra en la parte anterior-lateral de ésta. Se ha realizado un entrenamiento mediante SVM para obtener los umbrales que forman las reglas de decisión del algoritmo.

Para detectar una PT, se emplea la STFT por la que mediante una respuesta frecuencial, el sistema determina si ha ocurrido una PT o no. En caso negativo, se asume

que la postura mantenida es igual que la postura analizada anteriormente. En caso positivo, se observa  $Y_W$  para determinar si la persona está en una postura tumbada, o bien está sentado o de pie. En el segundo caso, se ejecuta la Ecuación 6.6, que junto a la variable 'Postura', determina la postura final de la persona.

El algoritmo propuesto se ha evaluado sobre una base de datos con personas sanas, y una base de datos de personas con la PD. En ambos casos, los resultados son significativos, mostrando una buena respuesta del algoritmo con una sensibilidad superior a 86%, y una especificidad de más de 98%.

## Capítulo 7

# Detección e identificación de posturas con el algoritmo A90

En este apartado se detalla el algoritmo basado en inteligencia artificial para detectar e identificar posturas y con el sistema inercial localizado en el lateral de la cintura tal y como se muestra en la Figura 7.1. A diferencia de la ubicación del sistema del capítulo anterior, en este caso, se ha optado por escoger una posición descrita por Mathie et al. como la más cómoda [120], y una posición más concreta y precisa para obtener las bases de datos en los proyectos HELP [16] y REMPARK [18].

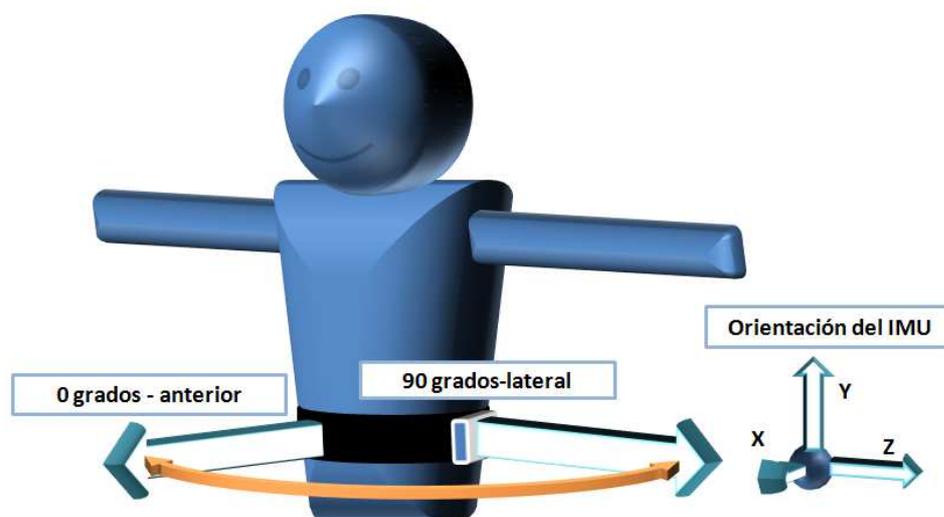


Figura 7.1. Ubicación del sistema inercial en el algoritmo A90

El algoritmo implementado es una estructura jerárquica de clasificadores, que combina técnicas de análisis dinámico como el apartado anterior (STFT) con SVMs. Las SVMs se han empleado para clasificar 11 actividades, entre ellas, SiSt, StSi, BU, BD, LS, SL como actividades correspondientes a PT. Por otro lado se clasifican las posturas de ‘estar de pie’, ‘sentado’, ‘tumbado’, ‘caminar’, ‘inclinado’. A diferencia del algoritmo A45, se evalúan los estados estáticos, y además, se incluye la actividad ‘caminar’.

Una de los problemas de la ejecución del algoritmo A45 con el sensor ubicado en lateral de la cintura, es que muchas PT de ‘sentarse’ y ‘levantarse’ no son diferenciables mediante la característica de la Ecuación 6.6. Muchas PT son prácticamente idénticas, pero otras conservan la relación entre los ejes X y Z. En la Figura 7.2 se observa la respuesta inercial del acelerómetro en dos PT: ‘Levantarse’ y ‘Sentarse’. Las dos respuestas de la izquierda representan la respuesta inercial con el sistema inercial colocado en la posición anterior-lateral (Posición 1), mientras que en la derecha corresponde a la respuesta inercial con el sistema ubicado en la posición lateral (Posición 2). Una característica visible en la Posición 1 es el cambio de nivel que sufre el eje X al final de la PT. Sin embargo este cambio de nivel no ocurre en la Posición 2. Esta evidencia provoca que el algoritmo A45 se deba alterar. Se debe rehacer la regla de decisión para que tenga en cuenta estos nuevos casos.

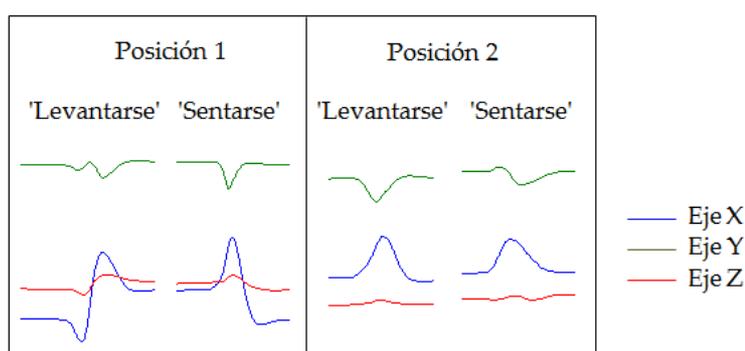


Figura 7.2. Respuesta inercial de dos PT en dos posiciones diferentes

Los parámetros del clasificador se han ajustado para que el algoritmo funcione en cualquier persona. Se han establecido 2 grupos de datos para analizar y evaluar el algoritmo. El primero con voluntarios sanos, y el segundo con pacientes con la PD. La

base de datos correspondientes al primer conjunto de datos se ha hecho en un protocolo de pruebas diferente al mencionado en el apartado 6.3, con otras personas y el sistema ubicado como marca la Figura 7.1 Se ha realizado una validación del algoritmo con la misma base de datos de pacientes con la PD utilizada para validar el algoritmo A45. La base de datos es compatible con el algoritmo A90 debido a que esta base de datos se realizó con dos sistemas, el primero situado en la ubicación de la Figura 6.1 y el segundo en la ubicación indicada en la Figura 7.1. El algoritmo desarrollado logra resultados de sensibilidad por encima de 97% y de especificidad por encima del 84%. Los resultados del segundo grupo de datos también reflejan unos valores similares.

## 7.2 Descripción del algoritmo A90

El principal objetivo del algoritmo es poder identificar con un acelerómetro triaxial situado en la cintura 11 posturas divididas en 2 grupos. El primer grupo son las posturas estáticas ('de pie', 'sentado', 'inclinado' y 'tumbado') y el segundo grupo las dinámicas ('levantarse' (SiSt), 'sentarse' (StSi), 'caminar', 'inclinarse' (BD), 'reincorporarse de inclinado' (BU), 'tumbarse' (SL) y 'reincorporarse de tumbado' (LS)).

Dadas unas condiciones iniciales conocidas, por ejemplo 'de pie', aunque se puede empezar desde cualquier postura, el algoritmo de identificación de posturas realiza un análisis de ventanas a través de las señales del acelerómetro. Cada ventana de datos se solapa al 50% como en el algoritmo A45. Primeramente, se realiza una STFT (Ecuación 6.5) para determinar si hay o no movimiento. Conocer la respuesta frecuencial nos permite distinguir si hay una PT o no. Tras confirmar que ha ocurrido una PT, se comprueba el valor  $Y_W$ . En caso de que se mantenga en un valor del umbral establecido para considerar que la persona se mantiene erguida, se determina que es una transición SiSt o StSi. Un modelo de SVM con kernel gaussiano determina si la transición ha sido un StSi o SiSt. A diferencia del kernel lineal empleado para obtener los umbrales que marcan las reglas de decisión, el kernel gaussiano nos proporciona una mayor generalización del problema, dado que el problema de separar SiSt y StSi es de mayor complejidad que el de establecer umbrales.

Por otro lado, en este algoritmo  $U_3$  pasa a ser llamado  $Y_{th}$ . Se define verticalidad

cuando  $Y_W > Y_{th}$ . Si la persona no mantiene la verticalidad ( $Y_W < Y_{th}$ ), se determina que, o bien ha ocurrido una transición de ‘inclinarse’, o bien de ‘tumbarse’. El diferencial del eje X, definido como  $a'_i{}^x = a_i^x - a_{i-1}^x$  donde  $i$  es el número de muestra, determina si la persona se ha tumbado o se ha inclinado. El eje X correspondería al eje anterior del IMU si el sistema inercial está ubicado como la Figura 3.1. La postura final determinada por  $a'_i{}^x$  establece un nuevo estado, que será evaluado en el futuro cuando haya ocurrido otro evento en el sistema inercial, en otras palabras, cuando  $Y_W$  permanezca por encima del umbral  $Y_{th}$ . En ese caso se produce el proceso inverso y se analiza el estado establecido anteriormente. Si la persona estaba inclinada, se asume que volverá a estar ‘de pie’. Sin embargo, si la persona estaba tumbada, se asume que la postura adoptada es ‘sentado’. Por esta razón, cuando el algoritmo determina un estado después de analizar varias características, este estado es almacenado y analizado en la siguiente iteración o evento del algoritmo.

El algoritmo es una estructura jerárquica de clasificadores tal y como se muestra en la Figura 7.3.  $Y_W$  es la media de los valores de  $a_i^y$  en una ventana, y por tanto,  $Y_{W-1}$  es la media de  $a_i^y$  en la ventana previa analizada.  $STFT_{th}$ ,  $With$ ,  $IAA_{th}$ ,  $JX_{th}$  y  $Y_{th}$  son los umbrales definidos en la Sección 7.3.  $y_i$  es la salida del clasificador ‘Levantarse’-‘Sentarse’ (Sit-to-Stand and Stand-to-Sit, SiSt-StSi).

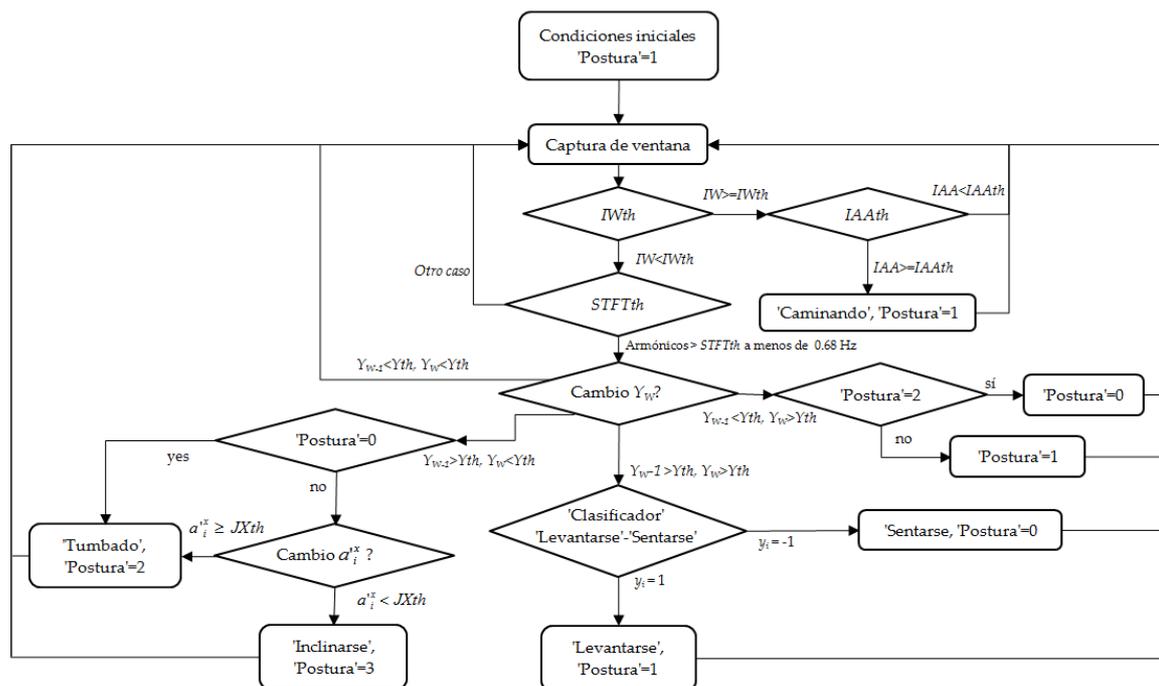


Figura 7.3. Algoritmo de posturas A90

La estructura jerárquica de clasificadores está compuesta de 5 clasificadores que son descritos en la siguiente sección. A continuación se describen brevemente:

- El clasificador STFT, que detecta si ha ocurrido una PT, tal como se ha descrito en el capítulo anterior.
- Clasificador de verticalidad, que determina si una persona está en una posición tumbada o erguida.
- El clasificador de 'tumbado'-'inclinado', cuya función es distinguir una postura tumbada de una inclinada mediante el diferencial del eje X del acelerómetro.
- El clasificador de caminar, que nos indica si una persona está caminando o no. Este clasificador depende de dos índices, uno de ellos y mediante la STFT, determina si la persona está caminando, el otro nos excluye algunos casos que se pueden dar como falsos positivos a través de la integral de los valores del acelerómetro en una ventana (Absolute Integration Accelerometer, IAA) [168].
- Clasificador SiSt-StSi, el cual realiza la clasificación entre sentarse y levantarse mediante una SVM con kernel gaussiano.

Los primeros 4 clasificadores, determinan posturas o actividad mediante clasificación basada en umbrales. Estos umbrales se han optimizado mediante SVM con kernel lineal. Cada clasificador tiene fijado un umbral, excepto el clasificador de caminar, que está basado en 2 umbrales. Además, el clasificador de SiSt-StSi también está basado en otro umbral que se fija previamente (Sección 7.4).

### 7.3 Umbrales del algoritmo A90

Para la detección de PT, se sigue la metodología descrita en el apartado 6.2. Se analiza la suma de la potencia de los armónicos en  $a_i^y$  y  $a_i^x$  por debajo de 0.68Hz (Banda PT) eliminando la componente continua. Se considera que hay una PT cuando esta suma sobrepasa el umbral ( $STFTth$ ) tal y como indica la Ecuación 6.5, pero esta vez sustituyendo  $U_1$  por  $STFTth$ . Este umbral será parecido a  $U_1$ , siendo entrenado nuevamente con la nueva base de datos ubicando el sistema inercial en la nueva posición.

Para determinar si una persona está caminando, se analizan los armónicos de la banda del caminar (Walking Band,  $WB$ ). Dado que todos los algoritmos tienen como objetivo analizar también pacientes con PD, se toma la banda de frecuencias definida por Moore et al. cuyo trabajo estudia el FoG basándose en diferentes bandas espectrales, una de ellas la de caminar definida entre 0.5 y 3Hz. En este problema, la  $WB$  y la banda de PT se solapan, por lo cual la banda de caminar se redefine entre 0.68 y 3Hz. Los armónicos sin embargo son extraídos de  $a_i^y$ , igual que Moore et al., puesto que el eje vertical del acelerómetro es el que más amplitud presenta cuando una persona está caminando.

Por otro lado se ha observado que algunas PT se ejecutan de forma rápida, haciendo que el voluntario al sentarse provoque rebotes en la cama, o bien, al no haberse sentado correctamente, decide colocarse mejor. Estas PT, pueden presentar armónicos en la banda del caminar debido a que los rebotes provocados por la cama o sofá repercuten en señales inerciales por encima de los 0.68Hz definidos como umbral entre la banda de PT y la banda  $WB$ . No obstante, los armónicos principales siguen correspondiendo a la banda de PT. El hecho de que puedan presentar armónicos en la banda del caminar puede provocar falsos positivos en el algoritmo. Para evitarlo se define un índice basado en la relación de la suma de armónicos de la  $WB$  dividido por los armónicos de la banda de PT. Este índice es distinguido como Índice de caminar (Walking Index,  $WI$ ). El umbral que clasifica si una persona camina se denomina  $WTth$ . Este índice no es el único que corrige la posibilidad de encontrarse falsos positivos. Dado que existe la posibilidad de que tanto  $WB$  como la banda de PT sean muy bajos, estando ambos índices cercanos a 0.

$WI$  puede dispararse, y dar falsos positivos en un movimiento prácticamente estático. Para ello se introduce el índice de  $IAA$ , que ha demostrado estar correlacionado con el gasto energético debido al movimiento, y que se define de forma continua mediante el índice  $IAAc$ :

$$IAAc = \int_{i=0}^T |a_i^x| dt + \int_{i=0}^T |a_i^y| dt + \int_{i=0}^T |a_i^z| dt \quad (7.1)$$

donde  $T$  es la longitud de la ventana en muestras. La formulación discreta del índice viene dada por:

$$IAA = \frac{1}{N} \sum_{i=1}^N [ |a_i^x| + |a_i^y| + |a_i^z| ] \quad (7.2)$$

donde  $N$  es la longitud de ventana. Por tanto, un valor del índice  $WI$  elevado, pero bajo en índice  $IAA$ , no se considera un episodio de caminar. El umbral previamente obtenido tras un proceso de entrenamiento que define si existe movimiento significativo para caminar se denomina  $IAAth$ .

El umbral  $Yth$  tiene como función determinar la verticalidad del tronco de una persona a través de la comparación de  $Yth$  con  $Y_w$ . Si un valor  $Y_w$  está por debajo del umbral  $Yth$ , se considera que la persona está en una posición tumbada. De otro modo, si  $Y_w$  está por encima de  $Yth$ , se considera que la persona está sentada, caminando, o de pie.

Finalmente, el umbral que distingue si una persona ha realizado una transición postural asociada a tumbarse, o bien a inclinarse se denomina  $JXth$ . Cuando una persona se inclina hacia adelante, la dinámica de  $X_w$  es negativa de acuerdo con la orientación de la Figura 3.1 debido a la gravedad. El diferencial del eje  $X$  ( $a_i^x$ ) es un buen indicador para conocer la trayectoria del cuerpo respecto a la gravedad después de un cambio de orientación en el eje  $Y$ . Por tanto el valor de  $a_i^x$  es comparado con  $JXth$ .

## 7.4 Diseño del clasificador SiSt-StSi en el algoritmo A90

Este apartado describe la metodología para poder identificar las dos PT. El clasificador SiSt-StSi, solo se ejecuta cuando una ventana de señal inercial es candidata a ser una PT de uno de estos dos tipos. Las condiciones para que se ejecute este clasificador son que la persona mantenga una  $Y_w > Y_{th}$  y que se haya producido una PT a través de la STFT.

Así pues, si la ventana actual determina que ha ocurrido una PT, y se mantiene la verticalidad, se analizan la ventana actual y la anterior. Si se analizan las dos ventanas, se analiza la transición completa sin perder información inercial puesto que la transición puede quedar entre dos ventanas.

Para analizar las dos ventanas se utiliza una detección de la dinámica de la señal a partir del diferencial del eje Y ( $a'_i = a_i - a_{i-1}$ ). Con este fin se introduce un nuevo umbral que determinará si existe movimiento en una parte de la señal. Este umbral se define como umbral dinámico (Dynamic threshold,  $DT$ ) y se representa en la Figura 7.4.  $Y'_w$  es el diferencial del eje Y ( $a'_i$ ) y está definido como  $Y'_w = \frac{\sum_{i=1}^n a'_i}{n}$ .  $DT$  se determina como un valor que satisface la Ecuación 7.3 e indica el umbral en el cual se considera que empieza y acaba la PT. Los tiempos que marcan el inicio y final de la PT son  $t_r$  y  $t_s$  respectivamente que satisfacen la Ecuación 7.3.  $Y_{MAX}$  es el valor medio de todos los valores máximos de  $|a'_i|$  del 70% de PT's escogidas al azar, ya sean PT de 'Levantarse' o 'Sentarse'.

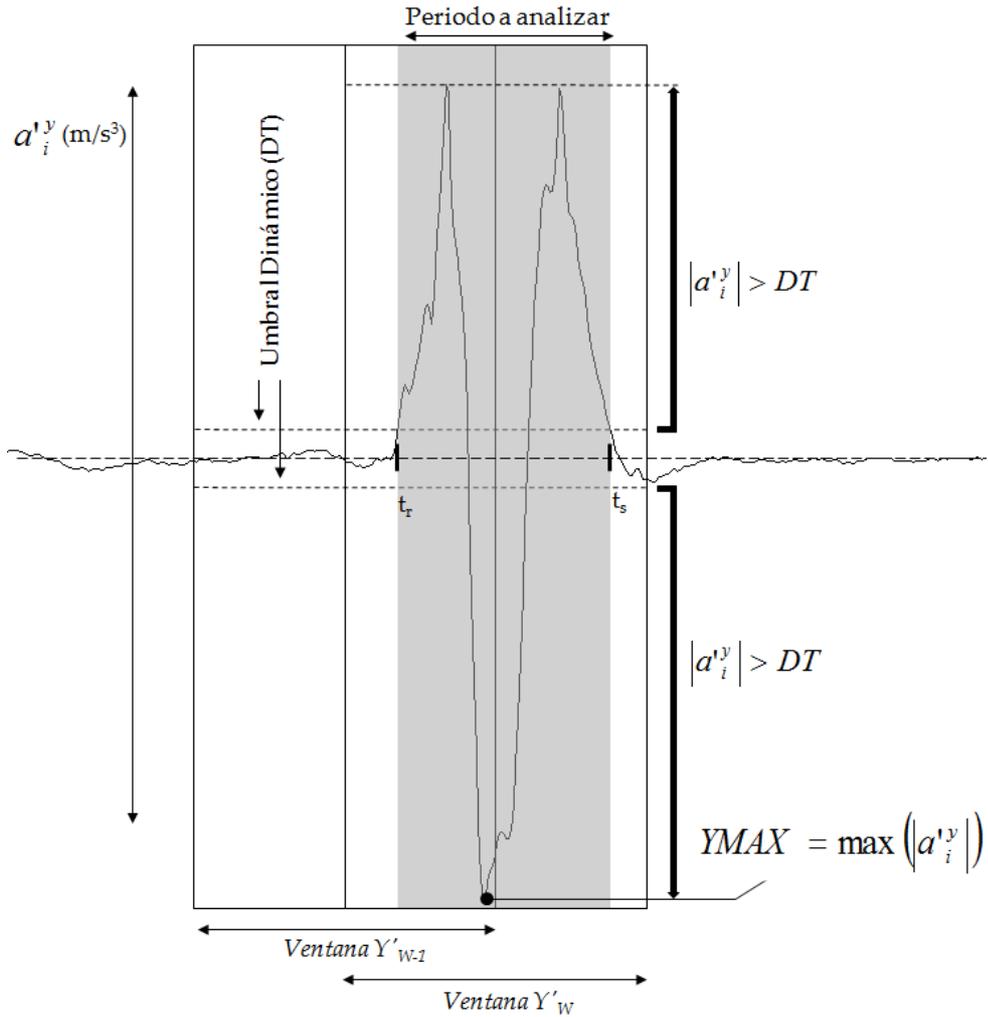


Figura 7.4. Análisis de la transición de posturas mediante el DT

Para determinar  $DT$ , se realiza un barrido de valores con el fin de fijar el valor óptimo para  $DT$ . Para cada valor de  $DT$  se obtiene una precisión correspondiente a la validación del clasificador SiSt-StSi. Con  $DT=0$ , se considera toda la ventana como entrada de la SVM, mientras que un valor por encima de  $YMAX$  significa que ningún valor es significativo. Por tanto se interpreta que no ha ocurrido ninguna PT puesto que ningún valor satisface la Ecuación 7.3. El barrido se realiza desde  $DT = 0.05 \cdot YMAX$  hasta  $DT = 0.95 \cdot YMAX$  con  $Q$  valores.

$$\forall t_i \in t_r, \dots, t_s \quad |a_i^{y}| > DT \quad (7.3)$$

$$\text{Sujeto a } r, s \in \mathbb{N}, \quad r < s$$

Por otro lado, las características de las entradas de la SVM son  $a_i^x$ , que es la aceleración del eje X o anterior, y  $M_i = \sqrt{a_i^{x^2} + a_i^{y^2} + a_i^{z^2}}$ , que es la magnitud de los 3 ejes de aceleración. El espacio de características de entrada para la SVM se define como  $x_i = [a_r^x, \dots, a_s^x, M_r, \dots, M_s]$ . La longitud  $t_r, \dots, t_s$  suele ser de aproximadamente 100 muestras, dependiendo del  $DT$  por lo que se considera gran cantidad de entradas para el modelo de la SVM. Por esa razón, y para reducir la carga computacional del algoritmo, el vector  $x_i$  con  $2 \cdot (s + r - 1)$  muestras se remuestrea para tener longitud  $2 \cdot P$  ( $P$  es el número de muestras por característica), reduciendo considerablemente la carga computacional.

### 7.5 Experimentos de evaluación del algoritmo A90

De forma parecida a las experimentaciones del algoritmo A45, los experimentos se han realizado con el IMU descrito en el Capítulo 3 de esta tesis. Se ha elaborado una nueva base de datos formada por 31 personas, la gran mayoría distintas a las que realizaron la base de datos anterior. Sin embargo, esta vez se sigue la metodología descrita por Samà et al. y empleada en el proyecto de ámbito europeo REMPARK [18,116,169]. La base de datos se graba con una videocámara de un teléfono móvil con el fin de obtener un gold-standard válido para poder etiquetar a posteriori. Los datos de la videocámara se sincronizan con el sistema inercial 9x2. Para sincronizar se emplea una tablet (DELL Latitude ST), que a través de una aplicación basada en Labview, envía la hora recogida por los servidores Network Time Protocol (NTP) al sistema inercial y al teléfono móvil. El 9x2 recoge la hora, minuto y segundo e inmediatamente se escribe en el registro del RTCC para que empiece la cuenta. El sistema inercial, como se ha explicado en el apartado 3.2.4, se calibra previamente a través de un frecuencímetro y durante la recogida de datos se calibra cada minuto en función de la temperatura interna. De esta forma los 2 sistemas de clock (teléfono móvil y 9x2) siguen la misma línea temporal. Sin embargo, esta sincronización puede tener un retraso de más de 1 segundo. Para ajustar este retraso se emplea también un evento de sincronización visual al principio de la captura de la base de datos y al final. Este evento visual está basado en dejar caer el sensor en la mesa con el fin de obtener un pico en la señal de la aceleración.

Al mismo tiempo este evento se graba en el video. De esta forma se puede acabar de sincronizar la señal del video con la señal inercial con un error de menos de 100ms.

Esta nueva base de datos está formada por 31 personas (15 hombres, 16 mujeres) de entre 23 a 53 años, con media de edad de 35.32 y una desviación estándar de 7.68 años. Todos los voluntarios realizan el protocolo 2 veces. La segunda vez se quitan el sensor y se lo colocan de nuevo, quedando como mínimo ligeramente orientado de forma distinta a la primera vez. Las pruebas tuvieron una duración de entre 4 - 5 minutos.

Se han grabado un total de 4 horas y 36 minutos de señal de video e inercial y se han registrado los siguientes números de episodios de las siguientes posturas o actividades:

<i>Postura</i>	<i>Núm. de Eventos</i>
<i>De Pie</i>	828
<i>Sentado</i>	517
<i>Sentarse (StSi)</i>	458
<i>Levantarse (SiSt)</i>	458
<i>Inclinarse (BD)</i>	62
<i>Reincorporarse de Inclinado (BU)</i>	62
<i>Caminando</i>	248
<i>Tumbado</i>	63
<i>Tumbarse (SL)</i>	63
<i>Reincorporarse de Tumbado (LS)</i>	63
<i>Inclinado</i>	62

Tabla 7.1. Número de episodios registrados para la segunda base de datos con voluntarios sanos

Esta base de datos se ha empleado para entrenar y para evaluar el algoritmo. Al igual que en el algoritmo A45, se ha utilizado la base de datos de MoMoPa, pero cogiendo esta vez los datos proporcionados por el 9x2 ubicado en el lateral del paciente. De esta base de datos se han registrado las siguientes actividades:

<i>Postura</i>	<i>Núm. de Eventos</i>
<i>De Pie</i>	24
<i>Sentado</i>	125
<i>Sentarse (StSi)</i>	86
<i>Levantarse (SiSt)</i>	86
<i>Caminando</i>	100

Tabla 7.2. Número de episodios registrados para la base de datos de pacientes con la PD

Anteriormente se han descrito los 5 umbrales y cómo se diseña la SVM para distinguir SiSt y StSi. Finalmente se ha descrito cómo se ha obtenido el DT. A continuación se describe el método de entrenamiento para obtener los 5 umbrales. De la primera base de datos (31 voluntarios sanos, 62 tomas de datos), se emplea el 75% de los datos (de las 62 tomas) para entrenar. Los 5 umbrales (*STFTth*, *IAAth*, *With*, *Yth* y *JXth*) son la frontera de separación de la función de discriminación extraída por la SVM con kernel lineal. Estos umbrales se extraen entrenando ese 75% de datos y a su vez también se extrae el modelo de SVM con kernel Gaussiano para distinguir un SiSt-StSi. Una vez fijados todos los modelos se ejecuta el algoritmo genérico evaluando los estados y obteniendo la sensibilidad y especificidad.

El modelo de la SVM para distinguir SiSt-StSi depende de los parámetros de coste  $C$  y gamma  $\gamma$ , que deben ser ajustados para maximizar la precisión del modelo. Sin embargo, se desea también minimizar el número de SV. Dado que muchos modelos pueden tener una precisión cercana a 100%, el modelo óptimo que se considera es el que tenga menos SV pero dentro del grupo con las precisiones por encima de la precisión máxima encontrada sustrayendo un 5%.

Por tanto, el cálculo necesario en la fase de predicción en tiempo real requerirá menos recursos pero conservando una precisión elevada. Con  $P=1$  hasta  $P=30$  se obtienen 30 modelos de SVM. El modelo óptimo de SVM es aquel que minimiza  $(SV_P \cdot 2P)$  donde  $SV_P$  es el número de vectores de soporte calculados en la fase de entrenamiento de la SVM con el espacio de características de entrada  $x_i$  con longitud  $2 \cdot P$ .

Una vez se determinan los 5 umbrales y el modelo de SVM, el algoritmo general queda completamente definido. Este proceso descrito hasta ahora se ejecuta 30 veces cambiando aleatoriamente el orden de la base de datos escogiendo en cada iteración un

75% de datos diferente con el fin de comprobar que los procesos de ajuste son independientes de los conjuntos de entrenamiento y evaluación. Asimismo, se evalúa también el segundo conjunto de datos (pacientes con PD) con los 30 modelos para observar si los umbrales y los modelos de SVM son compatibles en ambos conjuntos. Los resultados se muestran en el siguiente apartado.

## 7.6 Resultados y discusión

En este apartado se muestran y se discuten los resultados de los procedimientos descritos en el apartado 7.5. El umbral dinámico, que se fija antes de empezar el proceso de entrenamiento, se escoge después de entrenar 30 veces el clasificador StSi-SiSt con un DT diferente y un número diferente de entradas para la SVM. En la Figura 7.5 se muestran las precisiones alcanzadas para cada valor de DT y su relación con el número de entradas  $x_i$  para la SVM. El requisito propuesto para seleccionar el valor de DT es superar como mínimo el 95% en precisión.

Como se observa en la Figura 7.5 las precisiones con más de 3 entradas por característica y  $DT > 0.3 \cdot Y_{MAX}$ , son mayores que 0.95. Consecuentemente, el valor de DT se fija a  $0.3 \cdot Y_{MAX}$  ya que escoger un DT cercano a 0 nos garantiza el análisis de la mayor parte de la señal posible. Sin embargo, se observa que un  $0.95 \cdot Y_{MAX}$  también proporciona muy buenas precisiones. No obstante, un DT muy alto nos limitaría el análisis no analizando algunos episodios de transiciones lentos ejecutados por pacientes con la PD puesto que en la ejecución de una PT por una persona con PD, el diferencial del eje Y analizado para determinar el periodo que ocurre la transición estaría atenuado. Así se observa en algunos de los resultados obtenidos en la Tabla 7.6. Asimismo en los resultados de Kralj et al. se muestra que una PT en una persona mayor o con deficiencia motora puede disminuir en rapidez de ejecución [149].

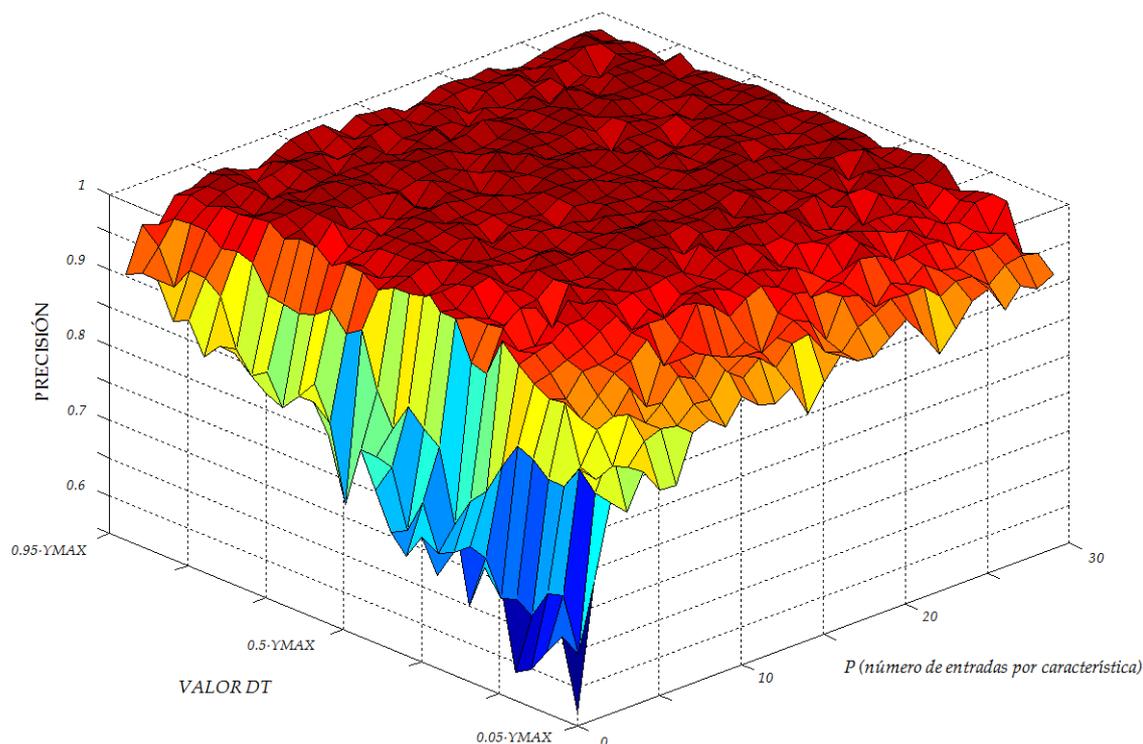


Figura 7.5. Relación entre precisión, DT y P

En las siguientes tablas, se muestran los resultados logrados en la evaluación del algoritmo general. Los resultados de la Tabla 7.3 muestran la media y desviación estándar de la sensibilidad y especificidad tras haber realizado 30 veces (cada una con diferentes conjuntos de entrenamiento y evaluación) los entrenamientos para obtener los umbrales, el modelo de SVM gaussiano y haber ejecutado el algoritmo general.

La matriz de confusión mostrada a continuación (Tabla 7.4) se obtiene a través de la suma de las 30 matrices de confusión obtenidas con la ejecución de los 30 algoritmos generales (Figura 7.3).

El algoritmo es muy sensible a la detección de las 11 actividades analizadas, como muestra la Tabla 7.3 dado que proporciona resultados por encima del 97%. Sin embargo, se pueden dar algunos falsos positivos tal como muestra la especificidad en los resultados de SiSt-StSi. Se refleja sobretodo la complejidad de análisis de las transiciones de SiSt y StSi con un acelerómetro en la cintura. Se puede observar a su vez, que la actividad SL se puede confundir con otras actividades, como ‘de pie’, ‘sentado’ o SiSt. Esta transición, sin embargo, no se considera relevante, puesto que esta transición siempre lleva a la postura de ‘tumbado’, la cual es difícilmente confundida con otras

posturas y además tiene muy pocos falsos positivos como se muestra la especificidad en la postura ‘tumbado’. Las posturas estáticas más importantes que se pueden confundir debido a que son consecuencia de determinar bien las transiciones SiSt y StSi, son ‘de pie’ y ‘sentado’. Existen pocos casos de confusión en estas posturas como se muestra en la Tabla 7.4

Las tablas Tabla 7.5 y Tabla 7.6 muestran los resultados de evaluar los umbrales, y el modelo de SVM con el algoritmo general en el segundo conjunto de datos, realizado con pacientes con PD. Los resultados de la Tabla 7.5 muestran la media y desviación estándar de haber realizado la evaluación 30 veces con los 30 modelos obtenidos. La Tabla 7.6 muestra la suma de las 30 matrices de confusión obtenidas en las 30 evaluaciones.

	<i>De pie</i>	<i>Sentado</i>	<i>StSi</i>	<i>SiSt</i>	<i>BD</i>	<i>BU</i>
<i>Sensibilidad</i>	0.97±0.01	0.99±0.00	0.99±0.00	0.99±0.01	1.00±0.00	0.99±0.00
<i>Especificidad</i>	0.96±0.02	0.89±0.04	0.84±0.03	0.95±0.03	0.96±0.05	0.92±0.07

	<i>Caminando</i>	<i>Tumbado</i>	<i>SL</i>	<i>LS</i>	<i>Inclinado</i>
<i>Sensibilidad</i>	0.98±0.01	0.99±0.00	0.99±0.00	1.00±0.00	1.00±0.00
<i>Especificidad</i>	1.00±0.00	0.97±0.03	0.99±0.01	0.99±0.01	0.99±0.04

Tabla 7.3. Resultados de Sensibilidad y Especificidad de voluntarios sanos

		REAL										
		<i>De pie</i>	<i>Sentado</i>	<i>StSi</i>	<i>SiSt</i>	<i>BD</i>	<i>BU</i>	<i>Caminando</i>	<i>Tumbado</i>	<i>SL</i>	<i>LS</i>	<i>Inclinado</i>
PREDICCIÓN	<i>De pie</i>	0.94	0.03	0	0.01	0	0.01	0.03	0	0.04	0.02	0.01
	<i>Sentado</i>	0.05	0.97	0.02	0.02	0	0	0.01	0.02	0.04	0.02	0
	<i>StSi</i>	0.01	0	0.94	0.14	0	0.03	0	0	0.03	0	0.01
	<i>SiSt</i>	0	0	0.04	0.83	0	0.02	0	0	0.01	0	0
	<i>BD</i>	0	0	0	0	1	0	0	0	0	0	0
	<i>BU</i>	0	0	0	0	0	0.94	0	0	0	0.03	0
	<i>Caminando</i>	0	0	0	0	0	0	0.96	0	0	0	0
	<i>Tumbado</i>	0	0	0	0	0	0	0	0.98	0.01	0	0
	<i>SL</i>	0	0	0	0	0	0	0	0	0.87	0	0
	<i>LS</i>	0	0	0	0	0	0	0	0	0	0.93	0
	<i>Inclinado</i>	0	0	0	0	0	0	0	0	0	0	0.98

Tabla 7.4. Matriz de confusión para los voluntarios sanos

	<i>De Pie</i>	<i>Sentado</i>	<i>StSi</i>	<i>SiSt</i>	<i>Caminando</i>
<i>Sensibilidad</i>	99±2.00	87±3.00	99±0.00	98±0.00	93±0.00
<i>Especificidad</i>	25±5.00	98±0.00	78±4.00	94±0.02	1±0.0

Tabla 7.5. Resultados de Sensibilidad y Especificidad para pacientes con PD

		REAL				
		<i>De pie</i>	<i>Sentado</i>	<i>StSi</i>	<i>SiSt</i>	<i>Caminando</i>
PREDICCIÓN	<i>De pie</i>	0.73	0.04	0	0.02	0.11
	<i>Sentado</i>	0.08	0.93	0	0.06	0.04
	<i>StSi</i>	0.02	0.01	0.99	0.07	0.03
	<i>SiSt</i>	0	0	0.00	0.81	0.00
	<i>Caminando</i>	0.17	0.02	0	0.03	0.82

Tabla 7.6. Matriz de confusión para pacientes con PD

Como se describe en el apartado 7.5, sólo se muestran las actividades que se han realizado para el proyecto MoMoPa. No obstante, lo más relevante en este algoritmo, es poder comparar las PT de SiSt-StSi entre los pacientes sanos y pacientes con PD con alteraciones motoras. Los resultados en este caso son muy similares a la Tabla 7.3 respecto a la sensibilidad y especificidad de ambas transiciones posturales. Se desprende, por lo tanto, que el modelo extraído con los pacientes sanos se pueden generalizar al segundo conjunto de datos. Los resultados de la Tabla 7.5 sin embargo son ligeramente inferiores a la Tabla 7.3 La diferencia puede explicarse por el diseño de DT. La función del umbral de DT es de fijar el inicio y final de una transición a través del diferencial del eje Y de la señal del acelerómetro. Cuando se supera el umbral  $STFT_{th}$ , y hay un candidato a ser StSi o SiSt, DT fija el inicio de la transición. Sin embargo, y dado los movimiento intrínsecos involuntarios de un paciente con PD (p.ej: discinesias), el umbral DT no es capaz de determinar cuándo es el final de la PT. En este caso, toda la señal de la ventana formaría parte de  $x_i$ . De esta forma aparecerían tramos de las entradas de la SVM que no correspondería a una PT. Asimismo, podría provocar un error de clasificación en la SVM entre estados estáticos.

En cuanto al resto de actividades, resalta el gran descenso en la especificidad que se

produce en la postura ‘de pie’ el resultado de la cual se ve reflejado en la matriz de confusión (Tabla 7.6). La actividad de ‘caminando’ afecta de manera excesiva en los resultados y se confunde claramente con la actividad de ‘de pie’. Debido a las alteraciones motoras que presentan los pacientes con PD, los umbrales establecidos para determinar una tarea de caminar, no se pueden extrapolar en algunos casos los umbrales entrenados del primer conjunto de datos al segundo. Cuando el algoritmo se ejecuta, la actividad de caminar es muy difícil de detectar si el paciente presenta síntomas como bradicinesias (Tabla 7.6). La bradicinesia provoca que la señal de *IAA* no supere nunca el umbral *IAAth* debido a la lentitud del movimiento. Por lo tanto la ejecución del caminar del paciente con PD se confunde por una actividad de ‘de pie’. Por consiguiente, el clasificador de ‘caminando’ debe de ser específico para los pacientes con PD. En otras palabras, el conjunto de datos con el que se debe fijar el umbral, se debe realizar con un conjunto de datos formado con personas con PD. Para comprobarlo, se ha llevado a cabo un experimento donde se ha escogido un paciente y se ha establecido un umbral empírico a partir de los datos obtenidos con este paciente. El algoritmo se ha probado con el resto de pacientes. La Tabla 7.7 muestra los resultados de evaluar el algoritmo con los pacientes con PD después de haber modificado el umbral *With* y *IAAth*.

		REAL				
		<i>Stand</i>	<i>Sit</i>	<i>StSi</i>	<i>SiSt</i>	<i>Walking</i>
PREDICTED	<i>Stand</i>	0.73	0.04	0	0.02	0.11
	<i>Sit</i>	0.08	0.93	0	0.06	0.04
	<i>StSi</i>	0.02	0.01	0.99	0.07	0.03
	<i>SiSt</i>	0	0	0.00	0.81	0.00
	<i>Walking</i>	0.17	0.02	0	0.03	0.82

Tabla 7.7. Matriz de confusión para pacientes con Parkinson con umbral específico para caminar

## 7.7 Conclusiones sobre el algoritmo A90

El algoritmo A90 está compuesto por una estructura jerárquica de clasificadores que determina la postura mediante el análisis de las PT. En este caso, a diferencia del algoritmo A45, el sensor está ubicado a 90 grados y, en esta posición, se pueden obtener

respuestas inerciales inciertas como se muestra en la Figura 7.2. El eje X y Z se pueden comportar de forma muy similar y, por tanto, una relación entre estos dos ejes como se realiza en el algoritmo A45 no es suficiente para determinar una PT de SiSt o de StSi. Para ello, se recurre al paradigma de la SVM con kernel gaussiano, capaz de resolver el problema de forma más óptima que el kernel lineal. Además, se introduce como característica de entrada el módulo, que contiene información del eje Y que, como se muestra en la Figura 7.2, muestra un comportamiento distinto entre una PT de SiSt y de StSi. Asimismo, se incluyen nuevos clasificadores, como el de ‘caminar/no caminar’, y el que distingue un ‘inclinarse’, de un ‘tumbarse’. Todos los umbrales son obtenidos mediante un proceso de entrenamiento con una SVM con kernel lineal. Todos los clasificadores se obtienen 30 veces con conjuntos de datos aleatoriamente diferentes para comprobar la independencia entre datos de entrenamiento y evaluación.

Los resultados muestran unas sensibilidades por encima de 97% y especificidades por encima 84%. Sin embargo, cuando los clasificadores se evalúan en un conjunto de datos formado por pacientes con PD, el clasificador de caminar no funciona adecuadamente. Es por ello que este clasificador debe ser específico para los pacientes con PD. Sin embargo, el clasificador SiSt-StSi proporciona resultados por encima de 98% y 78% para sensibilidad y especificidad respectivamente con lo que demuestra la buena adaptabilidad del clasificador SiSt-StSi de un grupo de personas sanas a un grupo con la PD.

## Capítulo 8

# Estado del arte en el Bloqueo de la Marcha

En este capítulo se describe el estado del arte en el Bloqueo de la Marcha focalizado en las metodologías existentes para identificar este síntoma.

### *8.1 Primeras tentativas para identificar el FoG*

James Parkinson fue el primero en definir este síntoma como un estado del paciente en el cual éste se veía *“irresistiblemente obligado a dar pequeños pasos muy rápidos”*[170]. Moreau et al. define el FoG como *“una incapacidad repentina para mantener una marcha efectiva”*[32].

El FoG se ha estudiado ampliamente en el campo de la salud durante años, pero fue Giladi en el 1992 quien empieza a estudiar con detalle a partir de cuestionarios este síntoma [171]. Posteriormente participa en los estudios clínicos más importantes hasta ahora a nivel de estudio del FoG con acelerómetros [172].

En 2001 Nieuwboer et al. a través de videocámaras, electromiografía y plataformas de presión observaron anomalías en el caminar de un paciente cuando se bloquea, reduciendo su longitud de paso y moviéndose a una frecuencia mayor que la marcha normal [50]. En 2003 se empieza a usar acelerometría para estudiar más exhaustivamente

el movimiento de los pacientes cuando sufren FoG, y así demostrar mediante señales inerciales los movimientos descritos por Nieuwboer et al. 2 años antes. Han et al. muestran como a partir de acelerómetros situados en los tobillos, las señales obtenidas cuando hay un episodio de FoG contienen armónicos entre 6-8Hz por lo que están directamente en la banda asociada al FoG, sin embargo la población de evaluación y validación era sólo de dos pacientes con PD [173]. En 2008, se publican los resultados de Moore et al., los cuales detectaron a través de acelerómetros situados también en el tobillo una banda de frecuencias que estaba totalmente asociada al movimiento cuando un paciente padecía FoG [2]. Asimismo, se definió el índice de congelación ( $FI$ ) como una relación espectral del cuadrado de la potencia espectral de aquellas frecuencias asociadas al FoG, entre 3 y 8 Hz ( $FB$ ), entre el cuadrado de la potencia espectral de la banda de frecuencias correspondiente al caminar, entre 0.5 y 3Hz ( $WB$ ). La latencia de detección estaba en 6 segundos, y la cantidad de falsos positivos dentro de situaciones controladas era muy alta (20%). Sin embargo introduciendo un umbral personalizado para cada paciente, los falsos positivos bajaban al 10% y la precisión pasaba de 78% a 89%.

Más tarde, bajo el proyecto Dynamic Analysis of Physiological Networks (DAPHNET) liderado por Bächlin [174], el Instituto Federal Suizo de Tecnología de Zurich (ETH Zurich) junto con diversas instituciones universitarias y médicas de Israel, realizó un algoritmo online capaz de detectar e identificar el FoG adaptando la directrices frecuenciales del trabajo de Moore [49,130,172]. No obstante, y debido a que la relación de Moore obtenía valores muy elevados cuando el paciente estaba en una situación estática, tranquila, o inmóvil, etc., el grupo de Bächlin introdujo el índice de potencia ( $PI$ ), que era la suma de potencia espectral de los armónicos de las 2 bandas ( $WB$  y  $FB$ ). El índice de potencia  $PI$  consideraba que la persona se estaba moviendo si superaba un umbral ( $P_{th}$ ). De lo contrario, la persona estaba quieta o en ausencia de movimiento. Si se superaba el  $P_{th}$  y, por lo tanto, la persona estaba realizando alguna actividad relevante en términos de movimientos, el  $FI$  se podía evaluar de forma que si superaba otro umbral ( $F_{th}$ ) se designaba un positivo de FoG. Formalmente está definido de la siguiente manera:

$$Episodio\ de\ FoG = \begin{cases} \text{positivo,} & \text{si } FI > Fth \wedge PI > Pth \\ \text{negativo,} & \text{de otra manera} \end{cases} \quad (8.1)$$

El índice de potencia permite reducir los falsos positivos que se obtenían con el algoritmo de Moore en situaciones donde la persona no se moviera.

Una de las principales aportaciones del grupo de Bächlin fue implementar el algoritmo en online. Para ello, realizó algunas modificaciones respecto del trabajo de Moore, como por ejemplo, el ventaneado de señal fue reducido de 6 a 4 s., lo cual reducía la latencia del sistema de Moore. Los resultados obtenidos por Bächlin en 10 pacientes son una referencia importante debido al número significativo de FoG's que detectaron (237). Además, obtuvieron un 73.1% de sensibilidad y 81.6% de especificidad en la rodilla con un umbral fijo para todos los pacientes basado en el máximo entre los valores mínimos en la sensibilidad y especificidad del *FI* y *PI*. Por otro lado, consiguieron un 88.6% de sensibilidad y 92.4% de especificidad con un umbral particular para cada paciente [172].

## 8.2 Hacia una identificación óptima del FoG

La mayoría de autores ubican el sensor en el tobillo, rodilla o muslo. Aparentemente la pierna es el mejor lugar para obtener una señal de mayor amplitud en la marcha o en un episodio de FoG. No obstante, en el trabajo de Bächlin también estudian otros emplazamientos, como por ejemplo, la cintura, donde afirman que puede ser una buena ubicación. Sin embargo, los resultados dependen mucho de la orientación del sensor, que está directamente relacionada con la anatomía del paciente.

Existen también otros trabajos relacionados con la detección del FoG, como Jovanov et al., que al igual que Bächlin, utiliza un sensor en el tobillo como Moore, Han y Bächlin. Con una latencia de 320ms son capaces detectar FoG basándose también en transformadas de Fourier. El sistema está formado por un módulo WT32 capaz de emitir señal por Bluetooth en interfaz HFP-AG para enviar audio rítmico a un auricular con receptor de Bluetooth que lleva el paciente [175]. Un trabajo similar sobre la identificación de FoG es el de Zabaleta et al. Estudia a partir de un acelerómetro de 3 ejes

y un giroscopio de 2 ejes situados en el pie, el gemelo y muslo la frecuencia en la marcha normal y el FoG a través de espectros de potencia. Para clasificar, utiliza características diversas (frecuencia dominante, cuartiles del espectro, amplitudes de armónicos cercanos a las frecuencias dominantes...) junto con el FI propuesto por Moore. Los mejores resultados obtenidos son con el giroscopio en el plano sagital en el tobillo y con la aceleración con el sensor situado también en el tobillo con un 80.8% y 82.7% de precisión respectivamente [176]. Cole et al. utiliza además de acelerómetros situados en el muslo, espinilla y brazo, electromiografía para detectar el FoG a través de redes neuronales dinámicas [177]. Finalmente se puede destacar el trabajo de Niazmand et al. donde usan 5 acelerómetros en la pierna y un datalogger integrados en un pantalón [178]. Sin embargo, a nivel de algoritmia este grupo también sigue las directivas frecuenciales de Bächlin y Moore.

En la actualidad no sólo se han utilizado acelerómetros para detectar un FoG. Delval et al. se basa en los criterios de Nir Giladi, y Bastiaan R. Bloem (expertos en el FoG) para saber si ha existido un verdadero positivo del FoG en un paciente. Con esta información y trabajando con espectros frecuenciales y wavelets, junto con información de video y goniómetros situados en la rodilla, tratan de detectar episodios de FoG de periodo muy corto (<1s) [51]. Además, ponen en duda la relación entre festinación y FoG a nivel inercial ya que se obtienen falsos positivos de personas sin FoG debido a que pueden sufrir festinaciones, consecuentes de las alteraciones de la marcha en la bradicinesia. Nieuwboer et al. ya explica en el 2001 la aparente similitud espaciotemporal entre una festinación y un episodio de FoG al iniciar la marcha [50]. Delval et al. proponen que es un tema que se debe estudiar más a fondo.

Por otro lado, se han realizado varios experimentos para conocer a fondo el comportamiento del FoG y para saber cuándo puede producirse. La universidad de Ontario utiliza la alfombra GAITRite® (CIR systems, Inc. Clifton, New Jersey, USA) para detectar comportamientos de los pacientes con la EP avanzada y con FoG al pasar por diferentes puerta de diferente anchura o, al seguir una luz para desviar su atención y provocar FoG [52,179].

Dado que se ha visto que en algunos pacientes unos impulsos sensoriales rítmicos (auditivas, visuales o hápticas) pueden detener o reducir el tiempo de los episodios de

FoG [42–44], en la actualidad se están definiendo nuevas líneas de investigación que consisten en observar el comportamiento del paciente justo antes de tener un FoG. Con este fin, se envía un impulso sensorial rítmico antes de que el paciente sufra un episodio de FoG. Almeida observa diferentes características como longitud del paso, velocidad, variabilidad entre un episodio y un comportamiento normal [179], Nutt et al. muestra como una serie de múltiples fallos motores simultáneos, tanto en las rodillas, como el movimientos en los dedos y el peso provocado del paciente en una plataforma de sensores de presión, conducen a un episodio de FoG [47]. Plotnik et al. proponen una parametrización de la marcha de forma que a través de un umbral se pueda considerar una marcha “normal” de una marcha con FoG y poder actuar con anterioridad a que el episodio ocurra [180].

### ***8.3 Conclusiones del estado del arte de FoG***

El FoG es uno de los síntomas más complejos de estudiar según Giladi y Nieuwboer por múltiples causas [31]. Entre otras, la heterogeneidad de los movimientos de los pacientes con la PD provoca que sea complejo poder identificar bien los síntomas. Sin embargo, y de acuerdo con la literatura, parece que los algoritmos de Moore y Bächlin han sido aplicados a otras metodologías. Se han empleado distintos sensores, u observando otro tipo de ubicaciones, pero manteniendo la esencia del algoritmo propuesta por Han et al.[173], que es el análisis frecuencial de la señal inercial proveniente del paciente con la PD. No obstante, se buscan nuevas técnicas para poder identificar este síntoma como el GAITRite [179], o la electromiografía [177].

Además, existen indicios de poder detectar el FoG antes de que el episodio sea perceptible [47,180], sin embargo, parece que esta línea de investigación es tan solo una hipótesis por el momento.

## Capítulo 9

# Mejora de la detección del Bloqueo de la Marcha mediante contexto de postura

El método de detección de FoG empleado por los diferentes investigadores viene determinado por el estado de las características analizadas en la ventana temporal actual [2,56,175–178]. Sin embargo, el contexto en que ocurre un episodio se puede percibir mediante otros sensores o, también, analizando el espacio o ambiente que rodea al paciente con la PD. Por ejemplo, Takac et al., a través de una MS Kinect realiza un mapeado de la zona de visión de la cámara de profundidad. A través de este mapa, se determinan dónde están las zonas más conflictivas para un paciente con FoG, por ejemplo, zonas estrechas, puertas u objetos (muebles, sillas, mesas) que puedan interferir en la trayectoria del paciente. Además, se identifica al paciente y se le hace un seguimiento por la zona de visión, con lo que se puede determinar la trayectoria del paciente y, en consecuencia, permite observar si se dirige a una zona que le puede causar un episodio de FoG [181,182]. El contexto significa poder conocer el lugar, o las situaciones que pueden provocar un episodio de FoG tal y como describe Schaafsma [41]. Conocer el contexto reduce el número de falsos positivos que se dan en el algoritmo de Moore cuando las situaciones de FoG no implican un riesgo de caída, por ejemplo,

estirado, o sentado. A pesar de que Schaafsma reporta los tipos de FoG como aquellos que se dan cuando el paciente está de pie, hay situaciones en la que el estrés y sobretodo realizar dos tareas simultáneas pueden inducir a un episodio de FoG cuando el paciente está sentado [41,46,47]. Sin embargo, al estar sentado, no se considera peligroso caerse, puesto que el paciente está apoyado en la silla o en el sofá.

Dado que el algoritmo de Moore puede contener falsos positivos, se considera entonces que, la contextualización ayudaría a aumentar la especificidad, del algoritmo. Por el contrario, podría eliminar algún TP si el contexto de la situación no se realiza correctamente y, en consecuencia, la sensibilidad también bajaría.

### ***9.1 Método de evaluación del algoritmo de detección del bloqueo de la marcha***

En el proyecto DAPHNET, se reúnen 10 pacientes con la PD que ejecutan una serie de actividades bajo un protocolo de pruebas realizado en un laboratorio. En el proyecto se aplica el algoritmo de detección de FoG propuesto por Moore y extendido por Bächlin consiguiendo una sensibilidad de un 73.1% y una especificidad de un 81.6%. Estos resultados se obtienen fijando un único umbral para todos los pacientes. Sin embargo, no queda claro el método de evaluación, por ejemplo, no se expone si se evalúa a nivel de episodio, o a nivel de ventana. Dado que se pueden establecer nuevos algoritmos para la detección y por lo tanto se desea comparar los resultados del nuevo algoritmo con el algoritmo de detección de FoG empleado en el proyecto DAPHNET, resulta necesario establecer un método estándar para poder evaluar de igual forma todos los algoritmos. Tal y como se explica en el apartado 4.3, existen 4 posibilidades que resultan de evaluar una muestra por parte de un instrumento de diagnóstico: TP, TN, FP y FN.

Se propone un método de evaluación basado en episodios en lugar de ventanas. La ventaja reside en que episodios largos detectados, de varias ventanas de duración, sólo se contabilizarán una única vez (un solo TP) y, de la misma manera, tramos de muchas ventanas sin episodios no se contarán como múltiples TN. De esta manera, se evalúa el algoritmo de detección de forma más rigurosa.

Se propone evaluar un algoritmo de detección a nivel de episodio a través de la

construcción de 2 tablas. La primera representará los episodios etiquetados. La segunda corresponderá a los episodios detectados por el algoritmo de detección de FOG. Una fila en cada una de las tablas representará un episodio y estarán formadas por dos columnas: en la primera se anotará el tiempo de inicio del episodio y en la segunda columna se anotará el tiempo de fin del episodio. Para ello, se obtienen primero los vectores correspondientes al tiempo de la señal:  $t_1, \dots, t_K$ ; los correspondientes a la salida del algoritmo:  $s_1, \dots, s_K$ , donde:

$$s_j = \begin{cases} 1, & \text{si FoG detectado} \\ 0, & \text{si FoG no detectado} \end{cases} \quad (9.1)$$

y los correspondientes a la etiqueta  $e_1, \dots, e_K$ , donde:

$$e_i = \begin{cases} 0, & \text{si No FoG} \\ 1, & \text{si FoG} \\ 2, & \text{si Undefined} \end{cases} \quad (9.2)$$

En el vector de las etiquetas  $e_1, \dots, e_K$ , un episodio de FoG está definido como un conjunto de muestras consecutivas que ocurre desde una muestra  $m_0^i$  a otra muestra  $m_f^i$  y que satisfacen la siguiente expresión:

$$e_{m_0^i-1} = \{0, 2\}, \quad e_{m_0^i} = 1, \dots, e_{m_f^i} = 1, e_{m_f^i+1} = \{0, 2\} \quad (9.3)$$

Con los valores  $t_{m_0^i}$  y  $t_{m_f^i}$  correspondientes a  $e_{m_0^i}$  y  $e_{m_f^i}$  se construye la siguiente tabla:

<i>Etiqueta</i>			
<i>Número de episodio</i>	<i>Tiempo inicial</i>	<i>Tiempo final</i>	<i>Resultado</i>
1	$t_{m_0^1}$	$t_{m_f^1}$	$R_{e^1}$
...	...	...	...
i	$t_{m_0^i}$	$t_{m_f^i}$	$R_{e^i}$

...	...	...	...
n	$t_{m_0^n}$	$t_{m_f^n}$	$R_{e^n}$

Tabla 9.1. *Evaluación de algoritmos, tabla de episodios de FoG etiquetados*

De la misma forma se construye la tabla de la salida del algoritmo (Tabla 9.2). El episodio de FoG detectado en la salida del algoritmo se define como un conjunto de muestras consecutivas que ocurre desde una muestra  $m_0^j$  a otra muestra  $m_f^j$  y que satisfacen la siguiente expresión:

$$s_{m_0^{j-1}} = 0, s_{m_0^j} = 1, \dots, s_{m_f^j} = 1, s_{m_f^{j+1}} = 0 \quad (9.4)$$

Con los valores  $t_{m_0^j}$  y  $t_{m_f^j}$  correspondientes a  $s_{m_0^j}$  y  $s_{m_f^j}$  se construye la siguiente tabla:

<b>Salida del algoritmo</b>			
<i>Número de episodio</i>	<i>Tiempo inicial</i>	<i>Tiempo final</i>	<i>Resultado</i>
1	$t_{m_0^1}$	$t_{m_f^1}$	$R_{s^1}$
...	...	...	...
j	$t_{m_0^j}$	$t_{m_f^j}$	$R_{s^j}$
...	...	...	...
p	$t_{m_0^p}$	$t_{m_f^p}$	$R_{s^p}$

Tabla 9.2. *Evaluación de algoritmos, tabla de episodios de FoG detectados*

En cada tabla se añade otra columna donde en cada fila se anota la coincidencia temporal de cada uno de los episodios etiquetados y de los episodios correspondientes a la salida del algoritmo.

En el caso de la tabla de los episodios etiquetados (Tabla 9.1), el vector *Resultado*, que está formado por tantos valores como episodios etiquetados, se constituye por  $R_{e^1}, \dots, R_{e^n}$  donde  $R_{e^i}$  tomará el valor 0 o 1 en función de si el episodio en cuestión ha sido detectado (1) o no (0) de acuerdo con las siguientes condiciones:

$$R_{ei} = \begin{cases} 1, & \text{si } \begin{array}{l} t_{m_0j} > t_{m_0i} \wedge t_{m_0j} < t_{m_fi} \\ t_{m_fj} > t_{m_0i} \wedge t_{m_fj} < t_{m_fi} \end{array} \\ 0, & \text{otro caso} \end{cases} \quad (9.5)$$

En el caso de la tabla de episodios detectados por el algoritmo (Tabla 9.1), el vector *Resultado*, de longitud igual al número de episodios detectados por el algoritmo, se constituye por  $R_{s^1}, \dots, R_{s^n}$  donde  $R_{s^i}$  tomará el valor 0 o 1 en función de si el episodio detectado es correcto (1) o es un falso positivo (0) de acuerdo con las siguientes condiciones:

$$R_{sj} = \begin{cases} 1, & \text{si } \begin{array}{l} t_{m_0i} > t_{m_0j} \wedge t_{m_0i} < t_{m_fj} \\ t_{m_fi} > t_{m_0j} \wedge t_{m_fi} < t_{m_fj} \\ t_{m_0i} < t_{m_0j} \wedge t_{m_fi} > t_{m_fj} \end{array} \\ 0, & \text{otro caso} \end{cases} \quad (9.6)$$

Con las dos tablas y los resultados, se obtienen los TP, FP, y FN de acuerdo a:

- En la tabla de los episodios etiquetados (Tabla 9.1), un episodio  $R_{ei} = 1$  significa que el caso se ha detectado correctamente y por tanto es un TP.
- Un episodio  $R_{ei} = 0$  es un caso de FN, puesto que el algoritmo no ha detectado este caso.
- Los FP se obtienen con la tabla de salida de algoritmo (Tabla 9.2). Un episodio detectado  $R_{s^i} = 0$ , significa que no coincide temporalmente con la tabla de etiquetas, y por tanto es un FP.

Los TN son aquellos episodios en los cuales no existe enfermedad y el algoritmo así lo detecta. Para ello se construye un nuevo vector  $TN_1, \dots, TN_K$  formado por:

$$TN_i = \begin{cases} 1, & \text{si } e_i = 0 \wedge s_i = 0 \\ 0, & \text{otro caso} \end{cases} \quad (9.7)$$

Con este vector se contabilizan los episodios de TN. Un episodio de TN está definido como un conjunto de muestras consecutivas que satisfacen la siguiente expresión:

$$TN_{m_f^h} = \{0\}, \quad TN_{m_f^{h+1}} = 1, \dots, TN_{m_0^{h+1-1}} = 1, TN_{m_0^{h+1}} = \{0\} \quad (9.8)$$

Un episodio de TN está acotado por el tiempo transcurrido  $t_{m_0^{h+1-1}} - t_{m_f^{h+1}}$  donde empieza y acaba el episodio de TN siendo  $h$  el número de episodio de FoG detectado por el algoritmo (sea FP o TP). Sin embargo, ocurre con frecuencia que la persona puede estar realizando una actividad considerada como TN por el algoritmo durante muchos minutos y sólo se contabilizaría 1 caso TN en esta situación. Se ha determinado que un caso de TN no puede superar los 30 segundos. Así pues  $TN = \text{ceil}\left(\frac{t_{m_0^{h+1-1}} - t_{m_f^{h+1}}}{30}\right)$ , donde  $\text{ceil}(t)$  es la función redondeo hacia  $+\infty$ . Por ejemplo, si  $t_{m_0^{h+1-1}} - t_{m_f^{h+1}} = 45\text{s}$ , hay 2 TN, si  $t_{m_0^{h+1-1}} - t_{m_f^{h+1}} = 25\text{s}$  hay 1 TN y si  $t_{m_0^{h+1-1}} - t_{m_f^{h+1}} = 70\text{s}$ , hay 3 TN. Además  $t_{m_0^{h+1-1}} - t_{m_f^{h+1}}$  debe ser más grande que 3 ventanas (6.4 s) para ser considerado como TN ya que, de otra manera, por cada TP o FP habría siempre un episodio de TN.

Del mismo modo que los TN se fragmentan en casos de episodios muy largos, los FP también se fragmentan. En un hipotético caso donde la evaluación de una señal se obtuviera:  $s_{m_0^1} = 1, \dots, s_{m_0^j} = 1, \dots, s_{m_f^K} = 1$ , sólo se obtendría 1 FP en una señal de decenas de minutos. Por tanto, se determina que  $FP = \text{ceil}\left(\frac{t_{m_f^j} - t_{m_0^j}}{\text{mean}(FoG \text{ episode})}\right)$ , donde  $\text{mean}(FoG \text{ episode})$  es la media de la duración de los episodios de FoG que ha tenido el paciente.

## 9.2 Contextualización del algoritmo de detección de Bloqueo de la Marcha

Con el fin de poder evaluar el algoritmo de Moore correctamente, se ha realizado un estudio de sensibilidad y de especificidad para diferentes valores de  $Pth$  y de  $Fth$ . Con ello se obtiene una tabla con la sensibilidad (Tabla 9.4) y otra de especificidad (Tabla 9.5) donde se anotan los resultados obtenidos evaluando el algoritmo de detección de FoG con cada pareja de umbrales.

Además, y siguiendo la metodología de evaluación del apartado 9.1 se construye una tercera tabla donde se anotaran los periodos de tiempo que el algoritmo de posturas ha detectado que la persona está sentada (Tabla 9.3). La tabla se construye partiendo del vector de resultados ‘sentado/no-sentado’ que se ha adquirido a partir del algoritmo A90. Este vector está formado por  $c_1, \dots, c_K$  correspondientes al tiempo de la señal:  $t_1, \dots, t_K$  donde:

$$c_r = \begin{cases} 1, & \text{sentado} \\ 0, & \text{cualquier otra actividad} \end{cases} \quad (9.9)$$

El periodo en estado ‘sentado’ se define como un conjunto de muestras consecutivas que ocurre desde una muestra  $m_0^r$  a otra muestra  $m_f^r$  y que satisfacen la siguiente expresión:

$$c_{m_0^r-1} = 0, \quad c_{m_0^r} = 1, \dots, c_{m_f^r} = 1, c_{m_f^r+1} = 0 \quad (9.10)$$

Con los valores  $t_{m_0^i}$  y  $t_{m_f^i}$  correspondientes a  $c_{m_0^r}$  y  $c_{m_f^r}$  se construye la siguiente tabla:

<i>Número de episodio</i>	<i>Tiempo inicial</i>	<i>Tiempo final</i>
1	$t_{m_0^1}$	$t_{m_f^1}$
...	...	...
R	$t_{m_0^r}$	$t_{m_f^r}$
...	...	...
N	$t_{m_0^n}$	$t_{m_f^n}$

Tabla 9.3. *Evaluación de algoritmos, tabla de periodos de 'sentado' detectados*

Todos los casos de FP que se han dado en la Tabla 9.2 y los TP que se han dado en la Tabla 9.1 se evalúan de nuevo. Puesto que el objetivo es reducir el número de falsos positivos, existe el riesgo de eliminar verdaderos positivos. El algoritmo de posturas parte como hipótesis inicial de que el FoG no puede darse cuando se está sentado o tumbado. Por esta razón, los falsos positivos que existen cuando una persona está sentada son eliminados. Sin embargo, en el supuesto caso que el algoritmo falle, un verdadero positivo previamente detectado no se consideraría como verdadero positivo, si no como falso negativo.

Por tanto, en la Ecuación 9.5 se aplica la siguiente condición en los casos que se haya determinado  $R_{ei} = 1$

$$R_{ei} = 0, \quad \text{si } t_{m_0^r} < t_{m_0^i} \wedge t_{m_f^r} > t_{m_f^i} \quad (9.11)$$

En la Ecuación 9.6 se añade también la siguiente condición en los casos que se haya determinado  $R_{sj} = 0$ .

$$R_{sj} = 1, \quad \text{si } t_{m_0^r} < t_{m_0^j} \wedge t_{m_f^r} > t_{m_f^j} \quad (9.12)$$

De esta forma se ven disminuidos los FP en el caso que el algoritmo de detección esté dando un FP cuando la persona se esté sentando.

### ***9.2.2 Evaluación del algoritmo de detección de Bloqueo de la Marcha con contextualización mediante posturas***

Para determinar con precisión la sensibilidad y la especificidad con un umbral genérico para cualquier paciente con la PD, se han escogido dos grupos de análisis. El primer grupo de análisis está compuesto con pacientes que suelen tener FoG, y el

segundo se ha escogido con pacientes que no tienen FoG.

En total se han estudiado 20 pacientes con PD con una escala de Hoehn and Yahr de más de 2 (7 mujeres y 13 hombres), y con capacidad cognitiva suficiente para poder realizar las pruebas. La edad media de los pacientes es de 69.3 años y la desviación estándar de 7.05 años. La escala de Hoehn and Yahr media atribuida a cada paciente es de 2.74 y su desviación estándar de 0.41. Hay 10 pacientes que presentan FoG, mientras que los otros 10 presentan otros síntomas de la PD, pero no presentan FoG. Todos los pacientes han realizado 2 pruebas de unos 20 minutos cada una. La primera prueba se realiza en estado motor 'OFF' y la segunda se realiza en estado motor 'ON'. Todas las pruebas se realizan en casa de los pacientes, con lo que facilita la aparición de episodios de FoG. Entre las diferentes actividades que el paciente ejecuta, está el protocolo de pruebas de falsos positivos para FoG. Este protocolo de pruebas consiste en realizar algunos movimientos en los cuales su respuesta frecuencial es aproximada a la de un episodio de FoG. Por ejemplo, lavarse los dientes, pintar un dibujo en un papel, o limpiar las ventanas. Algunos pacientes, realizan estas pruebas mientras están sentados. Siguiendo la metodología para capturar datos inerciales sincronizados con un video que realiza la función de gold-standard, terapeutas expertos realizan diferentes etiquetas de la señal, actividad, discinesias, bradicinesias y FoG [169].

A todas las señales capturadas se le aplica el algoritmo de Moore y el algoritmo A90 de posturas, obteniendo los siguientes resultados:

		Umbral de congelación ( $Fth$ )								
		0	0.5	1	1.5	2	2.5	3	3.5	4
Umbral de potencia ( $Pth$ )	0	100	99.5	99.6	90.3	83.7	75.1	67.1	57.7	50.5
	0.5	99.4	99.4	91	78.9	71.5	64.1	57.2	48.1	43.3
	1	82.6	80.4	76.9	69	60.1	54.5	47.8	41.5	38.1
	1.5	66.9	63.6	59.3	51.8	45.3	40.2	36	30.7	26.6
	2	50.3	46.7	42.4	35.6	31.4	27.4	25	20.5	18.2
	2.5	40.2	36	32	27.2	22.9	20.3	19.9	18.4	16.8
	3	34.4	29.8	27.2	21.7	18.8	16.5	16.3	16.3	14.6

Tabla 9.4. Sensibilidad del algoritmo de detección de FoG

		Umbral de congelación ( $F_{th}$ )								
		0	0.5	1	1.5	2	2.5	3	3.5	4
Umbral de potencia ( $P_{th}$ )	0	0	4.1	14.7	30.2	46.1	56.7	64.5	69.6	72.7
	0.5	28.8	25.1	36.3	57.2	74.7	85.4	90.8	94	95.3
	1	31.9	30.3	42.9	64.6	80.1	90	94.4	96.9	98.9
	1.5	35	37.4	51	70.5	84.5	92.3	95.7	97.4	99.1
	2	39.5	44.5	61.3	75.9	87.7	93.8	96.7	97.8	99.2
	2.5	43.3	50.5	68.8	81.1	90.4	94.9	97.2	98.4	99.5
	3	46.4	56.3	74.5	85.2	92.3	95.8	97.6	98.7	99.6

Tabla 9.5. Especificidad del algoritmo de detección de FoG

		Umbral de congelación ( $F_{th}$ )								
		0	0.5	1	1.5	2	2.5	3	3.5	4
Umbral de potencia ( $P_{th}$ )	0	98.4	97.9	98	88.7	82.1	73.5	65.4	56.2	49
	0.5	97.8	97.8	89.4	77.4	70.1	62.6	55.8	46.6	41.8
	1	80.9	78.8	75.3	67.6	58.7	53	46.3	40	36.6
	1.5	65.5	62.1	57.8	50.3	43.8	38.8	34.5	29.2	25.2
	2	48.8	45.2	40.9	34.2	30	26	23.5	19.1	16.7
	2.5	38.7	34.6	30.5	25.8	21.4	18.9	18.4	17	15.4
	3	32.9	28.3	25.7	20.2	17.3	15.1	14.8	14.8	13.1

Tabla 9.6. Sensibilidad del algoritmo de detección de FoG + Posturas

		Umbral de congelación ( $F_{th}$ )								
		0	0.5	1	1.5	2	2.5	3	3.5	4
Umbral de potencia ( $P_{th}$ )	0	0	6.7	19.6	38.2	55.9	65	72.5	77.7	80.2
	0.5	39	31.8	42.4	62.8	79	88	93.6	94.8	95.8
	1	43	37.9	49.8	70.8	84	91.2	95.6	97.9	99.4
	1.5	47.4	46	58	76.3	87.9	93.4	96.6	98.3	99.4
	2	51.7	53.1	67.5	81.4	90.4	94.5	97.4	98.4	99.5
	2.5	56.9	60.4	76.1	86.1	92.7	95.6	97.8	98.9	99.8
	3	60.9	66.4	80.5	88.4	93.4	96.3	98.1	99	99.9

Tabla 9.7. Especificidad del algoritmo de detección de FoG + Posturas

Cada una de las tablas representa la sensibilidad y especificidad calculada para un modelo con diferentes valores de umbrales en el  $P_{th}$  y el  $F_{th}$ . A medida que el  $P_{th}$  y  $F_{th}$  aumentan, la sensibilidad decrece y la especificidad aumenta. Para realizar una primera evaluación del algoritmo de posturas, se calcula la media de las 4 tablas para ver el decrecimiento de la sensibilidad y el aumento de la especificidad después de aplicar el algoritmo de posturas al algoritmo de detección de FoG. La media de la sensibilidad para el algoritmo de detección de FoG es de 48.8% con una desviación estándar de 5.46%. Añadiendo el algoritmo de posturas se obtiene una sensibilidad media de 47.3% con desviación estándar de 5.44%. De esta manera, la sensibilidad baja un 1.5% en promedio al añadir el algoritmo de posturas. La media de especificidad del algoritmo de detección de FoG es de 69.9% con una desviación estándar de 3.71%. Añadiendo el algoritmo de posturas se obtiene un 74.6% de especificidad con una desviación estándar de 5.67%. La especificidad aumenta un 4.7% añadiendo el algoritmo de posturas a la detección del FoG.

Desde el punto de vista de uno de los modelos, se ha escogido el modelo óptimo como define la Ecuación 9.13.

$$\begin{aligned} \text{modelo \acute{o}ptimo} &= \max(\sqrt{\text{Sensibilidad}_{PI,FI} \cdot \text{Especificidad}_{PI,FI}}) \\ &\text{Sujeto a } \text{Sensibilidad} > 0.7 \text{ y } \text{Especificidad} > 0.7 \end{aligned} \quad (9.13)$$

El modelo óptimo obtenido es  $\text{Sensibilidad}_{0,5,2} = 71.5\%$  y  $\text{Especificidad}_{0,5,2} = 74.7\%$  para el algoritmo de FoG, y  $\text{Sensibilidad}_{0,5,2} = 70.1\%$  y  $\text{Especificidad}_{0,5,2} = 79\%$  para el modelo de de detección de FoG añadiendo el algoritmo de posturas. Con el algoritmo de posturas se incrementa la especificidad un 4.3%, mientras que la sensibilidad decrece un 1.4%. Los resultados muestran una mejoría significativa en la especificidad teniendo en cuenta que no todos los pacientes realizan el protocolo de falsos positivos mencionado en el presente apartado mientras están sentados.

Los resultados obtenidos para el modelo óptimo en los 10 pacientes que no presentan episodios de FoG a los que se ha evaluado el algoritmo estando en estado motor 'ON' y estado motor 'OFF', muestran un incremento del 4.3% en especificidad. A nivel individual, la especificidad puede aumentar hasta un 11.95%, dado que el paciente pasa una gran parte del protocolo de pruebas sentado. En algunos pacientes, el aumento de la especificidad puede ser nulo, puesto que no existen falsos positivos cuando el paciente está sentado. Del mismo modo ocurre cuando se evalúa el grupo de pacientes que tienen FoG. La pérdida de verdaderos positivos ocurre cuando el paciente realiza algún movimiento de pie conflictivo, similar a un sentarse (un sentarse sin llegar a sentarse e incorporarse inmediatamente) de forma que se aplique erróneamente el modelo de SVM para SiSt-St.Si. Esto no ocurre a menudo, y el modelo acierta cuando ocurre una transición postural de sentarse o levantarse, de forma que los verdaderos positivos no se anulan prácticamente, dejando intacta la sensibilidad del algoritmo.

### ***9.3 Conclusiones acerca de la contextualización del algoritmo de detección de FoG***

El modelo propuesto por Moore y extendido por Bächlin ha sido aplicado en diferentes trabajos dado su buen rendimiento [175–177]. Sin embargo, en todos estos trabajos, las pruebas siguen siendo ambulatorias en ámbito de laboratorio. Estas

pruebas, da lugar a que no se puedan producir falsos positivos. Dentro del proyecto REMPARK, los pacientes con la PD se han analizado en sus propias casas, y se han realizado protocolos de falsos positivos para FoG, en los que se incluyen realizar algunas tareas mientras el paciente está sentado. En el caso que el paciente haga un movimiento en el cual la frecuencia principal esté ubicada en la banda definida por Moore (3-8Hz), es muy probable que se obtenga un falso positivo.

El algoritmo propuesto propone hacer un seguimiento postural del paciente y, no ejecutar el algoritmo de Moore y extendido por Bächlin en las situaciones que el paciente esté sentado. Con esto, la especificidad de los algoritmos aumentaría, aunque, si el algoritmo estuviera mal diseñado, la sensibilidad bajaría. Sin embargo se han obtenidos resultados significativos, en 20 PD con escala Hoehn & Yahr de 2.74 de media la especificidad aumenta casi un 5% dependiendo del modelo del algoritmo de Moore y Bächlin por solo un descenso del 1.5% en la sensibilidad. Estos resultados demuestran que contextualizando el algoritmo, es posible mejorar la detección del FoG.





## *Parte III: Observaciones finales*



# Capítulo 10

## Conclusiones, Perspectivas de Futuro y Publicaciones

El propósito principal de la tesis consiste en contribuir a la mejora de la monitorización de la PD diseñando un dispositivo portable de larga autonomía capaz de capturar y almacenar datos y, además, con la posibilidad de ejecutar algoritmos en tiempo real para poder monitorizar alteraciones motoras. El dispositivo portable se ha utilizado para recoger datos de pacientes y ha permitido el desarrollo de un algoritmo que contextualiza uno de los síntomas de la PD a través del conocimiento de la postura del paciente. Además de mejorar la especificidad de la detección del síntoma, conocer la postura de una persona es útil para poder monitorizar su actividad y poder evaluar la calidad de vida no sólo en pacientes con la PD sino también en personas de edad avanzada.

### *10.1 Discusiones y Conclusiones*

En este apartado se discute cada una de las temáticas de la tesis y describiendo las conclusiones finales. Este apartado está dividido siguiendo las diferentes temáticas de la tesis: el dispositivo inercial, el análisis de las posturas y su aplicación en FoG.

### ***10.1.1 Conclusiones acerca del IMU 9x2***

El 9x2 ha resultado ser una herramienta que se ha empleado en los proyectos europeos HELP y REMPARK, en el proyecto de ámbito nacional MoMoPa y además ha formado parte de otro proyecto europeo, FATE [183].

Hasta el día de hoy, en los proyectos MoMoPa y REMPARK se ha hecho uso de la capacidad del 9x2 para poder capturar señales inerciales de un acelerómetro, de un giroscopio y un magnetómetro a 200Hz con una autonomía de 36.8 horas. En el proyecto HELP se ha implementado un clasificador ‘online’ en el 9x2. El dispositivo era capaz de extraer características para el estudio de la marcha en pacientes con la PD en tiempo real y tomar decisiones mediante clasificadores basados en SVM. Dentro del proyecto FATE se ha escogido la estructura de firmware del 9x2 para poder implementar un clasificador ‘online’ de caídas.

El sistema inercial ha demostrado ser un dispositivo portable, más pequeño que la mayoría de teléfonos móviles que hay en el mercado. Además de ser un IMU competitivo por su reducido tamaño y peso, ya que es de similares valores que el resto de los IMUs, el 9x2 es el que tiene más autonomía capturando muestras a 200Hz. Además, el dispositivo presenta la posibilidad de almacenar datos inerciales con una tarjeta  $\mu$ SD o de enviarlos a través de Bluetooth. Como novedad, se presenta un dispositivo capaz de ejecutar clasificadores ‘online’ además de las características ya explicadas. Gracias a su sistema flexible compuesto por una máquina de estados, el sistema ejerce las tareas de adquisición de datos y de tratamiento de señal a la vez asignando prioridades a cada una de las acciones, con el fin de reducir el consumo manteniéndose el máximo tiempo posible en estado ‘Idle’, es decir, con la CPU del microcontrolador dormida. En este estado, sólo trabajan los periféricos configurados previamente y estos despertarán a la CPU sólo cuando ocurra algún evento. Además se le otorga la máxima prioridad al sistema de gestión de captura de datos de los sensores inerciales, asegurando la integridad de los mismos.

El uso del sistema en las distintas aplicaciones de monitorización del movimiento humano ha demostrado que el sistema es capaz de ejercer como datalogger y como clasificador en tiempo real. Asimismo, es el único dispositivo en el campo de la

dependencia que permite ambas operaciones dentro del mismo firmware y que permite capturar datos inerciales a 200 Hz con una autonomía muy elevada.

### ***10.1.2 Conclusiones acerca del análisis de posturas***

El análisis de posturas, tal como se ha resaltado en la literatura, es importante en la monitorización de la actividad de una persona para ayudar a evaluar su calidad de vida, ya sea una persona con alguna enfermedad crónica, como la PD, o también para personas mayores [5,60,64].

Tal y como se explica en el Capítulo 5, existen muchos métodos para determinar las posturas, de los cuales la mayoría utilizan varios sensores para ello. Sin embargo, hay algunos trabajos que utilizan un sólo sensor [159,160], aunque estas aproximaciones han sido bastante discutidas debido a que en ausencia de movimiento no es posible distinguir entre algunas posturas con tan sólo un acelerómetro [71,133]. En esta tesis, se demuestra que se puede determinar la postura siempre y cuando se conozcan las condiciones iniciales, en otras palabras, en qué postura se empieza ejecutar el algoritmo. Además, mediante reconocimiento de transiciones posturales, es posible determinar si la persona ha realizado una acción de 'levantarse' o de 'sentarse'. En consecuencia, es posible conocer la postura después de realizar una transición postural.

Esta tesis ha contribuido a la detección de posturas a través del diseño de 2 algoritmos: el algoritmo A45, con el sensor situado en la parte anterior-lateral del cuerpo, y el A90, situando el IMU en el lateral del tronco. En ambos algoritmos se ha comprobado la validez del algoritmo obteniendo las sensibilidades y especificidades en la detección de las diferentes posturas o actividades. Además, se han evaluado en pacientes con PD comprobando que el algoritmo funciona correctamente y validando que las transiciones SiSt y StSi son igualmente detectables para cualquier persona.

## ***10.2 Trabajo Futuro***

Dado que existen 2 grandes temáticas en esta tesis, la IMU, y el desarrollo de algoritmos para la detección de posturas, el trabajo futuro se divide también en estas 2 líneas de investigación.

### ***10.2.1 El sucesor del 9x2***

Dada la rapidez que la tecnología avanza, el 9x2 se ve obligado a experimentar cambios para adaptarse a las mejoras que los nuevos sensores y dispositivos ofrecen. Esta sección describe las mejoras a realizar de forma inminente en la nueva versión que sucederá al 9x2.

Los microcontroladores que se pueden encontrar en el mercado están ofreciendo consumos muy reducidos en comparación al modelo utilizado en el actual 9x2. Microchip está ofreciendo productos bastante similares, y no parece que haya avanzado mucho en cuanto a tecnología. Esta empresa ofrece dispositivos de 32 bits como mejora de los dsPICs, con memorias que doblan las del modelo actual (dsPIC33FJ128MC804), tanto Flash (memoria de programa) como RAM (memoria de datos). No obstante, la aparición de los microcontroladores de 32 bits, ha hecho que la DSP integrada en los dsPICs desaparezca. Sin embargo están apareciendo modelos de otras casas como STMicroelectronics, Texas Instruments, Atmel, Freescale y Energy Micro que están ofreciendo microcontroladores con más velocidad, menos consumo, más periféricos y más memoria que los PIC's de Microchip. De especial interés se ha encontrado el modelo de microcontrolador STM32F415RG. Este microcontrolador tiene un consumo menor que el modelo de dsPIC empleado ejecutando sus rutinas a la misma velocidad. Además, goza de 192 KB de RAM y 1024 KB de memoria de programa o Flash. En otras palabras, multiplica por 10 la capacidad de memoria del dsPIC. Otra de las ventajas es la velocidad que posee, y la facultad de poderse comunicar entre los distintos periféricos a través de un bus especial, con el fin de mantener a la CPU el máximo de tiempo en estado Sleep [184].

En cuanto a sensores inerciales, se están produciendo grandes avances que se deben

de tener en cuenta. Los principales fabricantes están ofreciendo los 3 sensores inerciales (acelerómetro, giroscopio y magnetómetro) en un sólo encapsulado (MPU9150/MPU9250 de Invensense, LSM333D de STMicroelectronics, BMX055 de Bosch). Además, STMicroelectronics ofrece un dispositivo que integra 3 sensores inerciales separados en un espacio muy reducido junto con un microcontrolador Cortex-M3 con un firmware específico para el tratamiento de datos inerciales (iNEMO-M1) [185].

El hecho de tener 3 sensores integrados en un mismo encapsulado aumenta la integridad de los datos, puesto que las 3 señales se tratan de la misma forma en el mismo circuito y se digitaliza y compacta en una trama generalmente I<sup>2</sup>C o SPI. El 9x2 por su parte, requiere de un tratamiento por separado y las señales analógicas son más susceptibles a ruidos intrínsecos de la PCB. Sin embargo, a pesar de que el circuito del 9x2 está diseñado para no generar ruido en la señal analógica, siempre es mejor tratar la señal en el mismo punto que el transductor. Además, se obtiene un sólo punto como origen de coordenadas dado que los 3 sensores inerciales están en un mismo encapsulado. El 9x2 por su parte tiene los 3 sensores inerciales separados por algunos centímetros, en consecuencia, el sistema tiene 3 puntos de origen de coordenadas.

En cuanto a comunicaciones, la tecnología Bluetooth V2.1 está evolucionando a la versión 4, siendo ésta de menor consumo, más prestaciones en cuanto a la creación de redes y más velocidad de transmisión de datos. Entre los dispositivos de más interés destaca el BLE113, de Bluegiga. El consumo de este dispositivo es aproximadamente la mitad que el actual WT12 trabajando en las mismas condiciones de velocidad. Además permite realizar más topologías de redes, cuya ventaja es la posibilidad de montar redes de sensores inerciales [186]. La tarjeta  $\mu$ SD está diseñada para almacenar datos hasta 3 días y 19 horas muestreando a 200 Hz, o 19 días y 10 horas. El sistema FAT16 permite tamaños de tarjeta  $\mu$ SD de hasta 2 GB, pero si el sistema de archivos implantado es FAT32, la expectativa es de una capacidad de 1 mes con una tarjeta  $\mu$ SD de 16 GB, o 15 días para una tarjeta de de 8 GB muestreando a 200 Hz.

### ***10.2.2 Hacia una generalización del algoritmo de posturas***

Una de las líneas de trabajo futuro las que ya se está trabajando es unir los algoritmos

A45 y A90 en un único algoritmo, de forma que no importe la posición en el cual se coloque el sensor. Si bien es cierto que los terapeutas colocan el sensor inercial siguiendo el protocolo de pruebas del proyecto REMARK, en la vida real y sin terapeutas, es muy posible que un paciente no se coloque el sensor correctamente. Además, según la postura, el sensor puede desplazarse de forma que los algoritmos no acaben funcionando si dependen de la posición de la cintura. Para lograr este objetivo, es necesario poder combinar ambos algoritmos para corregir este error. La idea es poder entrenar y validar con las 2 bases de datos hechas para el algoritmo A45 y A90. Son 2 bases de datos independientes con diferentes personas y con diferentes pruebas.

Otro aspecto importante en la detección de posturas es la mejora del algoritmo de detección de la marcha a nivel de pacientes de Parkinson. Se debe diseñar un algoritmo específico para personas con la PD, puesto que no es posible asumir que una persona con la PD y otra sana caminen igual.

Como parte de la aplicación en el FoG, contextualizar los episodios puede ser de suma importancia para la evaluación de la enfermedad. Esto ya se puede conocer a través del algoritmo de posturas, sobre todo cuando la persona se levanta y se dispone a caminar. Sin embargo, una de las líneas que se llevan en el centro es la de poder combinar información de la Microsoft Kinect. Se ha realizado un estudio en forma de publicación que sugiere que es posible contextualizar aún más donde ocurren los episodios de FoG (proximidad a objetos, espacios estrechos, llegadas a un destino, giros, o dobles tareas) [181,182].

Otra línea de investigación es, además de la contextualización del FoG, la detección de un episodio de FoG. El algoritmo propuesto por Moore y extendido por Bächlin funciona con una especificidad y sensibilidad entorno al 80%, pero se ha visto que con umbrales genéricos puede no funcionar adecuadamente obteniendo valores muy bajos de sensibilidad o especificidad [49]. Sin embargo, con los umbrales específicos se obtienen resultados muy elevados. Uno de los objetivos de trabajo futuro debe ser la detección de episodios de FoG mediante un algoritmo genérico que pueda ser capaz de identificar episodios en cualquier paciente sin necesidad de adaptación. Esta línea está bastante estancada, ya que los últimos trabajos están enfocados en cómo responde el algoritmo de detección de FoG en diferentes partes del cuerpo, con diferentes tamaños

de ventana y diferentes umbrales, pero sin moverse de la línea principal [187]. Otro estudio propone nuevos indicadores para contextualizar el FoG como estudiar latidos del corazón o niveles de oxígeno en la hemoglobina, una proteína de la sangre [188]. Sin embargo, queda una línea a explorar en cuanto a características en un episodio de FoG en el estudio del movimiento. Es posible investigar nuevas características, o situaciones concretas que lleven a un episodio de FoG mediante técnicas probabilísticas, puesto que es más frecuente que el paciente manifieste un episodio de FoG en una situación que en otra. El FoG sigue siendo un trastorno complicado de estudiar, pero la línea sigue abierta y con muchas posibilidades.

### **10.3 Publicaciones**

**Contribuciones en el campo de dispositivos inerciales y aplicaciones en la enfermedad del Parkinson:**

- Rodríguez-Martín, D.; Pérez-López, C.; Samà, A.; Cabestany, J.; Català, A. A Wearable Inertial Measurement Unit for Long-Term Monitoring in the Dependency Care Area. *Sensors* 2013, 13, 14079–14104.
- Takač, B.; Català, A.; Rodríguez-Martín, D.; Chen, W.; Rauterberg, M. Ambient sensor system for freezing of gait detection by spatial context analysis. In *Proceedings of the 4th international conference on Ambient Assisted Living and Home Care*; 2012; pp. 232–239
- Samà, A.; Perez-Lopez, C.; Romagosa, J.; Rodríguez-Martín, D.; Català, A.; Cabestany, J.; Perez-Martínez, D. A.; Rodríguez-Molinero, A. Dyskinesia and motor state detection in Parkinson's Disease patients with a single movement sensor. In *Engineering in Medicine and Biology Society, 2012. EMBS 2008. 34th Annual International Conference of the IEEE*; 2012; pp. 1194–1197

- Takač, B.; Català, A.; Rodríguez Martín, D.; van der Aa, N.; Chen, W.; Rauterberg, M. Position and Orientation Tracking in a Ubiquitous Monitoring System for Parkinson Disease Patients With Freezing of Gait Symptom. *JMIR mhealth uhealth* 2013, 1, e14
- Samà, A.; Perez-Lopez, C.; Rodriguez-Martin, D.; Cabestany, J.; Moreno, J. M.; Rodriguez-Molinero, A. A Heterogeneous Database for Movement Knowledge Extraction in Parkinson' s Disease. In *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*; 2013

#### **Contribuciones en el campo del análisis de posturas:**

- Rodríguez-Martin, D.; Samà, A.; Perez-Lopez, C.; Català, A.; Cabestany, J.; Rodríguez-Molinero, A. SVM-based posture identification with a single waist-located triaxial accelerometer. *Expert Syst. Appl.* 2013, 40, 7203–7211
- Rodríguez-Martín, D.; Samà, A.; Pérez-López, C.; Català, A. Identification of sit-to-stand and stand-to-sit transitions using a single inertial sensor. *Stud. Health Technol. Inform.* 2012, 177, 113–7
- Rodríguez-Martín, D.; Samà, A.; Pérez-López, C.; Català, A.; Cabestany, J.; Rodríguez-Molinero, A. Identification of Postural Transitions Using a Waist-Located Inertial Sensor. In *International Work Conference on Artificial Neural Networks. Lecture Notes on Computer Science.*; Springer-Verlag, 2013; Vol. 7903, pp. 142–149
- Rodríguez-Martín, D.; Samà, A.; Pérez-López, C.; Cabestany, J.; Català, A.; Rodríguez-Molinero, A. Enhancing FoG detection by means of postural context using a waist accelerometer. In *First International Freezing of Gait Congress*; Dead Sea, Israel. Aceptado. 2014.



# Referencias

1. Zwartjes, D.; Heida, T.; van Vugt, J.; Geelen, J.; Veltink, P. Ambulatory Monitoring of Activities and Motor Symptoms in Parkinson's Disease. *IEEE transactions on bio-medical engineering* **2010**, *57*, 2778–2786.
2. Moore, S. T.; MacDougall, H. G.; Ondo, W. G. Ambulatory monitoring of freezing of gait in Parkinson's disease. *Journal of neuroscience methods* **2008**, *167*, 340–8.
3. Becq, G.; Bonnet, S.; Minotti, L.; Antonakios, M.; Guillemaud, R.; Kahane, P. Classification of epileptic motor manifestations using inertial and magnetic sensors. *Computers in biology and medicine* **2011**, *41*, 46–55.
4. Mizuike, C.; Ohgi, S.; Morita, S. Analysis of stroke patient walking dynamics using a tri-axial accelerometer. *Gait & posture* **2009**, *30*, 60–4.
5. Culhane, K. M.; O'Connor, M.; Lyons, D.; Lyons, G. M. Accelerometers in rehabilitation medicine for older adults. *Age and ageing* **2005**, *34*, 556–60.
6. Fulk, G. D.; Sazonov, E. Using Sensors to Measure Activity in People with Stroke. *Topics in Stroke Rehabilitation* **2012**, *18*, 746–757.
7. Krosshaug, T.; Andersen, T. E.; Olsen, O.-E. O.; Myklebust, G.; Bahr, R. Research approaches to describe the mechanisms of injuries in sport: limitations and possibilities. *British journal of sports medicine* **2005**, *39*, 330–9.
8. Picerno, P.; Camomilla, V.; Capranica, L. Countermovement jump performance assessment using a wearable 3D inertial measurement unit. *Journal of sports sciences* **2011**, *29*, 139–46.
9. Lukowicz, P.; Hanser, F.; Szubski, C.; Schobersberger, W. Detecting and Interpreting Muscle Activity with Wearable Force Sensors. *Pervasive Computing, Lecture Notes in Computer Science* **2006**, *3968*, 101–116.

10. Stančin, S.; Tomažič, S. Early improper motion detection in golf swings using wearable motion sensors: the first approach. *Sensors (Basel, Switzerland)* **2013**, *13*, 7505–21.
11. King, K.; Yoon, S. W.; Perkins, N. C.; Najafi, K. Wireless MEMS inertial sensor system for golf swing dynamics. *Sensors and Actuators A: Physical* **2008**, *141*, 619–630.
12. Siirtola, P.; Laurinen, P.; Roning, J.; Kinnunen, H. Efficient accelerometer-based swimming exercise tracking. *2011 IEEE Symposium on Computational Intelligence and Data Mining (CIDM)* **2011**, 156–161.
13. Yazdi, N.; Ayazi, F.; Najafi, K.; Member, S. Micromachined Inertial Sensors. *Proceedings of the IEEE* **1998**, *86*, 1640–1659.
14. Beeby, S.; Ensell, G.; Kraft, M.; White, N. *MEMS. Mechanical Sensors*; Artech House, 2004.
15. *MoMoPa-Monitoring the Mobility of Parkinson's Patients for Therapeutic Purposes. PI08/90756. FIS. ISCIII. 2009-2010.*
16. *HELP-Home-based Empowered Living for Parkinson's Disease. AAL-2008-1-022. 2008-2011.*
17. European Projects Association. [www.europeanprojects.org/awards/winners2013](http://www.europeanprojects.org/awards/winners2013).
18. *REMPARK-Personal Health Device for the Remote and Autonomous Management of Parkinson's Disease. FP7-ICT-2011-7-287677. 2011-2014.*
19. Hoehn, M. M.; Yahr, M. D. Parkinsonism: onset, progression, and mortality. *Neurology* **1967**, *17*, 427–427.
20. Fahn, S.; Elton, R. Unified rating scale for Parkinson's Disease. *Recent developments in Parkinson's disease* **1987**, 153–163.
21. Movement Disorders Society State of the Art Review. The Unified Parkinson's Disease Rating Scale (UPDRS): Status and Recommendations. *Movement Disorders* **2003**, *18*, 738–750.
22. Andlin-Sobocki, P.; Jönsson, B.; Wittchen, H. U.; Olesen, J. Costs of disorders of the brain in Europe. *European journal of neurology: the official journal of the European Federation of Neurological Societies* **2005**, *12*, 1–27.
23. Braak, H.; Ghebremedhin, E.; Rüb, U.; Bratzke, H.; Del Tredici, K. Stages in the development of Parkinson's disease-related pathology. *Cell and tissue research* **2004**, *318*, 121–34.
24. Fearnley, J. M.; Lees, A. J. Ageing and Parkinson's Disease: Substantia Nigra Regional Selectivity. *Brain* **1991**, *114*, 2283–2301.

25. Braak, H.; Braak, E. Pathoanatomy of Parkinson's disease. *Journal of Neurology* **2000**, *247*, II3–II10.
26. Veltink, P. H.; Engberink, E. G. O.; Van Hilten, B. J.; Dunnewold, R.; Jacobi, C. Towards a new method for kinematic quantification of bradykinesia in patients with Parkinson's disease using triaxial accelerometry. In *Proceedings of 17th International Conference of the Engineering in Medicine and Biology Society*; IEEE, 1995; Vol. 2, pp. 1303–1304.
27. Pastorino, M.; Cancela, J.; Arredondo, M. T.; Pansera, M.; Pastor-Sanz, L.; Villagra, F.; Pastor, M. A.; Martin, J. A. Assessment of Bradykinesia in Parkinson's disease patients through a multi-parametric system. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society.*; 2011; Vol. 2011, pp. 1810–1813.
28. Manson, A. J.; Brown, P.; O'Sullivan, J. D.; Asselman, P.; Buckwell, D.; Lees, A. J. An ambulatory dyskinesia monitor. *Journal of Neurology, Neurosurgery & Psychiatry* **2000**, *68*, 196–201.
29. Keijsers, N. L. W.; Horstink, M. W. I. M.; Gielen, S. C. a M. Ambulatory motor assessment in Parkinson's disease. *Movement Disorders* **2006**, *21*, 34–44.
30. Dunnewold, R. J. W.; Hoff, J. I.; van Pelt, H. C. J.; Fredrikze, P. Q.; Wagemans, E. A. H.; van Hilten, B. J. J. Ambulatory Quantitative Assessment of Body Position, Bradykinesia, and Hypokinesia in Parkinson's Disease. *Journal of Clinical Neurophysiology* **1998**, *15*, 235–242.
31. Giladi, N.; Nieuwboer, A. Understanding and treating freezing of gait in parkinsonism, proposed working definition, and setting the stage. *Movement Disorders* **2008**, *23*, 423–425.
32. Moreau, C.; Defebvre, L.; Bleuse, S.; Blatt, J. L.; Duhamel, A.; Bloem, B. R.; Destée, A.; Krystkowiak, P. Externally provoked freezing of gait in open runways in advanced Parkinson's disease results from motor and mental collapse. *Journal of neural transmission* **2008**, *115*, 1431–1436.
33. Lees, a J. The on-off phenomenon. *Journal of neurology, neurosurgery, and psychiatry* **1989**, *Suppl*, 29–37.
34. Nutt, J. G.; Woodward, W. R.; Hammerstad, J. P.; Carter, J. H.; Anderson, J. L. The On–Off Phenomenon in Parkinson's Disease. *New England Journal of Medicine* **1984**, *310*, 483–488.
35. Zappia, M.; Nicoletti, A.; Muñoz-S, D.; Tapia-Núñez, J. Reconsideraciones en el tratamiento de la enfermedad de Parkinson con levodopa : evidencias farmacodinámicas. *REVISTA DE NEUROLOGÍA* **2009**, *49*, 33–40.

36. Bartels, A. .; Balash, Y.; Gurevich, T.; Schaafsma, J. .; Hausdorff, J. .; Giladi, N. Relationship between freezing of gait (FOG) and other features of Parkinson's: FOG is not correlated with bradykinesia. *Journal of Clinical Neuroscience* **2003**, *10*, 584–588.
37. Grimbergen, Y. A.; Munneke, M.; Bloem, B. R. Falls in Parkinson's disease. *Current opinion in neurology* **2004**, *17*, 405–415.
38. Bloem, B. R.; Hausdorff, J. M.; Visser, J. E.; Giladi, N. Falls and freezing of gait in Parkinson's disease: a review of two interconnected, episodic phenomena. *Movement disorders : official journal of the Movement Disorder Society* **2004**, *19*, 871–84.
39. Schrag, A.; Hovris, A.; Morley, D.; Quinn, N.; Jahanshahi, M. Caregiver-burden in parkinson's disease is closely associated with psychiatric symptoms, falls, and disability. *Parkinsonism & related disorders* **2006**, *12*, 35–41.
40. Giladi, N.; Treves, T. a; Simon, E. S.; Shabtai, H.; Orlov, Y.; Kandinov, B.; Paleacu, D.; Korczyn, a D. Freezing of gait in patients with advanced Parkinson's disease. *Journal of neural transmission Vienna Austria 1996* **2001**, *108*, 53–61.
41. Schaafsma, J. D.; Balash, Y.; Gurevich, T.; Bartels, a. L.; Hausdorff, J. M.; Giladi, N. Characterization of freezing of gait subtypes and the response of each to levodopa in Parkinson's disease. *European Journal of Neurology* **2003**, *10*, 391–398.
42. Nieuwboer, A.; Baker, K.; Willems, A.-M.; Jones, D.; Spildooren, J.; Lim, I.; Kwakkel, G.; Van Wegen, E.; Rochester, L. The short-term effects of different cueing modalities on turn speed in people with Parkinson's disease. *Neurorehabilitation and neural repair* **2009**, *23*, 831–6.
43. Arias, P.; Cudeiro, J. Effect of rhythmic auditory stimulation on gait in Parkinsonian patients with and without freezing of gait. *PloS one* **2010**, *5*, 8.
44. Lim, I.; van Wegen, E.; de Goede, C.; Deutekom, M.; Nieuwboer, A.; Willems, A.; Jones, D.; Rochester, L.; Kwakkel, G. Effects of external rhythmical cueing on gait in patients with Parkinson's disease: a systematic review. *Clinical rehabilitation* **2005**, *19*, 695–713.
45. Okuma, Y. Freezing of gait in Parkinson's disease. *Journal of neurology* **2006**, *253*, VII27–32.
46. Giladi, N.; Hausdorff, J. M. The role of mental function in the pathogenesis of freezing of gait in Parkinson's disease. *Journal of the neurological sciences* **2006**, *248*, 173–6.
47. Nutt, J. G.; Bloem, B. R.; Giladi, N.; Hallett, M.; Horak, F. B.; Nieuwboer, A. Freezing of gait: moving forward on a mysterious clinical phenomenon. *Lancet neurology* **2011**, *10*, 734–44.

48. Hausdorff, J. M.; Balash, Y.; Giladi, N. Time series analysis of leg movements during freezing of gait in Parkinson ' s disease : akinesia , rhyme or reason ? *Physica A* **2003**, *321*, 565–570.
49. Bächlin, M.; Roggen, D.; Plotnik, M.; Hausdorff, J. M.; Giladi, N.; Tröster, G. Online Detection of Freezing of Gait in Parkinson's Disease Patients: A Performance Characterization. *Proceedings of the 4th International ICST Conference on Body Area Networks* **2009**.
50. Nieuwboer, A.; Weerdt, W. De; Desloovere, K.; Fieuws, S.; Broens-kaucsik, E. Abnormalities of the Spatiotemporal Characteristics of Gait at the Onset of Freezing in Parkinson ' s Disease. *Movement Disorders* **2001**, *16*, 1066–1075.
51. Delval, A.; Snijders, A. H.; Weerdesteyn, V.; Duysens, J. E.; Defebvre, L.; Giladi, N.; Bloem, B. R. Objective detection of subtle freezing of gait episodes in Parkinson's disease. *Movement disorders : official journal of the Movement Disorder Society* **2010**, *25*, 1684–93.
52. Knobl, P.; Kielstra, L.; Almeida, Q. The relationship between motor planning and freezing of gait in Parkinson's disease. *Journal of neurology, neurosurgery, and psychiatry* **2012**, *83*, 98–101.
53. Nieuwboer, A.; De Weerdt, W.; Dom, R.; Lesaffre, E. A frequency and correlation analysis of motor deficits in Parkinson patients. *Disability and rehabilitation* **1998**, *20*, 142–150.
54. Giladi, N.; Tal, J.; Azulay, T.; Rascol, O.; Brooks, D. J.; Melamed, E.; Oertel, W.; Poewe, W. H.; Stocchi, F.; Tolosa, E. Validation of the freezing of gait questionnaire in patients with Parkinson's disease. *Movement Disorders* **2009**, *24*, 655–661.
55. Nieuwboer, A.; Rochester, L.; Herman, T.; Vandenberghe, W.; Emil, G. E.; Thomaes, T.; Giladi, N. Reliability of the new freezing of gait questionnaire: agreement between patients with Parkinson's disease and their carers. *Gait & posture* **2009**, *30*, 459–463.
56. Bächlin, M.; Roggen, D.; Plotnik, M.; Hausdorff, J. M.; Tröster, G. Experiences in Developing a Wearable Gait Assistant for Parkinson's Disease Patients.
57. Ermes, M.; Pärkka, J.; Mantyjarvi, J.; Korhonen, I. Detection of daily activities and sports with wearable sensors in controlled and uncontrolled conditions. *IEEE transactions on information technology in biomedicine : a publication of the IEEE Engineering in Medicine and Biology Society* **2008**, *12*, 20–6.
58. Brodie, M.; Walmsley, A.; Page, W. Fusion motion capture: a prototype system using inertial measurement units and GPS for the biomechanical analysis of ski racing. *Sports Technology* **2008**, *1*, 17–28.

59. Avci, A.; Bosch, S.; Marin-Perianu, M.; Marin-Perianu, R. S.; Havinga, P. J. M. Activity recognition using inertial sensing for Healthcare, wellbeing and sports applications: A survey. *23th International Conference on Architecture of Computing Systems, ARCS 2010, Hannover, Germany* **2010**, 167–176.
60. Zijlstra, W.; Aminian, K. Mobility assessment in older people: new possibilities and challenges. *European Journal of Ageing* **2007**, *4*, 3–12.
61. Salarian, A.; Russmann, H.; Wider, C.; Burkhard, P. R.; Vingerhoets, F. J. G.; Aminian, K. Quantification of tremor and bradykinesia in Parkinson's disease using a novel ambulatory monitoring system. *IEEE transactions on bio-medical engineering* **2007**, *54*, 313–22.
62. Weiss, A.; Herman, T.; Plotnik, M.; Brozgol, M.; Maidan, I.; Giladi, N.; Gurevich, T.; Hausdorff, J. M. Can an accelerometer enhance the utility of the Timed Up & Go Test when evaluating patients with Parkinson's disease? *Medical Engineering & Physics* **2010**, *32*, 119–125.
63. Foerster, F.; Smeja, M.; Fahrenberg, J. Detection of posture and motion by accelerometry: a validation study in ambulatory monitoring. *Computers in Human Behavior* **1999**, *15*, 571–583.
64. Najafi, B.; Aminian, K.; Paraschiv-Ionescu, A.; Loew, F.; Bula, C. J.; Robert, P. Ambulatory system for human motion analysis using a kinematic sensor: monitoring of daily physical activity in the elderly. *IEEE Transactions on Biomedical Engineering* **2003**, *50*, 711–723.
65. Godfrey, A.; Conway, R.; Meagher, D.; O'Laighin, G. Direct measurement of human movement by accelerometry. *Medical engineering & physics* **2008**, *30*, 1364–86.
66. Brandes, M.; Schomaker, R.; Möllenhoff, G.; Rosenbaum, D. Quantity versus quality of gait and quality of life in patients with osteoarthritis. *Gait & posture* **2008**, *28*, 74–9.
67. Auvinet, B.; Berrut, G.; Touzard, C.; Moutel, L.; Collet, N.; Chaleil, D.; Barrey, E. Reference data for normal subjects obtained with an accelerometric device. *Gait & posture* **2002**, *16*, 124–34.
68. Samà, A.; Perez-Lopez, C.; Romagosa, J.; Rodriguez-Martin, D.; Català, A.; Cabestany, J.; Perez-Martínez, D. A.; Rodríguez-Molinero, A. Dyskinesia and motor state detection in Parkinson's Disease patients with a single movement sensor. In *Engineering in Medicine and Biology Society, 2012. EMBS 2008. 34th Annual International Conference of the IEEE; 2012*; pp. 1194–1197.
69. Mathie, M. J.; Coster, A. C. F.; Lovell, N. H.; Celler, B. G. Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement. *Physiological Measurement* **2004**, *25*, 1–20.

70. Zheng, H.; Black, N. D.; Harris, N. D. Position-sensing technologies for movement analysis in stroke rehabilitation. *Medical & biological engineering & computing* **2005**, *43*, 413–20.
71. Gjoreski, H.; Lustrek, M.; Gams, M. Accelerometer Placement for Posture Recognition and Fall Detection. In *2011 Seventh International Conference on Intelligent Environments*; Ieee, 2011; pp. 47–54.
72. Preece, S. J.; Goulermas, J. Y.; Kenney, L. P. J.; Howard, D.; Meijer, K.; Crompton, R. Activity identification using body-mounted sensors—a review of classification techniques. *Physiological measurement* **2009**, *30*, R1–33.
73. Mannini, A.; Sabatini, A. M. Machine learning methods for classifying human physical activity from on-body accelerometers. *Sensors (Basel, Switzerland)* **2010**, *10*, 1154–75.
74. Yang, C. C.; Hsu, Y. L. A review of accelerometry-based wearable motion detectors for physical activity monitoring. *Sensors (Basel, Switzerland)* **2010**, *10*, 7772–88.
75. Taraldsen, K.; Chastin, S. F. M.; Riphagen, I. I.; Vereijken, B.; Helbostad, J. L. Physical activity monitoring by use of accelerometer-based body-worn sensors in older adults: a systematic literature review of current knowledge and applications. *Maturitas* **2012**, *71*, 13–9.
76. Vigna, B. More than Moore : micro-machined products enable new applications and open new markets. In *IEEE International Electron Devices Meeting*; 2005; Vol. 00, p. 8.
77. Puers, R. Capacitive sensors: When and how to use them. *Sensors and Actuators A: Physical* **1993**, *37–38*, 93–105.
78. STMicroelectronics, Inc. LIS3LV02DQ datasheet. MEMS Inertial Sensor. 2005.
79. Invensense, Inc. IDG650. Dual-Axis Gyroscope Product Specification. 2009.
80. Invensense, Inc. ISZ650. Single-Axis Gyroscope Product Specification 2009.
81. Gouwanda, D.; Senanayake, S. M. Periodical gait asymmetry assessment using real-time wireless gyroscopes gait monitoring system. *Journal of Medical Engineering & Technology* **2011**, *35*, 432–440.
82. Najafi, B.; Aminian, K.; Loew, F.; Blanc, Y.; Robert, P. A. Measurement of stand-sit and sit-stand transitions using a miniature gyroscope and its application in fall risk evaluation in the elderly. *IEEE Transactions on Biomedical Engineering* **2002**, *49*, 843–851.
83. Li, Q.; Stankovic, J. a.; Hanson, M. a.; Barth, A. T.; Lach, J.; Zhou, G. Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information. In

- 2009 *Sixth International Workshop on Wearable and Implantable Body Sensor Networks*; 2009; pp. 138–143.
84. Lenz, J.; Edelstein, S. Magnetic sensors and their applications. *IEEE Sensors Journal* **2006**, *6*, 631–649.
85. Honeywell, Inc. 2-Axis Magnetic Sensor Circuit. HMC6042 datasheet 2007.
86. Honeywell, Inc. 1-Axis Magnetic Sensor. HMC1041Z. 2005.
87. Yang, H. H.; Myung, N. V.; Yee, J.; Park, D.-Y.; Yoo, B.-Y.; Schwartz, M.; Nobe, K.; Judy, J. W. Ferromagnetic micromechanical magnetometer. *Sensors and Actuators A: Physical* **2002**, *97-98*, 88–97.
88. Troiano, R. P.; Berrigan, D.; Dodd, K. W.; Mâsse, L. C.; Tilert, T.; McDowell, M. Physical activity in the United States measured by accelerometer. *Medicine and science in sports and exercise* **2008**, *40*, 181–8.
89. James, D. A.; Davey, N.; Rice, T. An accelerometer based sensor platform for insitu elite athlete performance analysis. In *Proceedings of IEEE Sensors, 2004.*; Ieee, 2004; pp. 1373–1376.
90. Patel, S.; Lorincz, K.; Hughes, R.; Huggins, N.; Growdon, J.; Standaert, D.; Akay, M.; Dy, J.; Welsh, M.; Bonato, P.; Member, S. Monitoring Motor Fluctuations in Patients With Parkinson ' s Disease Using Wearable Sensors. *IEEE transactions on information technology in biomedicine* **2009**, *13*, 864–873.
91. Kostek, B.; Kaszuba, K.; Zwan, P.; Robowski, P.; Slawek, J. Automatic assessment of the motor state of the Parkinson's disease patient--a case study. *Diagnostic pathology* **2012**, *7*, 18.
92. Weenk, D.; van Beijnum, B.-J.; Baten, C. T. M.; Hermens, H.; Veltink, P. Automatic identification of inertial sensor placement on human body segments during walking. *Journal of NeuroEngineering and Rehabilitation* **2013**, *10*, 31.
93. Zhou, H.; Hu, H. Human motion tracking for rehabilitation—A survey. *Biomedical Signal Processing and Control* **2008**, *3*, 1–18.
94. Feliz, R.; Zalama, E.; García-bermejo, J. G. Pedestrian tracking using inertial sensors. **2009**, *3*, 35–43.
95. Saber-Sheikh, K.; Bryant, E. C.; Glazzard, C.; Hamel, A.; Lee, R. Y. W. Feasibility of using inertial sensors to assess human movement. *Manual Therapy* **2010**, *15*, 122–125.
96. Britt, W. R.; Miller, J.; Waggoner, P.; Bevly, D. M.; Hamilton Jr, J. A. An embedded system for real-time navigation and remote command of a trained canine. *Personal Ubiquitous Comput.* **2011**, *15*, 61–74.

97. Rantakokko, J.; Emilsson, E.; Stromback, P.; Rydell, J. Scenario-based evaluations of high-accuracy personal positioning systems. In *Proceedings of the 2012 IEEE/ION Position, Location and Navigation Symposium*; Ieee, 2012; pp. 106–112.
98. Xsens Technologies B.V. [www.xsens.com](http://www.xsens.com).
99. Shimmer Research [www.shimmer-research.com](http://www.shimmer-research.com).
100. O'Donovan, K. J.; Greene, B. R.; McGrath, D.; O'Neill, R.; Burns, A.; Caulfield, B. SHIMMER: A new tool for temporal gait analysis. *Conference proceedings: ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference* **2009**, 2009, 3826–9.
101. KineO Electro Goniometer. Datasheet. <http://www.technoconcept.fr/>.
102. Measurement, EPFL-Laboratory of movement analysis and measurement. <http://lmam.epfl.ch/>.
103. Mariani, B.; Jim, C. On-Shoe Wearable Sensors for Gait and Turning Assessment of Patients With Parkinson ' s Disease. **2013**, *60*, 155–158.
104. White, D. K.; Wagenaar, R. C.; Ellis, T. Monitoring activity in individuals with Parkinson disease: a validity study. *Journal of neurologic physical therapy: JNPT* **2006**, *30*, 12–21.
105. Rochester, L.; Nieuwboer, A.; Baker, K.; Hetherington, V.; Willems, A.-M.; Chavret, F.; Kwakkel, G.; Van Wegen, E.; Lim, I.; Jones, D. The attentional cost of external rhythmical cues and their impact on gait in Parkinson's disease: effect of cue modality and task complexity. *Journal of neural transmission* **2007**, *114*, 1243–8.
106. Lord MicroStrain Inc. Inertial Sensors 3DM-GX1. Technical Product Overview. <http://www.microstrain.com/inertial/3DM-GX1>.
107. Sparkfun Electronics ® <https://www.sparkfun.com/products/9980>.
108. Zhang, K.; Werner, P.; Sun, M.; Pi-Sunyer, F. X.; Boozer, C. N. Measurement of human daily physical activity. *Obesity research* **2003**, *11*, 33–40.
109. Huddleston, J.; Alaiti, A.; Goldvasser, D.; Scarborough, D.; Freiberg, A.; Rubash, H.; Malchau, H.; Harris, W.; Krebs, D. Ambulatory measurement of knee motion and physical activity: preliminary evaluation of a smart activity monitor. *Journal of neuroengineering and rehabilitation* **2006**, *3*, 21.
110. De Bruin, E. D.; Hubli, M.; Hofer, P.; Wolf, P.; Murer, K.; Zijlstra, W. Validity and reliability of accelerometer-based gait assessment in patients with diabetes on challenging surfaces. *Journal of aging research* **2012**, *2012*, 954378.

111. Van Hees, V. T.; Slootmaker, S. M.; De Groot, G.; Van Mechelen, W.; Van Lummel, R. C. Reproducibility of a triaxial seismic accelerometer (DynaPort). *Medicine and science in sports and exercise* **2009**, *41*, 810–7.
112. Godfrey, a; Culhane, K. M.; Lyons, G. M. Comparison of the performance of the activPAL Professional physical activity logger to a discrete accelerometer-based activity monitor. *Medical engineering & physics* **2007**, *29*, 930–4.
113. Rowlands, A. V.; Thomas, P. W. M.; Eston, R. G.; Topping, R. Validation of the RT3 triaxial accelerometer for the assessment of physical activity. *Medicine and science in sports and exercise* **2004**, *36*, 518–524.
114. Stayhealthy Inc. Tech Specs-RT3. [http://www.stayhealthy.com/en\\_us/main/rt3tech](http://www.stayhealthy.com/en_us/main/rt3tech).
115. FATE-Fall Detector for the Elder. FP7-CIP-ICT-PSP-2011-5-297178. 2011-2014.
116. Cabestany, J.; Moreno, J. M.; Perez, C.; Sama, A.; Catala, A. REMPARK: When AI and Technology Meet Parkinson Disease Assessment. In *20th International Conference on Mixed Design of Integrated Circuits and Systems*; 2013.
117. Cabestany, J.; Moreno, J. M.; Perez, C.; Sama, A.; Catala, A. FATE: One Step Towards an Automatic Aging People Fall Detection Service. In *20th International Conference on Mixed Design of Integrated Circuits and Systems*; 2013.
118. FATE-Fall Detector for the Elder. FP7-CIP-ICT-PSP-2011-5-297178. 2011-2014.
119. Zhou, S.; Shan, Q.; Fei, F.; Li, W. J.; Wu, P. C. K.; Meng, B.; Chan, C. K. H.; Liou, J. Y. J. Gesture recognition for interactive controllers using MEMS motion sensors. In *2009 4th IEEE International Conference on Nano/Micro Engineered and Molecular Systems*; 2009; pp. 935–940.
120. Mathie, M. J.; Basilakis, J.; Celler, B. G. A system for monitoring posture and physical activity using accelerometers. *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society* **2001**, *4*, 3654–3657.
121. Bouten, C. V.; Koekkoek, K. T.; Verduin, M.; Kodde, R.; Janssen, J. D. A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity. *IEEE transactions on bio-medical engineering* **1997**, *44*, 136–47.
122. Giansanti, D.; Maccioni, G.; Macellari, V. Guidelines for Calibration and Drift Compensation of a Wearable Device with Rate-Gyroscopes and Accelerometers. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society.*; 2007; Vol. 2007, pp. 2342–5.
123. Thurlby Thandar Instruments Inc. QL355T & QL355TP Precision Power Supplies. Instruction Manual. 2003.

124. Agilent Technologies Inc. Agilent 53131A/132A/181A Counters. Data sheet. 2001.
125. Microchip, Inc ©. dsPIC33FJ32MC302 / 304, dsPIC33FJ64MCX02 / X04, and dsPIC33FJ128MCX02 / X04 Data Sheet. 2008.
126. Bluegiga. WT12 data sheet versión 2.5. 2008.
127. Bonnet, S.; Héliot, R. A. A Magnetometer-Based Approach for Studying. **2007**, *54*, 1353–1355.
128. Schepers, H. M.; Roetenberg, D.; Veltink, P. H. Ambulatory human motion tracking by fusion of inertial and magnetic sensing with adaptive actuation. *Medical & biological engineering & computing* **2010**, *48*, 27–37.
129. Disk SD Card Product Family. OEM Product Manual. V.2.2. 1997.
130. Bächlin, M.; Plotnik, M.; Roggen, D.; Giladi, N.; Hausdorff, J. M.; Tröster, G. A wearable system to assist walking of Parkinson s disease patients. *Methods of information in medicine* **2010**, *49*, 88–95.
131. Yong, C. Y.; Sudirman, R.; Mahmood, N. H.; Chew, K. M.; Rahim, A. H. A.; Zainudin, M. N. H. Time-Frequency Domain and Spectrogram Distribution for Human Motion and Movement Behaviour Analysis. In *2012 International Conference on Biomedical Engineering and Biotechnology*; 2012; pp. 943–946.
132. Anguita, D.; Ghio, A.; Oneto, L.; Parra, X.; Reyes-Ortiz, J. L. Energy Efficient Smartphone-Based Activity Recognition using Fixed-Point Arithmetic. Special Session in Ambient Assisted Living: Home Care. *Journal of Universal Computer Science* **2013**.
133. Rodriguez-Martin, D.; Samà, A.; Perez-Lopez, C.; Català, A.; Cabestany, J.; Rodriguez-Molinero, A. SVM-based posture identification with a single waist-located triaxial accelerometer. *Expert Systems with Applications* **2013**, *40*, 7203–7211.
134. Jain, A. K.; Duin, R. P. W.; Mao, J. Statistical Pattern Recognition : A Review. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **2000**, *22*, 4–37.
135. Simon, H. *Machine Learning*; Michalski, R. S.; Carbonell, J. G.; Mitchell, T. M., Eds.; Springer Berlin Heidelberg: Berlin, Heidelberg, 1983; pp. 25–37.
136. Duda, R.; Hart, P. E.; Stork, D. G. *Pattern Classification*; 2nd ed.; Wiley: New York, New York, USA, 2001; pp. 1–10.
137. Johnson, K. J.; Synovec, R. E. Pattern recognition of jet fuels : comprehensive GC x GC with ANOVA-based feature selection and principal component analysis. *Chemometrics and Intelligent Laboratory Systems* **2002**, *60*, 225–237.

138. Robnik-Sikonja, M.; Kononenko, I. Theoretical and Empirical Analysis of ReliefF and RReliefF. *Machine* **2003**, *53*, 23–69.
139. Bishop, C. *Pattern Recognition and Machine Learning*; Jordan, M.; Kleinberg, J.; B. Schölkopf, Eds.; Springer: New York, 2006; p. 738.
140. Schölkopf, B.; Smola, A. J. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*; MIT Press, 2002.
141. Begg, R.; Kamruzzaman, J. A machine learning approach for automated recognition of movement patterns using basic, kinetic and kinematic gait data. *Journal of biomechanics* **2005**, *38*, 401–8.
142. Lau, H.-Y.; Tong, K.-Y.; Zhu, H. Support vector machine for classification of walking conditions using miniature kinematic sensors. *Medical & biological engineering & computing* **2008**, *46*, 563–73.
143. Anexo 3 - Sensibilidad y especificidad. In *Métodos de investigación clínica y epidemiológica (Tercera edición)*; Elsevier España: Madrid, 2004; pp. 335–340.
144. Powers, D. M. . EVALUATION : FROM PRECISION , RECALL AND F-MEASURE TO ROC , INFORMEDNESS , MARKEDNESS & CORRELATION. *Journal of Machine Learning Technologies* **2011**, *2*, 37–63.
145. Barralon, P.; Vuillerme, N.; Noury, N. Walk detection with a kinematic sensor: frequency and wavelet comparison. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference* **2006**, *1*, 1711–4.
146. Salarian, A.; Russmann, H.; Vingerhoets, F. J. G.; Burkhard, P. R.; Aminian, K. Ambulatory Monitoring of Physical Activities in Patients With Parkinson's Disease. *IEEE Transactions on Biomedical Engineering* **2007**, *54*, 2296–2299.
147. Nyberg, L.; Gustafson, Y. Patient Falls in Stroke Rehabilitation : A Challenge to Rehabilitation Strategies. *Stroke* **1995**, *26*, 838–842.
148. Cheng, P.-T.; Liaw, M.-Y.; Wong, M.-K.; Tang, F.-T.; Lee, M.-Y.; Lin, P.-S. The sit-to-stand movement in stroke patients and its correlation with falling. *Archives of Physical Medicine and Rehabilitation* **1998**, *79*, 1043–1046.
149. Kralj, A.; Jaeger, R. J.; Munih, M. Analysis of standing up and sitting down in humans: Definitions and normative data presentation. *Journal of Biomechanics* **1990**, *23*, 1123–1138.
150. Guzmán, R. A.; Prado, H. E.; Porcel Melián, H.; Cordier, B. Differences in momentum development when standing up from a chair between elderly with and without frequent falls history. *Revista española de geriatría y gerontología* **2009**, *44*, 200–4.

151. Nuzik, S.; Lamb, R.; VanSant, a; Hirt, S. Sit-to-stand movement pattern. A kinematic study. *Physical therapy* **1986**, *66*, 1708–13.
152. Piriyaaprasarth, P.; Morris, M. E.; Winter, A.; Bialocerkowski, A. E. The reliability of knee joint position testing using electrogoniometry. *BMC musculoskeletal disorders* **2008**, *9*, 10.
153. Kerr, K. M.; White, J. A.; Barr, D. A.; Mollan, R. A. B. Analysis of the sit-stand-sit cycle in normal subjects movement. *Clinical Biomechanics* **1997**, *12*, 236–245.
154. Robertson, G. E.; Caldwell, G. E.; Hamill, J.; Kamen, G.; Whittlesey, S. N. *Research Methods in Biomechanics*; 2004.
155. Doorenbosch, C. A. M.; Harlaar, J.; Roebroek, M. E.; Lankhorst, G. J. Two strategies of transferring from sit-to-stand; The activation of monoarticular and biarticular muscles. *Journal of Biomechanics* **1994**, *27*, 1299–1307.
156. Schenkman, M.; Berger, R. a; Riley, P. O.; Mann, R. W.; Hodge, W. a Whole-body movements during rising to standing from sitting. *Physical therapy* **1990**, *70*, 638–48; discussion 648–51.
157. Wheeler, J.; Woodward, C.; Ucovich, R. L.; Perry, J.; Walker, J. M. Rising from a chair. Influence of age and chair design. *Physical therapy* **1985**, *65*, 22–6.
158. Veltink, P. H.; Bussmann, H. B.; de Vries, W.; Martens, W. L.; Van Lummel, R. C. Detection of static and dynamic activities using uniaxial accelerometers. *IEEE transactions on rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society* **1996**, *4*, 375–85.
159. Baek, J.; Lee, G.; Park, W.; Yun, B. Accelerometer Signal Processing for User Activity Detection. *Knowledge-Based Intelligent Information and Engineering Systems Lecture Notes in Computer Science* **2004**, *3215*, 610–617.
160. Karantonis, D. M.; Narayanan, M. R.; Mathie, M.; Lovell, N. H.; Celler, B. G. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring. *IEEE transactions on information technology in biomedicine : a publication of the IEEE Engineering in Medicine and Biology Society* **2006**, *10*, 156–67.
161. Bidargaddi, N.; Klingbeil, L.; Sarela, A.; Boyle, J.; Cheung, V.; Yelland, C.; Karunanithi, M.; Gray, L. Wavelet based approach for posture transition estimation using a waist worn accelerometer. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference* **2007**, *2007*, 1884–7.
162. Bao, L.; Intille, S. S. Activity Recognition from User-Annotated Acceleration Data. *Computing (Lecture Notes in Computer Science)* **2004**, *3001*, 1–17.

163. Ganea, R.; Paraschiv-Ionescu, A.; Aminian, K. Detection and Classification of Postural Transitions in Real-World Conditions. *2012*, *20*, 688–696.
164. Fleury, A.; Vacher, M.; Noury, N. SVM-based multimodal classification of activities of daily living in Health Smart Homes: sensors, algorithms, and first experimental results. *IEEE transactions on information technology in biomedicine : a publication of the IEEE Engineering in Medicine and Biology Society* **2010**, *14*, 274–83.
165. Ataya, A.; Jallon, P. Amelioration of Physical Activity Estimation From Accelerometer Sensors Using Prior Knowledge. In *20th European Signal Processing Conference*; 2012; pp. 954–958.
166. Rodríguez-Martín, D.; Samà, A.; Pérez-López, C.; Català, A. Identification of sit-to-stand and stand-to-sit transitions using a single inertial sensor. *Studies in health technology and informatics* **2012**, *177*, 113–7.
167. Morris, T. R.; Cho, C.; Dilda, V.; Shine, J. M.; Naismith, S. L.; Lewis, S. J. G.; Moore, S. T. A comparison of clinical and objective measures of freezing of gait in Parkinson's disease. *Parkinsonism & related disorders* **2012**, *18*, 572–7.
168. Bouten, C. V.; Westerterp, K. R.; Verduin, M.; Janssen, J. D. Assessment of energy expenditure for physical activity using a triaxial accelerometer. *Medicine and science in sports and exercise* **1994**, *26*, 1516–23.
169. Samà, A.; Perez-Lopez, C.; Rodriguez-Martin, D.; Cabestany, J.; Moreno, J. M.; Rodriguez-Molinero, A. A Heterogeneous Database for Movement Knowledge Extraction in Parkinson's Disease. In *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*; 2013.
170. Parkinson, J. An Essay on the Shaking Palsy. *Journal of Neuropsychiatry* **14**, 223–236.
171. Giladi, N.; McMahon, D.; Przedborski, S.; Flaster, E.; Guillory, S.; Kostic, V.; Fahn, S. Motor blocks in Parkinson's disease. *Neurology* **1992**, *42*, 333–9.
172. Bachlin, M.; Plotnik, M.; Roggen, D.; Maidan, I.; Hausdorff, J. M.; Giladi, N.; Troster, G. Wearable Assistant for Parkinson's Disease Patients With the Freezing of Gait Symptom. *Ieee Transactions On Information Technology In Biomedicine* **2010**, *14*, 436–446.
173. Han, J. .; Lee, W. J.; Ahn, T. B.; Jeon, B. S.; Park, K. S. Gait analysis for freezing detection in patients with movement disorder using three dimensional acceleration system. In *25th Annual International Conference of the IEEE EMBS*; 2003; pp. 1863–1865.
174. Bachlin, M. DAPHNET Project-Dynamic Analysis of Physiological Networks. Sixth Framework Programme, FP6  
<http://www.wearable.ethz.ch/research/groups/health/daphnet/index> (accessed Oct 28, 2013).

175. Jovanov, E.; Wang, E.; Verhagen, L.; Fredrickson, M.; Fratangelo, R. deFOG--A real time system for detection and unfreezing of gait of Parkinson's patients. In *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*; 2009; Vol. 2009, pp. 5151–4.
176. Zabaleta, H.; Keller, T.; Fimbel, E. J. Gait analysis in frequency domain for freezing detection in patients with Parkinson's disease. *Gerontechnology* **2008**, *7*, 4.
177. Cole, B. T.; Member, S.; Roy, S. H.; Nawab, S. H.; Member, S. Detecting Freezing-of-Gait During Unscripted and Unconstrained Activity. **2011**, 5649–5652.
178. Niazmand, K.; Tonn, K.; Zhao, Y.; Fietzek, U. M.; Schroeteler, F.; Ziegler, K.; Ceballos-Baumann, a. O.; Lueth, T. C. Freezing of Gait detection in Parkinson's disease using accelerometer based smart clothes. In *IEEE Biomedical Circuits and Systems Conference (BioCAS)*; IEEE, 2011; pp. 201–204.
179. Almeida, Q. J.; Lebold, C. a Freezing of gait in Parkinson's disease: a perceptual cause for a motor impairment? *Journal of neurology, neurosurgery, and psychiatry* **2010**, *81*, 513–8.
180. Plotnik, M.; Giladi, N.; Hausdorff, J. M. Is freezing of gait in Parkinson's disease a result of multiple gait impairments? Implications for treatment. *Parkinson's disease* **2012**, *8*.
181. Takač, B.; Català, A.; Rodríguez Martín, D.; van der Aa, N.; Chen, W.; Rauterberg, M. Position and Orientation Tracking in a Ubiquitous Monitoring System for Parkinson Disease Patients With Freezing of Gait Symptom. *JMIR mhealth and uhealth* **2013**, *1*, e14.
182. Takač, B.; Català, A.; Rodriguez-Martin, D.; Chen, W.; Rauterberg, M. Ambient sensor system for freezing of gait detection by spatial context analysis. In *Proceedings of the 4th international conference on Ambient Assisted Living and Home Care*; 2012; pp. 232–239.
183. Rodríguez-Martín, D.; Pérez-López, C.; Samà, A.; Cabestany, J.; Català, A. A Wearable Inertial Measurement Unit for Long-Term Monitoring in the Dependency Care Area. *Sensors* **2013**, *13*, 14079–14104.
184. ST Microelectronics, Inc ©. STM32F415xx,STM32417xx Data Sheet 2013.
185. ST Microelectronics, Inc ©. I-Nemo-M1. System-on-Board. Data Sheet 2013.
186. Bluegiga Technologies. BLE113 Datasheet. Version 1.2. 2013.
187. Moore, S. T.; Yungheer, D. a; Morris, T. R.; Dilda, V.; MacDougall, H. G.; Shine, J. M.; Naismith, S. L.; Lewis, S. J. G. Autonomous identification of freezing of gait in Parkinson's disease from lower-body segmental accelerometry. *Journal of neuroengineering and rehabilitation* **2013**, *10*, 19.

188. Mazilu, S.; Blanke, U.; Roggen, D.; Tr, G.; Gazit, E.; Hausdorff, J. H. Engineers Meet Clinicians : Augmented Parkinson ' s Disease Patients to Gather Information for Gait Rehabilitation. In *4th Augmented Human International Conference*; 2013; p. 4.

