

UNIVERSIDAD DE JAÉN



ESCUELA DE DOCTORADO

DEPARTAMENTO DE INFORMÁTICA

Nuevas metodologías para el reconocimiento de cambios posturales a través de sensores

MEMORIA DE TESIS PRESENTADA POR:

Edna Rocio Bernal Monroy

PARA OPTAR AL GRADO DE DOCTOR EN

Tecnologías de la Información y la Comunicación

Directores:

Dra. Macarena Espinilla Estévez

Dr. Javier Medina Quero

Jaén, 9 de septiembre de 2021

La memoria titulada **Nuevas metodología para el reconocimiento de cambios posturales a través de sensores**, que presenta D^a. Edna Rocio Bernal Monroy para optar al grado de doctor, ha sido realizada dentro del Programa de Doctorado en Tecnologías de la Información y la Comunicación de la Universidad de Jaén bajo la dirección de la Dra. D^a. Macarena Espinilla Estévez y el Dr. D. Javier Medina Quero.



D. Edna Rocio Bernal
Monroy
Doctorando

Dra. Macarena Espinilla
Estévez
Directora

Dr. Javier Medina Quero
Director

Agradecimientos

Durante estos cuatro años de desarrollo de esta tesis doctoral, no hubiera sido posible su finalización sin el apoyo, en cada uno de los momentos de angustia y desesperación, de cada una de las personas que citaré a continuación.

Primero y, dar gracias a Dios, por haberme permitido llegar al final de esta meta, y no permitirme desfallecer antes los momentos de angustia.

Agradecer siempre a mi familia, porque siempre me motivaron a seguir adelante. A mis padres, Orlando Bernal y Hilda Monroy, mi hermana Diana Bernal y mi sobrina Sara Sofía Bernal, por el apoyo; y ánimo que me brindan, me dan la fortaleza necesaria para cumplir con mis metas. A mis amigos, quienes siempre han estado en los buenos y malos momentos y quienes siempre me han dado ánimo para seguir adelante. De igual forma a mi angelito Leonardo Ramírez, que desde el cielo siempre me acompaña y sé que se sentirá muy orgulloso de cumplir nuestro sueño.

De igual manera mi más sincero agradecimiento a mis directores de tesis, la Dra. Macarena Espinilla Estévez y el Dr. Javier Medina Quero por su enorme paciencia, dedicación y de quienes he aprendido mucho, a quienes admiro y quienes son unos grandes seres humanos, gracias por la colaboración y apoyo ofrecidos desde siempre y sobre todo por esa gran amistad que me han brindado, a quienes debo el realizar el doctorado en la Universidad de Jaén.

A los miembros del grupo de investigación Davinci de la Universidad Nacional Abierta y a Distancia y el grupo ASIA, quienes me han acompañado en todo este proceso y de quienes me han aportado con sus conocimientos.

Al Servicio Andaluz de Salud, el centro de Neuro Rehabilitación Neurobase (Jaén, España) por la colaboración recibida. Gracias a los compañeros de las universidades de Florencia (Italia) y Halmstad (Suecia) por el gran recibimiento durante mis estancias internacionales.

Finalmente, agradecer que esta tesis doctoral haya sido apoyada financieramente en el marco de la Unión Europea en las acciones Marie Skłodowska Curie para la investigación e innovación, en el programa Horizonte 2020, el acuerdo número 734355, REMIND: "The use of computational techniques to improve compliance to reminders within smart environments", de igual forma al proyecto de investigación financiado por la Fundación Pública Andaluza para la Investigación Biosanitaria de Andalucía Oriental (FIBAO), con código PI 0387 2018.

UNIVERSIDAD DE JAÉN

Resumen

Escuela de Doctorado

Departamento de Informática

Programa de Doctorado en Tecnologías de la Información y la
Comunicación

**Nuevas metodologías para el reconocimiento de cambios
posturales a través de sensores**

Edna Rocio Bernal Monroy

Esta memoria de tesis doctoral titulada «Nuevas metodologías para el reconocimiento de cambios posturales a través de sensores», se enfoca en las úlceras por presión (UPP) definidas como lesiones que se presentan en personas con movilidad reducida, y que requieren de atención constante por parte de los cuidadores que las atienden, pues son una patología frecuente en personas mayores. Una estadística concluyente que revalida esta situación es la que reporta el Grupo Nacional para el Estudio y el Asesoramiento en Úlceras por Presión y Heridas Crónicas de España (GNEAUPP), que en 2017 reportó el aumento en el número de personas con este padecimiento, pasando del 7.9 % al 9.1 %, en los programas de atención domiciliaria, y del 12.6 % al 14.2 % en los centros sociosanitarios.

Con el fin de posibilitar nuevas alternativas que permitan mitigar la complicación de las úlceras por presión, en este trabajo se presentan los resultados de investigación de la tesis doctoral, planificados y desarrollados, que han permitido implementar dos metodologías de reconocimiento de cambios posturales de monitoreo en tiempo real, con dispositivos vestibles inerciales no invasivos para la detección y cálculo de postura, basándose en las recomendaciones de los programas de rehabilitación, y usando técnicas de inteligencia artificial. Estas metodologías permiten monitorear las posturas y los tiempos de cada paciente, los cuales pueden configurarse siguiendo un protocolo de atención con el cual se puede alertar al personal médico o cuidador ante cualquier situación.

La primera metodología está basada en un registro histórico de la actividad corporal, dataset, y por el reconocimiento de posturas en

tiempo real con técnicas de Inteligencia Artificial. Por su parte, la segunda metodología comprende el uso de dispositivos vestibles inerciales adheridos a la ropa en zonas no invasivas, encargados de registrar el tiempo en que la persona ha permanecido en la misma posición, la recolección de datos de personas reales en diferentes posturas es clave en la prevención de úlceras, y la estimación de las posturas en tiempo real se realiza mediante técnicas de inteligencia artificial.

Ambas metodologías ofrecen el cálculo de las posturas, permitiendo a los cuidadores reducir el estrés, ya que se ofrece conocimiento de forma objetiva de los tiempos y las posturas del paciente. Además, la segunda metodología permite personalizar el tratamiento según las necesidades particulares del mismo.

Por tanto, el cuidado de la salud apoyado en la tecnología posibilita nuevas alternativas para disminuir riesgos asociados a complicaciones médicas, como es el caso de las UPP que, en algunos casos, parecen difícilmente monitorizables. Gracias a las metodologías propuestas de monitoreo con dispositivos vestibles se puede controlar completamente los tiempos y posturas del paciente.

Summary

This doctoral thesis report titled "New methodologies for the recognition of postural changes through sensors", focuses on pressure ulcers (PU) defined as lesions that occur in people with reduced mobility, and that require constant attention from the caregivers, as they are a frequent pathology in older people. A conclusive statistic that revalidates this situation is that reported by the National Group for the Study and Counseling of Pressure Ulcers and Chronic Wounds of Spain (GNEAUPP, in its acronym for Spanish), which in 2017 reported an increase in the number of people with this condition, going from 7.9 % to 9.1 % home care programs, and from 12.6 % to 14.2 % in social and health centers.

To enable new alternatives to mitigate the complication of pressure ulcers, this work presents the research results of the doctoral thesis, planned and developed, which have allowed the implementation of two real-time monitoring methodologies, with wearable non-invasive inertial devices for posture detection and calculation, based on the recommendations of rehabilitation programs, and using artificial intelligence techniques. These methodologies allow monitoring of the postures and times of each patient, which can be set up following a care protocol with which the medical staff or caregiver can be alerted to any situation.

The first methodology is based on a historical record of body activity, a dataset, and the recognition of postures in real-time with Artificial Intelligence techniques. On other hand, the second methodology includes the use of inertial wearable devices in non-invasive areas, recording the time the person has remained in the same position, the

collection of data from real people is key in ulcer prevention positions, the estimation of postures in real-time using artificial intelligence techniques.

Both methodologies offer the calculation of postures, allowing caregivers to reduce stress since an objective knowledge of the times and postures of the patient is offered. In addition, the second methodology allows personalizing the treatment according to the particular needs.

Therefore, health care supported by technology enables new alternatives to reduce risks associated with medical complications, as is the case with PUs, which, in some cases, seem difficult to monitor. Thanks to the proposed monitoring methodologies with wearable devices, the times and postures of the patient can be fully controlled.

Índice general

1. Introducción	1
1.1. Motivación	2
1.2. Propuesta tesis doctoral	9
1.3. Objetivos específicos	9
 2. Estado del arte úlceras por presión	 13
2.1. El gran desafío de la prevención de úlceras por presión	14
2.2. Proyectos centrados en las UPP	20
2.2.1. Aplicaciones Móviles	27
2.3. Herramientas tradicionales de apoyo para el tratamiento de UPP	29
2.4. Metodologías de reconocimiento de posturas	33
 3. Dispositivos inteligentes para el reconocimiento de actividades	 44
3.1. Dispositivos con sensores inerciales	44
3.1.1. Acelerómetro	45
3.1.2. Giroscopio	46
3.1.3. Magnetómetro	47
3.2. Dispositivos vestibles	48

3.3. Reconocimiento de actividades	53
3.3.1. Señal de actividad	55
3.3.2. Extracción de características	57
3.3.3. Modelo de actividad	58
3.3.4. Inferencia de la actividad	60
 4. Nueva metodología para la clasificación de cambios posturales con sensores inerciales	 62
4.1. Arquitectura	63
4.2. Modelo de procesamiento	65
4.3. Evaluación	67
4.3.1. Entrenamiento usando Leave-One-Out	67
4.3.2. Modelo adaptativo entrenado	68
Prueba A: Sin personalización	68
Prueba B: Con personalización suave	69
Prueba B: Con personalización media	70
Prueba B: Con personalización fuerte	70
4.4. Fortalezas y limitaciones	73
 5. Nueva metodología para la clasificación de cambios posturales en textiles sensorizados	 76
5.1. Arquitectura	77
5.1.1. Sensores inerciales adheridos a la ropa:	77
5.1.2. Modelo basado en datos para el reconocimiento de posturas en cama	78
5.1.3. Método difuso basado en el conocimiento para calcular la prioridad de los cambios posturales .	81

- 5.1.4. Umbral configurable de cambios posturales,
según las necesidades de los cuidadores 88
- 5.2. Evaluación 89
 - 5.2.1. Evaluación del reconocimiento de la postura en
la cama mediante sensores inerciales conectados
a la ropa 89
 - 5.2.2. Prueba A – Aprendizaje Personalizado 91
 - 5.2.3. Prueba B – Evaluación basada en participante
invisible 91
 - 5.2.4. Modelo basado en conocimiento - Protocolos . . 97
 - Modelo A: protocolo postural básico con
intervalos de tiempo de cambio de dos
horas 98
 - Modelo B: protocolo postural dinámico con
intervalo de tiempo de cambio
adaptativo 99
 - Modelo C: protocolo postural para prevenir la
presión sobre las zonas lesionadas del
cuerpo 102
- 5.3. Fortalezas y limitaciones de la implementación en un
entorno del mundo real 104
- 6. Conclusiones y Trabajos Futuros 109
 - 6.1. Conclusiones y trabajos futuros 109
 - 6.1.1. Conclusiones 109
 - 6.1.2. Trabajos futuros 113
 - 6.2. Publicaciones relacionadas con la tesis doctoral 115

6.2.1. En revistas internacionales	115
6.2.2. En congresos internacionales de alta relevancia.	115
6.2.3. Seminarios y conferencias impartidos	120
6.2.4. Estancias de investigación	121
A. English Summary	124
A.1. Introduction	124
A.1.1. Motivation	125
A.2. Ph.D. thesis proposal	131
A.3. Specific objectives	132
A.4. Structure	132
A.5. Research proposals	134
A.5.1. New methodology for postural change classification with inertial sensors	134
A.5.2. New methodology for the classification of postural postural changes in textiles sensorised textiles	148
A.5.3. UJA Human Activity Recognition multi-occupancy dataset	161
A.6. Conclusions and Future Works	172
A.6.1. Conclusions	172
A.6.2. Future work	175

Índice de figuras

2.1. Cambios Posturales (https://www.ozoaqua.es/dia-mundial/)	
.....	15
2.2. Sistema SEAPULP [4]	21
2.3. Diagrama de selección de los participantes del estudio y procedimiento de recolección de datos, Santa María, RS, Brasi	22
2.4. Escenario del Sistema CardioSmart.	23
2.5. Ángulo dado por el dispositivo en el eje X al sentarse.	24
2.6. Configuración del sistema y el sistema de coordenadas de la etiqueta	26
2.7. Ejemplo de 8 posturas	26
2.8. Marco de fusión de sensores.	27
2.9. Aplicativo WOUND ANALYSIS	28
2.10. Smart UPP https://www.smartupp.es/	29
2.11. https://helcos.net/users/login	29
2.12. APP Pressure Ulcer Guide)	30
2.13. Reloj de pared giratorio para ayuda en la prevención de úlceras	31
2.14. A) Cojín Antiescaras; B) Colchón de Espuma	32
2.15. A) Espuma de alta especificación; B)Colchón de espuma	32

2.16. Arquitectura de los componentes propuestos en la metodología: conjunto de datos limitado de sensores de tapete de presión, representación visual difusa, aumento de datos y aprendizaje de las CNN	39
2.17. Arquitectura general del sistema	42
3.1. Giroscopio, acelerómetro y magnetómetro [51]	45
3.2. Procedimiento general basado en sensores para reconocer actividades humanas [102]	55
3.3. Ejemplos de sensores: smart watch y RFID (lector y tarjeta) [95]	57
3.4. Esquema general para la inferencia de actividades . . .	61
4.1. Dispositivos Android, ubicados en el hombro y el tobillo	64
4.2. Arquitectura de componentes de la metodología para la prevención de úlceras por presión mediante monitorización de cambios posturales usando sensores inerciales	65
4.3. Reloj que indica tiempos de frecuencia sobre el cambio de postura [97]	71
4.4. Matriz de confusión para el clasificador SVM con personalización. Se definen siete posiciones: (a) inactivo, (b) en decúbito supino, (c) reclinado, (d) izquierda, (e) derecha, (f) sentado y (g) caminando . . .	71

4.5. Matriz de confusión para el clasificador SVM con personalización. Se definen siete posiciones: (a) inactivo, (b) en decúbito supino, (c) reclinado, (d) izquierda, (e) derecha, (f) sentado y (g) se incluyen caminando e inactivo 72

5.1. Arquitectura y componentes: i) sensores inerciales adheridos a la ropa, ii) modelo de datos para el reconocimiento de posturas, iii) aplicación del conocimiento difuso para calcular la prioridad de los cambios posturales para las zonas del cuerpo, y iv) configuración de un umbral de tiempo para las notificaciones a los cuidadores 77

5.2. Tactigon ONE: izquierda), sensor inercial integrado en la placa; centro y derecha), Tactigon adherido a los calcetines y la camiseta del paciente, respectivamente. . 78

5.3. Clasificación de posturas de pacientes en cama para la prevención de úlceras por presión (de izquierda a derecha): supino, izquierda, derecha, semi sentado, supino con la pierna derecha doblada y supino con la pierna izquierda doblada 80

5.4. Procesamiento difuso a partir de una secuencia básica de cambios posturales, para calcular el grado de presión de agregación de las zonas del cuerpo: hombro y cadera izquierda / derecha, durante dos intervalos de tiempo T de cambios posturales. 84

5.5. Cuantificación difusa definida por dos puntos de control: principio y final del cambio de postura, para calcular el grado de prioridad de los mismos para la zona del cuerpo. Además, se muestra el grado de prioridad de los cambios posturales durante un día, que evoluciona según los cambios realizados por los cuidadores.	87
5.6. Matriz de confusión: SVM-Support Vector Machine con aprendizaje personalizado	93
5.7. Matriz de confusión: KNN con aprendizaje personalizado	94
5.8. Matriz de confusión: C4.5 Decision Tree con aprendizaje personalizado	94
5.9. Matriz de confusión: SVM Support Vector Machine con aprendizaje del participante invisible en la evaluación de datos	95
5.10. Matriz de confusión: KNN K-vecinos más próximos con aprendizaje del participante invisible en la evaluación de datos	95
5.11. Matriz de confusión: C4.5 Árbol de decisión con aprendizaje del participante invisible en la evaluación de datos	96
5.12. Protocolo postural básico para cuatro posturas en la cama en intervalos de dos horas	99
5.13. Protocolo dinámico para extender el intervalo de tiempo de cambio de dos horas durante el día a cuatro horas por la noche	101

5.14. Protocolo adaptado para prevenir la presión sobre las
zonas lesionadas del cuerpo 104

Índice de tablas

2.1. Puntuación grupos de riesgo UPP	16
2.2. Prevalencia en Úlceras por Presión (UPP) en pacientes en el mundo	19
4.1. Resultados sin personalización para las siete posturas, incluyendo caminando e inactivo, agrupados según cuatro clasificadores: SVM, NB, C4.5, KNN	69
4.2. Resultados sin personalización, agregando movimiento (caminar)	69
4.3. Resultados con personalización para las siete posturas, incluidas caminando e inactivo	69
4.4. Resultados con personalización adicionando las clases inactiva y caminando	70
4.5. Resultados finales con personalización	70
5.1. Métricas de precisión (P), Recall (R) y F1-Score (F1) en evaluación de datos con aprendizaje personalizado	92
5.2. Métricas de precisión (P), Recall (R) y F1-Score (F1) con aprendizaje de participantes invisibles en la evaluación de datos.	92

5.3. Grado de presión promedio por unidad de tiempo para
los modelos A, B y C 103

Capítulo 1

Introducción

Esta memoria de tesis doctoral tiene como propósito generar una solución para mejorar las condiciones de vida de la población con movilidad reducida, que presenta patologías de úlceras por presión, a partir de los avances de la tecnología en campos como: dispositivos inteligentes vestibles con sensores inerciales y técnicas de inteligencia artificial. Para ello, se propone el desarrollo de metodologías para el reconocimiento de cambios posturales, usando sensores vestibles inerciales que apoyen el monitoreo y acompañamiento para estos pacientes, para que puedan convertirse en un recurso o herramienta de soporte y de seguimiento por parte del equipo médico, así como para los cuidadores y familiares.

El proyecto de investigación, en el cual se enmarca esta memoria, se titula "Sistema inteligente para prevención de úlceras por presión basado en dispositivos vestibles no invasivos", evaluado en la Convocatoria de Salud del Servicio Andaluz de Salud de la Junta de Andalucía, y financiado por la Fundación Pública Andaluza para la

Investigación Biosanitaria de Andalucía Oriental (FIBAO) en 2018, con código *PI* – 0387 – 2018.

1.1. Motivación

En un principio, la problemática de las úlceras por presión no atraía la atención de los sistemas médicos, pero debido al incremento en los costos que afecta directamente al sistema de salud, por los días de hospitalización de cada paciente, se ha considerado un campo de oportunidad para la investigación [70].

Es decir, el gasto público se ve afectado por los costos generados en el tratamiento de las UPP, este costo incluye el importe total de la atención al paciente. En efecto en este valor se tiene en cuenta los gastos directos, es decir, los recursos médicos como no médicos, y por otra parte, los gastos indirectos, relacionados al dolor generado por el hecho de padecer las UPP; y finalmente tenemos los intangibles, relacionado a la calidad de vida del paciente, que afectan a su familia y/o su cuidador. Hoy en día, no se han encontrado estudios profundos que dimensionen el impacto económico de las UPP; en su mayoría solo tienen en cuenta, el costo de la lesión por presión establecido al tratamiento dado según la gravedad de la lesión, o un cuidado preventivo [30].

Además, cabe decir que el valor de la atención se incrementa al tener que utilizar dispositivos tecnológicos para cuidado de las heridas, el costo también aumentara dependiendo el tratamiento y la severidad de la úlcera, para ello, se debe tener en cuenta el

tiempo de cicatrización y la incidencia de complicaciones, se debe tener en cuenta algunos costos adicionales en casos de intervenciones quirúrgicas, lo que significa el aumento de días hospitalizados e incremento en los tiempos de cuidado, entre otros aspectos [90]. Estos costos podrían disminuir, implementando medidas preventivas, como programas institucionales cuyo propósito sean evitar la aparición de UPP en pacientes con riesgos de padecerlas [88].

Por otra parte, es importante analizar la prevalencia en el mundo de patologías en pacientes con movilidad reducida, por lo cual se mencionan a continuación algunas estadísticas relevantes.

En España, la prevalencia de UPP se encuentra entre el 7 % y el 8 %, en hospitales; y ha venido en aumento pasando a del 7.9 % al 9.1 % entre personas vinculadas a programas de atención domiciliaria. En gran parte de las lesiones, un 65 %, son de origen nosocomial, es decir, se presentan internamente en el hospital durante la estancia en el paciente. En cuanto a las características de los pacientes en gran parte son personas adultas mayores por encima de 72 años [73].

En cuanto al contexto europeo, en Alemania la tasa general de prevalencia de enfermedades asociadas a úlceras por presión en los hospitales fue estimada en 10.2 % [49]. Otro estudio hecho en Bélgica, Portugal, Italia, Reino Unido y Suecia calculó la prevalencia de este tipo de enfermedades en 18.1 % [97]. En Holanda, la prevalencia media estimada fue del 23.1 % [16]. En Estados Unidos [28] se calculó esta situación en una unidad de cuidados intensivos quirúrgicos, donde el 10.6 % de los pacientes presentó enfermedades con presencia

de UPP por mantener la misma posición durante mucho tiempo. En Canadá, una revisión sistemática sobre esta afectación permitió establecer una prevalencia general de 26 % [104], mientras que en México [38] se estableció una prevalencia de 1.5 %, en una institución cardiológica, con respecto a enfermedades asociadas a la falta de movimiento; en Brasil, un estudio determinó la incidencia de este tipo de enfermedades en una institución hospitalaria en São Paulo con un resultado del 23.1 % de prevalencia [84].

Un estudio realizado por la Facultad de Medicina de la Universidad Nacional de Colombia, indica que las UPP se producen con frecuencia en el sitio de hospitalización, con un 54 %, mientras que el 33 % se presentan en la casa y el 13 % se originan en el lugar donde fue remitido el paciente. Los cambios de posición, como medida preventiva de las UPP, se efectúan en el 95 % de los casos: el 61 % se cumple cada 120 minutos y el 12 % cada 180 minutos [40].

Con respecto a la edad, existe una mayor prevalencia de estas alteraciones en personas mayores; el 51 % de estas personas tiene enfermedades asociadas al movimiento y presenta úlceras por presión; el rango de edad de las personas con este tipo de alteraciones está entre los 62 a 80 años de edad [42].

Como se observa en las estadísticas presentadas anteriormente, el riesgo de padecer UPP en paciente es frecuente en los países mencionados, a pesar de lo cual, los sistemas de salud no consideran una prioridad al abordaje de esta problemática.

No obstante, en España el problema de las úlceras por presión

ha aumentado con respecto a años anteriores, e incluso se ha duplicado; por esta razón, se ha calificado como “epidemia viva y alarmante que vive bajo las sábanas de los pacientes en los diferentes niveles asistenciales” y ha evidenciado falencias importantes en su prevención [74]. Por ello, muchas guías de cuidados sitúan de forma apropiada los cambios de posturas como principal mecanismo de prevención [82], y se ha demostrado que “un cuidado preventivo es necesario y suficiente para evitar la aparición de las úlceras por presión” [21]. Estos cuidados han sido descritos de forma protocolaria en el ámbito de la enfermería, para el diagnóstico, tratamiento y rehabilitación con el uso de taxonomías [39].

A pesar de la gravedad del problema, son escasos los trabajos basados en tecnología que permiten mejorar los cuidados y cambios posturales para prevenir las úlceras por presión. El trabajo más importante en este campo es español: en [109] se presenta una aplicación informática específica de gestión de UPP que permite la valoración sobre el riesgo de padecimiento de estas úlceras y un cribado del estado nutricional de los pacientes, para favorecer el intercambio de datos entre profesionales y niveles asistenciales. Un poco más prolíferas han sido las patentes presentadas al respecto. Se destaca como una propuesta innovadora la de [50] (1985), quien ideó una primera propuesta sobre bases de datos remotas. En [18] se presenta el diseño de un dispositivo sin especificar los sensores o el mecanismo de control y se hace la medición de la presión y no del tiempo u orientación. En [46] se presentó una patente reciente que evalúa si “el movimiento de un paciente es correcto”, pero no describe a sus

cuidadores ni al sistema de alertas basado en el tiempo y la duración de una postura.

En cuanto a la prevención de UPP, existen infinidad de oportunidades para implementar diferentes tecnologías de apoyo, monitoreo y seguimiento de los pacientes con movilidad reducida. Los cambios de posturas son un componente imprescindible en la prevención y el tratamiento de las UPP. Por lo anterior, las metodologías propuestas en esta investigación se enfocan en el reconocimiento de cambios posturales a través de sensores, los cuales se convierten en una herramienta de seguimiento en tiempo real, que permiten evitar la aparición y complicación de las UPP.

Como se indicó anteriormente, en esta propuesta de investigación se ha hecho uso de dispositivos con sensores inerciales; para el caso de este estudio, se han utilizado el acelerómetro y el giroscopio. Teniendo en cuenta que un factor importante es el reconocimiento de la actividad diaria de los pacientes, el acelerómetro se ha convertido en el sensor más utilizado, por los datos que proporciona al generar una señal cuando hay movimiento o ausencia del mismo, y por identificar la orientación respecto a la gravedad [19]. De igual forma, el giroscopio mide la velocidad angular de un objeto y permite realizar el análisis del movimiento humano, identificando las transiciones de posturas o caídas [23].

Teniendo en cuenta los anteriores indicadores de prevalencia y la importancia de los cambios posturales, esta tesis doctoral se considera una propuesta tecnológica innovadora y de gran utilidad que abarca

las siguientes temáticas:

- **Entornos inteligentes.** Definidos como espacios físicos en los cuales las tecnologías de la información y comunicación se combinan de forma ubicua, para conseguir objetivos específicos para el usuario, el entorno o ambos casos [63].

- **Identificación de tecnologías vestibles con sensores inerciales.** Estas soluciones se estudian dentro de los modernos paradigmas de la información como: la computación ubicua (Ubiquitous Computing) [103] y la inteligencia ambiental (Ambient Intelligence) [114], donde se desarrollan tecnologías cada vez más inteligentes, integradas en el entorno, que son sensibles y responden a las necesidades de las personas de forma interactiva y contextualizada. Estos paradigmas incluyen otras definiciones, de modo que los objetos inteligentes, compuestos por actuadores, sensores y visualizadores, se comunican entre sí mediante Internet of Things (IoT) [35], creando una red de cooperación que configura un entorno inteligente (Smart Environments)[17].

En concreto, se han señalado las tecnologías vestibles (wearables), con sensores inerciales, como una solución con múltiples ventajas: i) tamaño reducido, ya que este tipo de tecnología va con el propio usuario, unida a su cuerpo como si fuera una parte más de este, es decir, se puede llevar, literalmente, puesta; ii) permite agrupar en un mismo dispositivo diferentes sensores, como en nuestro caso de

estudio, donde usamos acelerómetro y giroscopio, que de forma automática y no invasiva detectan la postura y el tiempo de estancia del paciente; iii) se puede personalizar el tratamiento según las necesidades de cada paciente. Además, estas tecnologías son útiles para recoger nuevos datos y señales vitales durante la actividad física diaria [18], destacándose en el área de la salud, pues permiten monitorear o describir las necesidades de los pacientes de forma constante y poco invasiva [54].

- **Reconocimiento de actividades (AR).** Son soluciones que pueden detectar la actividad física que tienen las personas en diferentes entornos [107], basándose en el procesamiento de la información recibida de diferentes sensores, bien sea usando la tecnología vestible, sensores incluidos en objetos de uso común, o en el mismo entorno [13]. Los enfoques de reconocimiento de actividades se clasifican en entornos basados en datos, entornos basados en conocimiento y entornos híbridos. Para el objeto de esta memoria de tesis doctoral, utilizaremos enfoques basados en datos y enfoques basados en conocimiento para el reconocimiento de las posturas.
- **Reconocimiento de cambios posturales.** En esta memoria de tesis se proponen dos metodologías para el reconocimiento de cambios posturales: a partir de sensores que porta el paciente o mediante sensores adheridos a la ropa, los cuales permiten hacer monitoreo en tiempo real.

La propuesta de las metodologías presentadas tendrá un impacto importante en las siguientes dimensiones: en primer lugar, diseñar protocolos y enviar notificaciones adaptados a cada paciente permitiendo mayor flexibilidad; en segundo lugar, facilitar una herramienta de soporte que permita al personal de enfermería o a los familiares realizar un seguimiento de manera continua mediante el uso de sensores; finalmente, se reduce la carga de los cuidadores gracias al control automático basado en sensores.

1.2. Propuesta tesis doctoral

Basándose en la motivación y las consideraciones expuestas anteriormente, esta propuesta de tesis doctoral se fundamenta en el diseño y evaluación de metodologías para el reconocimiento de cambios posturales, a partir de los datos obtenidos por dispositivos vestibles con sensores, los cuales son procesados a través de técnicas de inteligencia artificial.

1.3. Objetivos específicos

Para llevar a cabo esta investigación se plantean los siguientes objetivos específicos:

- Identificar las necesidades de monitoreo y problemáticas de pacientes con úlceras por presión, mediante la revisión del estado del arte, teniendo en cuenta la implementación de dispositivos vestibles con sensores inerciales.

- Realizar un estado del arte sobre sensores, en el contexto de aplicación, como herramientas de apoyo en el monitoreo y cuidado de pacientes con riesgos de padecer UPP.
- Proponer y evaluar metodologías de reconocimiento de cambios posturales. La primera metodología con sensores adheridos al cuerpo humano, y la segunda de ellas con sensores adheridos a textiles del paciente.

Para alcanzar los objetivos que plantea esta memoria de tesis doctoral, el presente documento se estructura del siguiente modo:

- **Capítulo 1.** En este capítulo se presenta la introducción, la motivación y la propuesta, así como los objetivos específicos establecidos durante la investigación.
- **Capítulo 2.** En este capítulo se presenta el estado del arte en relación a la temática sobre úlceras por presión. En primer lugar, se hace referencia a los datos más relevantes que ponen en evidencia el gran desafío para la sociedad que ocupa las UPP. En segundo lugar, se presentan relevantes proyectos en el contexto de UPP, las aplicaciones móviles para el seguimiento, prevención y entrenamiento del personal médico en protocolos y cambios posturales, las principales herramientas de apoyo para el tratamiento y, finalmente, las metodologías con respecto a enfoques de inteligencia artificial en relación a las UPP.
- **Capítulo 3.** En este capítulo se presentan los dispositivos inerciales y dispositivos vestibulares, los cuales serán utilizados para la propuesta de metodologías para el reconocimiento de

posturas. Además, se describe la metodología clásica para el reconocimiento de actividad, la cual es la base de las propuestas presentadas en esta tesis doctoral.

- **Capítulo 4.** En este capítulo se propone una metodología para el reconocimiento de los cambios posturales con sensores inerciales; se presentan la metodología, la arquitectura, el modelo de procesamiento (basado en datos - posturas) y la evaluación. El capítulo concluye con el análisis de las limitaciones y fortalezas sobre las pruebas realizadas.
- **Capítulo 5.** Continuando con lo planteado en el capítulo anterior, se presenta la metodología para el reconocimiento de cambios posturales en textiles sensorizados. En primer lugar, se discute la metodología con sensores inerciales adheridos a la ropa; en segundo lugar, la arquitectura; en un tercer momento, se presenta el modelo de procesamiento, que se divide en dos subtemas: i) modelo basado en datos para el reconocimiento de posturas en cama, y ii) modelo basado en conocimiento (protocolos) de acuerdo a las particularidades del paciente. Por último se presenta la evaluación, que se divide en dos clases: i) prueba A (con personalización); ii) prueba B (evaluación basada en participante invisible). El capítulo concluye con las limitaciones y fortalezas de la metodología en un entorno real.
- **Capítulo 6.** En este capítulo se exponen las conclusiones obtenidas en esta investigación de tesis doctoral, junto con la delimitación de los trabajos de investigación proyectados a

futuro.

- **Anexo A.** En este anexo se presenta el resumen de la memoria de tesis en inglés para dar cumplimiento a la mención internacional de la tesis. Asimismo, se exponen la motivación, los objetivos propuestos y la estructura. También, se describe la propuesta de investigación. Finalmente, se exponen las conclusiones de la investigación y se hace referencia a trabajos futuros que podrían ser el punto de partida de próximas investigaciones.

Capítulo 2

Estado del arte úlceras por presión

En este capítulo se presenta el estado del arte en relación a la temática sobre úlceras por presión. En primer lugar, se hace referencia a los datos más relevantes que ponen en evidencia el gran desafío para la sociedad que ocupa las UPP. En segundo lugar, se presenta la aplicación de proyectos en el contexto de UPP, las aplicaciones móviles para el seguimiento, prevención y entrenamiento del personal médico en protocolos y cambios posturales. Seguidamente, se describen las principales herramientas de apoyo para el tratamiento. Finalmente, se señalan las metodologías con respecto a enfoques de inteligencia artificial para la prevención de úlceras por presión.

2.1. El gran desafío de la prevención de úlceras por presión

La propuesta doctoral se enfoca en la patología de úlceras por presión (UPP), asociada principalmente a pacientes con movilidad reducida hospitalizados o en sus hogares, quienes pasan tiempos prolongados tiempos en cama o en la misma posición. Según la Guía de prácticas clínica para el cuidado de personas con UPP, estas se definen como una lesión localizada en la piel o el tejido subyacente, por lo general sobre una prominencia ósea, como resultado de la presión (incluyendo presión en combinación con cizalla) [23].

De igual forma, la causalidad de las UPP se deben a cuatro mecanismos por los cuales se altera la integridad de la piel, promoviendo su aparición. En el Manual de prevención y tratamiento de las UPP [2], se destacan los siguientes factores: la presión, la fricción, la fuerza externa de pinzamiento vascular y finalmente la maceración. Asimismo, se indica [59] como principal etiología de las UPP la fricción, la presión, el cizallamiento y la humedad.

Existen diferentes factores de riesgo que influyen en las UPP, los cuales han sido descritos por los siguientes indicadores: grado de inmovilidad, como factor evidente y clave [68], enfermedades vasculares, problemas circulatorios o presión sanguínea [27], y aspectos nutricionales y de dieta, descritos como un factor potencial de riesgo [89].

Estas UPP, como se ha dicho anteriormente, generan dolor, que

muchas veces no puede ser manifestado por los pacientes debido a su condición de salud; el problema además se puede acrecentar por otras complicaciones derivadas de esta problemática, sobre todo las relacionadas con la infección y sobreinfección a nivel sistémico, que aumentan las probabilidades de que el paciente pueda morir [3].

Las UPP pueden aparecer en cualquier parte del cuerpo, dependiendo de la zona de piel que esté sometida a mayor presión y a largos periodos de tiempos en la misma postura. Para evitar su aparición, según López [55], recomienda realizar cambios de posturas con una frecuencia determinada según el riesgo y tipo de UPP que presente el paciente; por ejemplo, en el caso de un paciente de riesgo alto debería realizarse un cambio cada cuatro horas, pero en un paciente leve con movilidad se podría extender este periodo a cada seis horas. Es importante tener en cuenta que estos cambios deben ser personalizados, de acuerdo con el estado de salud de cada paciente. En la figura 2.1 se pueden observar los cambios posturales comúnmente utilizados.




FIGURA 2.1: Cambios Posturales
(<https://www.ozoaqua.es/dia-mundial/>)

Concepto	Puntaje	Frecuencia
Riesgo Alto	<12	Valoración diaria
Riesgo Moderado	13-14	Valoración cada 3 días
Riesgo Bajo	>15	Valoración cada 5 días

TABLA 2.1: Puntuación grupos de riesgo UPP

Además, es importante tener en cuenta la escala de Braden, la cual se define como una “herramienta utilizada para la valoración del riesgo de UPP diseñada para identificar a los pacientes con riesgo de desarrollar una UPP” [41]. A través de esta herramienta se realiza una valoración del riesgo de deterioro cutáneo, mediante seis categorías: percepción sensorial, exposición a la humedad, actividad, movilidad, nutrición y roce/peligro de lesiones cutáneas. El resultado de la sumatoria de las categorías determina el riesgo de padecer las UPP, como se muestra [2.1](#).

Con respecto a las situaciones y problemas que pueden generar las UPP, en varios estudios se demuestran el impacto que las UPP producen, y que hace que sean consideradas como un problema complejo que, según [109], atañe a diferentes aspectos:

- Sociales por su sobrecarga del entorno familiar.
- Sanitarios por su alta incidencia y prevalencia generan deterioro de la calidad de vida del paciente, como consecuencia del sufrimiento, ingresos hospitalarios, discapacidad, e incluso muerte.
- Económicos en consumo de recursos materiales y profesionales, necesidad de consultas y hospitalizaciones e incremento del

coste de los procesos.

El cuidado de los pacientes que padecen o pueden padecer UPP han sido el foco de varios estudios, como resultado se tiene la creación de nuevos medicamentos y tratamientos costosos, así como el diseño de un sin número de guías prácticas clínica. Es importante resaltar la formación de los profesionales en temas de prevención, diagnóstico y tratamiento, también, existe un avance en el diseño de herramientas tecnológicas como aplicaciones informáticas, tratamiento de fotografía, entre otros. Todo ellos hacen un conjunto de herramienta de soporte importante en el abordaje integral de las UPP [45]. En este aspecto es donde la solución del proyecto desarrollado innova y busca ayudar a mitigar las complicaciones antes mencionadas causadas por una patología compleja como las UPP.

Es importante mencionar, en lo que respecta a la prevención de la aparición de las UPP, el proceso que se lleva a cabo en el interior de los centros médicos, el primer paso es la detección y registro temprano de la presencia o riesgo de aparición de la lesiones, puesto que, al identificar y valorar una herida a tiempo, es más fácil determinar el abordaje de la herida evitando complicaciones graves de la misma, que generan costos adicionales, es por ello la importancia de la prevención y tratamiento pertinentes a cada paciente [45]. Acorde a lo anterior, la solución presentada, con respecto al cuidado necesario que exige esta patología, busca prevenir y alertar ante situaciones que puedan generar la aparición de UPP.

Como complemento a lo anterior, contar con una herramienta

automatizada que permita la recolección de datos en tiempo real, adicionalmente con un registro sistemático y frecuente, con capacidad de predicción, interpretación y acceso a la información, sería un instrumento de apoyo de gran utilidad para el personal médico en su día a día, así como para el proceso de toma de decisiones citecapillas2004maneig, que es precisamente lo que la solución de esta tesis aporta.

Las tecnologías de la información y comunicación (TIC), de forma general favorecen [9]:

- La automatización de estos nuevos métodos, tratamientos y buenas prácticas.
- El proceso de compartir información entre grupos multidisciplinares.
- El establecimiento de un lenguaje común y consensuado.
- El análisis y la consulta ubicua de la información de forma rápida y efectiva, evitando duplicidades y errores.
- El acceso a la información en condiciones de seguridad y confidencialidad.

La tabla 2.2 muestra la prevalencia de UPP en pacientes de todo el mundo, de lo cual se concluye que para los adultos mayores de 60 años existe una mayor prevalencia de UPP (51 %) [14]. Las UPP también pueden aparecer en pacientes con movimiento limitado, es decir, pacientes con esclerosis lateral amiotrófica y casos de paraplejias. Para este tipo de úlceras, los tratamientos de

País	Prevalencia
Estados Unidos	10.6 % [47]
México	1.5 % [67]
Brasil	23.1 % [84]
Alemania	10.2 % [15]
Bélgica, Portugal, Italia, y Suiza	18.1 % [15]
Holanda	23.1 % [92]
España	7.2 % [92]
Colombia	18.2 % [40]

TABLA 2.2: Prevalencia en Úlceras por Presión (UPP)
en pacientes en el mundo

cuidado deben personalizarse y planificarse individualmente para cada paciente [117]. Para el tratamiento de estas lesiones, los métodos de intervención son eléctricos o ecográficos, y se aplican directamente sobre las heridas, lo cual hace que el proceso sea doloroso para los pacientes y costoso para el sistema de salud.

En relación a ello, Palfreyman y Stone [117] realizaron estudios sobre el análisis de costes de las UPP, mediante una revisión sistemática de este tipo intervención, concluyendo que: (i) el costo del tratamiento aumenta con la gravedad de la úlcera, debido al mayor tiempo de curación / recuperación; y (ii) este costo está compuesto por gastos en insumos de materiales, tiempo de enfermería y gastos de hospitalización para el sistema de salud, lo que genera un impacto económico significativo de esta enfermedad en el sistema nacional de atención y, por ende, en el presupuesto gubernamental.

2.2. Proyectos centrados en las UPP

Dentro las actividades de la presente tesis, se revisó un conjunto de aplicaciones, proyectos y metodologías enfocadas al reconocimiento de posturas a través de dispositivos inteligentes con sensores. En primer lugar, se explicarán diez proyectos que aplican tecnologías de apoyo a los pacientes que padecen o están en riesgo de padecer UPP.

El trabajo realizado por Hugo Daniel Aguagüña [4] aporta al cuidado del paciente mientras se encuentra en rehabilitación, normalmente son pacientes con movilidad limitada, el sistema detecta movimientos y posiciones por medio de una tarjeta Raspberry PI 3, que recibe el video del entorno a través de la cámara web ubicada frente al paciente en rehabilitación, a una distancia predeterminada, es importante destacar la ubicación e iluminación de la cámara para evitar la generación de falsas alertas. Esta tarjeta electrónica procesa la información recibida de la cámara para ser mostrada en la pantalla LCD; la imagen capturada del paciente se enmarca en un recuadro de color visible de acuerdo a parámetros establecidos en la programación. El personal médico debe instalar la aplicación Telegram, la cual proporciona una alerta en tiempo real mediante mensaje de texto enviado a un dispositivo móvil. Estas notificaciones se envían cuando se detectan movimientos del cuerpo, o cuando el paciente no está en la posición adecuada. Es una solución ingeniosa, pero un poco costosa para los sistemas de salud, más aún si se tiene en cuenta que esta patología no está priorizada. El sistema se puede observar en la figura 2.2




FIGURA 2.2: Sistema SEAPULP [4]

En otro estudio realizado por Yáñez [109], se presenta el desarrollo de una aplicación informática que permite estandarizar los criterios de prevención, tratamiento y seguimiento de UPP. Esta propuesta consta de un app que permite al personal médico la recolección de datos, con un software capaz de su interpretación y algoritmos de decisión, los cuales permiten la generación de información relacionada con el tipo de control realizado, que actúa como soporte para la toma de decisiones en cuestiones de resultados, recomendaciones y cuidados generales. La aplicación web permite la gestión y un seguimiento periódico, así como la valoración del riesgo de padecer UPP, exportando los datos en forma de indicadores al personal médico para determinar los cuidados y personalizar el tratamiento de cada paciente. A nivel de monitoreo es una excelente alternativa, pero no detecta la posición del paciente de manera automática, lo que hace que el error humano pueda ser un problema en el proceso.

En el proyecto realizado por [94] se tuvo como propósito comparar

la medida del área de úlceras venosas por medio de los programas de software AutoCAD e Image Tool. El personal de enfermería recolectó datos entre 21 pacientes con úlceras, además de diligenciar los formularios de recolección y tomar fotografías de las heridas. Las heridas de las UPP fueron medidas en ambos programas, y los resultados alcanzados en dicho proyecto fueron los siguientes: entre los tamaños de las úlceras se presentó gran amplitud, sin diferencia significativa entre las medidas; existe excelente correlación intraclase y de concordancia entre los programas de software, los cuales parecen ser más precisos en medidas de heridas con áreas mayores a 10 cm. A nivel de analítica es una solución interesante, pero no previene la aparición de UPP, algo que se puede observar en la figura 2.3




FIGURA 2.3: Diagrama de selección de los participantes del estudio y procedimiento de recolección de datos, Santa María, RS, Brasi

Por otra parte, se tiene la herramienta CardioSmart (Sistema inteligente de monitorización cardiológica empleando GPRS), el cual esta compuesto por : i) un terminal portátil y un centro receptor, que proporcionan monitoreo y atención médica durante todo el día en tiempo real. ii) procesamiento avanzado de señales para el reconocimiento de cardiopatías mediante redes neuronales, compresión empleando wavelets, encriptación y GPS para localizar al paciente. El sistema resultante ha sido validado clínicamente, cumpliendo los requisitos mínimos de este servicio tele cardiológico, y creando de esta manera un ambiente inteligente en torno al paciente[81]. El diseño se puede observar en 2.4




FIGURA 2.4: Escenario del Sistema CardioSmart.

En el año 2020, Cortés et al. [26] presentaron un proyecto cuyo objetivo era validar y determinar la factibilidad de un dispositivo que monitorea los cambios de movimiento, con el fin de usarlo tanto para prevención de caídas como de UPP. Metodológicamente, en la primera etapa se caracterizaron y ajustaron tres prototipos, determinando el dispositivo idóneo para el desarrollo de la investigación.

Definido el dispositivo, se evaluó el funcionamiento y factibilidad del mecanismo en cuatro fases. En la primera fase, se validó la sensibilidad del dispositivo con un goniómetro. En la segunda fase, se probó el funcionamiento del dispositivo en voluntarios. En una tercera fase, se ajustaron las alarmas para prevención de caídas y las notificaciones de cambio de posición para UPP con voluntarios en un ambiente simulado. En la cuarta fase, se analizó la factibilidad del dispositivo en pacientes en hospitalización y UCI.

Para los resultados se compararon tres prototipos, con la finalidad de seleccionar uno, y de acuerdo con el prototipo seleccionado se realizaron seis dispositivos iguales; en un segundo momento se establecieron cuatro pasos para determinar la factibilidad del dispositivo seleccionado, para lo cual se realizaron pruebas de sensibilidad con goniómetro y pruebas para determinar el tiempo de la postura en adultos sanos en la noche, además del testeo de las alarmas exitosas en prevención de caídas. El dispositivo se puede observar en la figura 2.5.




FIGURA 2.5: Ángulo dado por el dispositivo en el eje X al sentarse.

En el año 2020, en el estudio de Zhang et al. [115] para mejorar la precisión del reconocimiento de la postura y la confiabilidad para su uso con conjuntos de datos invisibles, se diseñaron y evaluaron tres

tipos de clasificadores (un solo modelo sMLP y dos modelos híbridos: hAHC y hSHC), que utilizaron un conjunto de datos recopilados de sujetos invisibles. Los datos experimentales demostraron que el modelo hAHC funcionó mejor en comparación con los otros, ya que no solo obtuvo la precisión deseada, sino que también mostró los resultados en tiempo real, utilizando claramente la ventana adaptativa basada en la postura, que evita el problema de superposición. Algunos de sus alcances más relevantes son: i) el desarrollo de un novedoso algoritmo de calibración de sensores, basado solo en software, que puede mejorar la precisión del acelerómetro; ii) la creación de un modelo híbrido innovador hAHC, que combina tres clasificadores complementarios en tres capas (ASS, sMLP y PV), capaces de reducir el número de muestras mal clasificadas del clasificador sMLP, por utilización del enfoque PV dentro de cada ventana deslizante adaptativa basada en la postura, separadas mediante el algoritmo ASS; iii) la adopción de un método de visualización creativa, mediante el cual la clasificación de la postura que se realizó en tiempo real es visualizada claramente en un formato animado; iv) además, como muchos otros sistemas, la salida del análisis puede proporcionar recordatorios en tiempo real cuando ocurre una anomalía en la actividad (por ejemplo, caídas).

En el año 2021, Diao et al. [29] presentan un sistema de tapete inteligente basado en un sensor denso flexible y en una matriz de electrodos con un algoritmo para el reconocimiento de la postura del sueño. El sistema ofrece una solución para detección de presión a largo plazo. Los resultados experimentales muestran que la precisión del




FIGURA 2.6: Configuración del sistema y el sistema de coordenadas de la etiqueta

experimento a corto plazo es hasta del 95.08 %, y que la precisión de la noche a la mañana es hasta del 86.35 %. Comparado con otros métodos, el sistema puede lograr una clasificación satisfactoria de precisión, mientras se reduce el espacio de la alfombra y el número de sensores, lo que potencialmente reduce el costo y el cálculo de complejidad, aumentando su portabilidad. Además, el sistema de tapete aún se puede mejorar explorando e integrando información adicional, como la respiración y los movimientos corporales, para proporcionar una evaluación más completa del sueño.




FIGURA 2.7: Ejemplo de 8 posturas

En el año 2021, Fan et al. [37] proponen un sistema de reconocimiento de postura de tiro de baloncesto, por fusión de sensores, basado en redes neuronales convolucionales (CNN). El sistema utiliza un framework de fusión de sensores para recopilar los datos de la postura

de disparo en la mano de fuerza principal y en el pie de fuerza principal de los jugadores, y realiza la fusión de datos del sensor. Posteriormente, se utiliza un modelo de aprendizaje profundo basado en CNN para la clasificación. Un total de 12 177 datos de postura de tiro de baloncesto de fusión de sensor, para las entradas de la mano derecha y del pie izquierdo, se recopilaron utilizando este sistema para 13 sujetos varones, adultos y jóvenes entre 18 y 40 años. Las posturas de tiro de las entradas de datos se entrenaron y probaron utilizando el clásico modelo de aprendizaje profundo VGG16, basado en CNN, mediante métodos de intra e interentrenamiento/prueba, logrando resultados satisfactorios de clasificación. El intratest logró un 98.6 %, en la tasa de recuperación promedio y una tasa de precisión promedio de 98.6 %.




FIGURA 2.8: Marco de fusión de sensores.

2.2.1. Aplicaciones Móviles

En este apartado se revisan los trabajos relacionados con sistemas de apoyo a las UPP a través de aplicaciones móviles.

La aplicación WOUND ANALYSIS [8] es un sistema que cuenta con las siguientes características: genera fotografías y registros de los pacientes, obtiene la autorización de los pacientes en un

consentimiento escrito para realizar el tratamiento, define la curva objetiva de la evolución de las lesiones, realiza consultas entre profesionales compartiendo los casos mediante la aplicación, además de que muestra una opción de empoderamiento de los pacientes, con auto registros y avisos al dispositivo en caso de mala evolución de la app con el paciente.



FIGURA 2.9: Aplicativo WOUND ANALYSIS

Otro ejemplo es el aplicativo Smart UPP, el cual tiene como propósito ayudar a prevenir la aparición de las UPP mediante el uso de inteligencia artificial [53]. Está dirigido al personal asistencial encargado del cuidado del paciente y permite recolectar información del mismo, para aplicar escalas de riesgo y elaborar de manera personalizada una guía de actuaciones preventivas. También es capaz de utilizar experiencias previas y el feedback suministrado por los usuarios para su autoaprendizaje, a fin de poder adaptarse a cada paciente.

El Sistema Integrado para el Manejo de Heridas (HELCOS)[99] es una herramienta que orienta tanto a los profesionales como a los pacientes para el manejo de heridas. La aplicación permite realizar



FIGURA 2.10: Smart UPP
<https://www.smartupp.es/>

tele consulta, con expertos de otras disciplinas, a modo de chat desde de la aplicación y para un caso concreto. Toda esta información queda registrada en la historia clínica que se genera en el sistema.

The image is a screenshot of a web login page for 'Helcos'. It features three vertical panels with maroon headers. The first panel, 'Usuarios registrados', has a login form with fields for 'Email' and 'Contraseña', a 'Recuérdame' link, and a button 'Iniciar sesión'. The second panel, 'Profesional Sanitario', contains text about creating a professional profile and a 'Registrarme' button. The third panel, 'Paciente', contains text about creating a patient profile and a 'Próximamente' button. All panels have a footer with the text 'No he recibido ninguna confirmación' and a 'Reenvíame' link.

FIGURA 2.11: <https://helcos.net/users/login>

La app Pressure Ulcer Guide [48] es una guía que proporciona estrategias de información y prevención sobre úlceras por presión, escaras o heridas. Cuenta con una herramienta de valoración de riesgo llamada escala de Braden, para evaluar la posibilidad de la úlcera por presión o escaras de decúbito.

2.3. Herramientas tradicionales de apoyo para el tratamiento de UPP

En esta sección se revisan los dispositivos médicos tradicionales más relevantes que son utilizados como herramientas de apoyo en el



FIGURA 2.12: APP Pressure Ulcer Guide)

tratamiento de UPP.

La empresa Ortopedia Moverte presentó en el año 2014 [86] su producto llamado “Reloj de pared giratorio para ayuda en la prevención de úlceras”, el cual permite crear un protocolo personalizado de cambios posturales para cada paciente de riesgo. Está compuesto por seis ruedas giratorias que ayudan a seleccionar entre las tres posiciones de descanso de personas encamadas: decúbito lateral en 30° (derecho e izquierdo) y decúbito supino. Es un reloj manual que permite un fácil recordatorio para el personal cuidador al lado de la cama del paciente. Al mismo tiempo, los familiares o responsables sanitarios pueden supervisar fácilmente el cumplimiento del protocolo. Al utilizar ilustraciones gráficas de las posiciones de los pacientes resulta muy intuitivo y fácil de interpretar. Entre las desventajas se tiene que no es un sistema automatizado, y las rotaciones deben realizarse manualmente, por lo cual no permite un monitoreo en tiempo real.

En el trabajo de [44] se presentó una revisión literaria de las superficies especiales de manejo de presión para la prevención y tratamiento de las UPP, tales como: cojines, camas, cobertores de colchones,



FIGURA 2.13: Reloj de pared giratorio para ayuda en la prevención de úlceras

colchones de espuma, estáticos, de presión de aire alternante y dispositivos denominados SEMP, los cuales permiten la redistribución de la presión y por tanto el alivio de la misma en las personas que presentan úlceras por presión o tienen riesgo de padecerlas, comparando además la eficacia de los colchones de aire de baja presión alterna y los colchones de superposición de aire de presión alterna. En los resultados obtenidos no se relacionan aspectos como la comodidad percibida por los pacientes y la adaptabilidad de estos. Es importante hacer hincapié en la formación del personal sanitario, quienes son los responsables de seleccionar y realizar un buen uso de estas herramientas, además de que, en la documentación revisada, ninguna hace referencia al ámbito domiciliario o atención primaria.

Por otra parte, se considera que la participación de la tecnología es muy valiosa como aporte en la prevención y tratamiento de este tipo de eventos, que si bien se había venido haciendo de forma indirecta, aportando en el desarrollo de superficies de soporte como



FIGURA 2.14: A) Cojín Antiescaras; B) Colchón de Espuma

colchones, cojines, taloneras, manoplas y demás, también se venían desarrollando técnicas para el tratamiento. Los autores McInnes E. y colaboradores [44] presentan una revisión sistemática para conocer la eficacia de las diferentes superficies utilizadas en el tratamiento de las UPP, como las mencionadas anteriormente, con el fin de disminuir su aparición. Entre los resultados mas relevantes que se obtuvieron se indica que las espumas de alta especificación, comparadas con el colchón de espuma utilizado en los hospitales, reducen la incidencia de aparición de UPP, pero su costo es alto para los centros de salud, por lo que no son una solución viable.



FIGURA 2.15: A) Espuma de alta especificación;
B) Colchón de espuma

2.4. Metodologías de reconocimiento de posturas

En esta sección se presentan tres metodologías de reconocimiento de posturas. La primera en relación a la clasificación de imágenes de UPP mediante el uso de técnicas de aprendizaje profundo; la segunda hace referencia a la clasificación de posturas en cama, utilizando sensores de tapete de presión para la prevención de UPP mediante redes neuronales convolucionales; y la tercera presenta un enfoque de aprendizaje profundo para la prevención de las úlceras por presión mediante dispositivos vestibles.

Antes de revisar cada metodología en detalle, se presenta un resumen con las tres metodologías en la tabla 2.4.

Metodologías	Casado et al.,2019	Rodríguez et al., 2020;	Cicceri et al., 2020
Tipo de sensores	Sensores de visión	Sensores de presión	acelerómetro y magnetómetro

Arquitectura	Uso de redes convolucionales para la clasificación de imágenes de úlceras cutáneas producidas por presión y técnica Data Augmentation.	1.Se proporciona una representación visual mediante procesamiento difuso de datos sin procesar a escala de grises. 2.Se incluyen técnicas de aumento de datos ad hoc. 3. Se evalúan 2 tipos de CNN.	Se utiliza una puerta de enlace, que tiene que recopilar datos de los sensores conectados a los cuerpos de los pacientes, procesarlos y luego enviar la información al servidor remoto y almacenarla en una base de datos que el personal médico puede acceder.
Algoritmos de clasificación	k-nearest neighbor Algorithm (LSH)	Tiempo real CNN	Tiempo real SVM Y RF

Datos	113 imágenes. Posturas: Skin, curación, necrosis, granulación, slough.	8 participantes Posturas: supina, izquierda y derecha	6 voluntarios Posturas: sentado, boca abajo, supino, acostado a derecha e izquierda y en movimiento.
Tipo de validación	Validación cruzada. K FOLD Cross Validation.	Validación cruzada Dejar un participante fuera	Validación tomando el 15 % de los datos de entrenamiento.
Precisión obtenida	Para las imágenes de 16 x16 Precisión del 90 % y para las imágenes de 8x8 tiene una precisión del 71 %.	Precisión de F1 del 98 %.	Con SVM precisión del 99.32 %. Con RF precisión del 82,80 %.

Clasificación de imágenes de úlceras por presión mediante el uso de técnicas de aprendizaje profundo

En el año 2019, Casado et al. [20] propusieron un estudio sobre el uso de redes convolucionales para la clasificación de imágenes de úlceras cutáneas producidas por presión. El diseño y desarrollo de una herramienta que realice la clasificación automática, eficiente y fiable de este tipo de lesiones sería de gran ayuda al personal médico. En una primera fase, se han diseñado varios sistemas convolucionales, los cuales se han entrenado y testeado con imágenes desconocidas para ello. Segunda fase, se continuo con la aplicación de la técnica llamada Data Augmentation, el cual permitió mejorar el desempeño de los primeros sistemas. Acto seguido, se realizó un estudio de los resultados obtenidos por cada sistema, observándose la evolución de ciertos parámetros que miden la eficiencia del mismo, como son la precisión, el F1-Score o el Recall. También se empleó la matriz de confusión, para observar cómo clasifican los diferentes sistemas a cada imagen, dependiendo de la clase a la que pertenece.

La arquitectura del sistema depende directamente del tamaño de la imagen de entrada a la red. Como consecuencia, un sistema que tiene como entrada imágenes de tamaño 16x16 no tendrá la misma arquitectura que uno que recibe como entrada imágenes de tamaño 8x8.

Con relación al dataset, un equipo médico realizó fotografías a color de las úlceras de pacientes que recibían asistencia sanitaria en sus domicilios. Se fotografiaron las úlceras localizadas en la cadera y el

sacro de los pacientes, empleando una cámara digital Canon EOS 40D.

Un grupo de expertos clínicos seleccionó 113 imágenes, que han sido segmentadas utilizando el algoritmo K vecino más cercano (KNN), calculado mediante una adaptación a aplicaciones de visión del algoritmo Local-Sensitive Hashing (LSH). Además se utilizó también un algoritmo de crecimiento de regiones, para conservar por completo los bordes que delimitaban las regiones que se obtuvieron de cada imagen. El resultado fue de 17.007 regiones, obtenidas tras la segmentación de todas las imágenes.

El conjunto de imágenes ha sido dividido en tres subconjuntos diferentes: entrenamiento, validación y test. El subconjunto entrenamiento es el más amplio y, en este caso, se ha decidido que abarque el 70 % de las imágenes totales de cada clase. Esto es así, debido a que cuanto mayor sea el tamaño de este subconjunto, mejor va a “aprender” la red a reconocer y clasificar los diferentes tipos de tejido. Como ya se puede suponer, este subconjunto va a ser utilizado para entrenar a la red.

Los mejores resultados se han obtenido con las imágenes de tamaño 16x16, alcanzándose, en cada subconjunto, precisiones cercanas al 90 %. Para los conjuntos de tamaño 8x8, los parámetros de clasificación disminuyen en un porcentaje considerable, entre el 70 % y 71 %, respectivamente. Entre los principales inconvenientes se encuentra el gran desbalanceo que sufre el conjunto de imágenes por el tamaño, además de que se cuenta con pocas imágenes, y las mismas resultan insuficientes.

In-Bed Posture Classification from Pressure Mat Sensors for the Prevention of Pressure Ulcers Using Convolutional Neural Networks

En el año 2020, Rodríguez et al. [83] presentaron una metodología para clasificar la postura humana en cama, utilizando sensores de tapete de presión para la prevención de úlceras por presión.

En primer lugar, la arquitectura del sistema de los datos recopilados por los sensores de tapete de presión proporciona una representación visual mediante procesamiento difuso de datos; sin procesar a escala de grises. Segundo, se incluyen técnicas de aumento de datos ad hoc para incrementar el conjunto de datos, generando nuevas imágenes sintéticas mediante transformaciones geométricas. Tercero, se evalúan dos tipos de CNN para analizar el impacto del número de capas y el tamaño en el aprendizaje de la postura. Finalmente, la clasificación de la postura de los pacientes permite el cálculo en tiempo real del tiempo que se mantiene cada posición, lo que permite que los cuidadores sean notificados cuando se alcanzan los límites de tiempo.

Se describen dos tipos de redes neuronales convolucionales para clasificar la postura de los pacientes en la cama. En el conjunto de datos se tienen tres clases para la CNN: posición supina, izquierda y derecha. Basándose en la información visual de las imágenes, las CNN aprenden de los núcleos que están relacionados con patrones visuales clave, cuya similitud con las regiones visuales de origen es definido por una operación convolucional.

Con relación al dataset, para efectos de evaluar la metodología




FIGURA 2.16: Arquitectura de los componentes propuestos en la metodología: conjunto de datos limitado de sensores de tapete de presión, representación visual difusa, aumento de datos y aprendizaje de las CNN

propuesta, se tiene un conjunto de datos desarrollado en el experimento II, que fue recopilado por el dispositivo Vista Medical BodiTrak BT3510. Este experimento se llevó a cabo con 8 participantes de entre 19 y 34 años. La altura y el peso de los participantes estaban en el rango de [169-186 cm] y [63-100 kg], respectivamente. En el experimento II se usó una alfombrilla de sensor de presión de esponja para recolectar datos sobre la postura en la cama de los participantes. La frecuencia de muestreo fue de 1 Hz y cada archivo incluyó la presión promedio de alrededor de 20 cuadros de 2 minutos (alrededor de 120 cuadros). La postura supina se definió mediante 8 posiciones diferentes; la postura izquierda incluye 3 posiciones diferentes y la postura derecha también.

Para fines de evaluación, se incluyó una validación cruzada de exclusión de un participante, lo que conduce a pruebas arduas dado que los datos no vistos de los participantes se utilizan para evaluar

modelos generados para otros participantes, sin incluir un aprendizaje personalizado.

Se observa que ambos modelos proporcionan resultados alentadores con precisión y puntuación F1 de hasta el 98 %. Este es un desempeño excelente, dado el contexto de aprendizaje y el proceso de validación altamente exigentes: (i) se utilizó una pequeña cantidad de muestras como datos de entrenamiento, (ii) se usó una validación cruzada, que dejó a un participante fuera, con datos de usuario no vistos para la evaluación. Entre los principales inconvenientes se tiene que para la clasificación de todos los participantes no se hizo uso de protocolos específicos. Además, las pruebas se realizaron con un reducido número de pacientes en el dataset en un ambiente real.

A deep learning approach for pressure ulcer prevention using wearable computing

En el año 2020, Cicceri et al. [24] propusieron el proyecto de enfoque de aprendizaje profundo para la prevención de las UPP, en el cual, mediante la informática portátil se recolectaron datos provenientes de sensores inerciales, con el objetivo de diseñar e implementar un sistema no invasivo de sensores vestibles para la prevención de UPP a través de técnicas de aprendizaje profundo. En particular, utilizando sensores inerciales se pueden estimar las posiciones del paciente, y enviar señales de alerta cuando permanece en la misma posición durante un periodo de tiempo demasiado largo. Para probar el sistema, se construyó un conjunto de datos, monitoreando las posiciones de varios pacientes durante su periodo de hospitalización,

que demostró la viabilidad de esta técnica y el nivel de precisión, comparando el modelo con otros enfoques populares de aprendizaje automático. Los resultados fueron alentadores, y demostraron que las técnicas de aprendizaje profundo ofrecen un mejor rendimiento en comparación con otras técnicas de aprendizaje automático como Support Vector Machine (SVM) y Random forest (RF); por esta razón, pueden considerarse como un apoyo confiable para la salud del paciente, particularmente para el dominio de la prevención de UPP.

La arquitectura se presenta en un escenario clínico y contempla a uno o más pacientes, ubicados en una habitación con una bata de hospital, con un conjunto de sensores portátiles adosados en el área abdominal. Los sensores son un acelerómetro de tres ejes y un magnetómetro de tres ejes, que utilizamos para detectar el movimiento del paciente y medir la orientación postural del cuerpo. Para poder gestionar varios dispositivos vestibles pertenecientes a diferentes pacientes en la misma habitación, se propuso una arquitectura hardware/software compuesta por una pasarela de habitación que se comporta como un puente entre los dispositivos Internet of Medical Things (IoMT) y la nube.

Para comparar el rendimiento del enfoque propuesto con otros modelos, se entrenaron y probaron otros algoritmos utilizando el mismo conjunto de datos, en particular SVM y algoritmos de RF. Las SVM pudieron generalizar muy bien los datos, alcanzando una precisión del 99.32 % en el conjunto de prueba. Además, utilizo el clasificador de RF, estableciendo 100 estimadores y aplicándolo al mismo conjunto de datos, logrando una precisión del 82.80 %.




FIGURA 2.17: Arquitectura general del sistema

Se trabajó un enfoque supervisado, donde todos los datos almacenados dentro del conjunto de datos están etiquetados con la posición correspondiente del paciente. La recolección de datos se ha realizado con seis voluntarios pertenecientes a diferentes perfiles, en términos de edad, peso y sexo. Se previó un conjunto de dispositivos portátiles adjuntos, que registraban la posición del cuerpo mientras se realizaban cinco actividades físicas como: permanecer sentado, boca abajo, supino, acostado a derecha e izquierda y en movimiento.

Los sensores se colocaron en el tórax de cada paciente, y gracias a la ayuda de enfermeras se monitorearon a todos los pacientes a través de una cámara. Cada voluntario tenía restricciones sobre los movimientos que podía hacer, por lo que los datos recopilados se derivaron de un esquema de movimiento totalmente natural. Este, en

particular, fue el principal requisito para los voluntarios para obtener un conjunto de datos sin ningún tipo de sesgo. Además, se recopilieron los datos de diferentes personas para tener una mejor generalización de los patrones de movimiento comunes.

Posteriormente, se dividió el conjunto de datos original en tres conjuntos, a saber: conjunto de entrenamiento, conjunto de validación y conjunto de pruebas, donde las dimensiones del conjunto de pruebas y entrenamiento son, respectivamente, el 85 % y el 15 % del conjunto de datos original que recopiló, mientras que el conjunto de validación se ha obtenido tomando el 15 % de los datos de entrenamiento. Se requiere de la validación de las técnicas para mejorar el rendimiento general del sistema en cuanto a capacidad de respuesta, comportamiento en tiempo real para el intercambio de datos y duración de la batería de los sensores.

Capítulo 3

Dispositivos inteligentes para el reconocimiento de actividades

En el desarrollo de esta tesis doctoral se han aplicado una serie de fundamentos que se explican en este capítulo. Por un lado, se revisan los dispositivos con sensores inerciales y dispositivos vestibles y, por otro lado, se expone la metodología utilizada para el reconocimiento de actividad en cuatro fases: señales de actividad, extracción de características, modelo de actividad y, finalmente, inferencia.

3.1. Dispositivos con sensores inerciales

Los dispositivos inerciales se pueden definir como mecanismos compuestos por sensores inerciales acoplados a un microcontrolador y a un sistema de comunicación. Los tipos de sensores inerciales son

el acelerómetro, el giroscopio y el magnetómetro, como se muestran en la figura 3.1.




FIGURA 3.1: Giroscopio, acelerómetro y magnetómetro [51]

Los dispositivos con sensores inerciales han sido ampliamente utilizados con éxito. Entre las aplicaciones más destacadas es digno de mención el estudio del movimiento humano.

3.1.1. Acelerómetro

El acelerómetro determina la aceleración lineal, de acuerdo a su funcionamiento, estos pueden ser: mecánicos, de efecto Hall, piezoeléctricos, piezoresistivos y capacitivos, siendo los dos últimos los más utilizados. En la década de los ochenta, el primer acelerómetro del mercado era el piezoresistivos, a pesar del tiempo, esta tecnología aún sigue en uso, teniendo en cuenta las ventajas en costo e inmunes a interferencias electromagnéticas [100]. Hoy en día los más usados son los acelerómetros capacitivos, ya que presentan mayores prestaciones, en cuanto a rango de sensibilidad, son mas robustos frente a cambios de temperatura y su consumo es menor, sin embargo,

tiene una limitación ya que soy muy susceptibles a las interferencias electromagnéticas [80].

Entre las ventajas mas importantes del acelerómetro, es considerado uno de los sensores más utilizados en estudios referentes a movimientos, debido a los datos que captura, proporcionando información inercial dinámica, es decir una señal puede indicar cuando hay movimiento, también ofrece información estática, es decir detecta cuando hay ausencia del movimiento, y además proporciona información con respecto a la orientación relativa respecto a la gravedad [60].

3.1.2. Giroscopio

El giroscopio determina la velocidad angular de un objeto y es utilizado en múltiples campos, como, por ejemplo, se utiliza en la estabilización de cámaras de fotografía para remediar el movimiento efectuado, de igual forma, los automóviles se usan para detectar giros, en robótica y otros campos como la aeronáutica [110].

El funcionamiento del giroscopio se basa en la medida del efecto Coriolis. Está formado esencialmente por un cuerpo con simetría de rotación que gira alrededor del eje de dicha simetría. Este principio causa que la estructura mecánica del giroscopio haga vibrar a otra estructura, esta vibración es directamente proporcional a la velocidad de rotación del sistema y que se puede medir a través de la capacitancia variable debido a la vibración entre la segunda estructura mecánica y unos electrodos fijos [85].

Se destacan varios trabajos implementado giroscopios para el análisis de movimientos, en los cuales se pueden mencionar, las transiciones de postura [69] o las caídas [52]. Una de sus ventajas a destacar es su bajo costo, por lo que es muy utilizado en la industria de videojuegos y aplicaciones para teléfonos móviles.

Entre sus limitaciones se tiene, en cuanto al movimiento es más limitado, ya que por ejemplo no aporta información inercial en el caso de ausencia de movimiento a diferencia del acelerómetro, en este caso, el giroscopio solo proporciona ruido blanco. Además, el giroscopio es propenso a sufrir derivas por cambios de temperatura. Por tanto, es necesario recalibrarlo con frecuencia en el caso de tomar medidas en periodos largos. En la propuesta de las metodologías se ha hecho uso del giroscopio para el análisis del movimiento humano, identificando las transiciones de posturas o caídas

3.1.3. Magnetómetro

Por otra parte, el magnetómetro determina el norte magnético, es decir, mide el campo magnético en un punto determinado, permitiendo analizar el movimiento de una persona. Se divide en dos tipos básicos: los que miden el campo magnético absoluto, y los que miden el campo magnético vectorialmente [106]. El último permite orientar en un punto determinado en el espacio, en efecto se puede identificar la orientación de un objeto a través de un magnetómetro triaxial. Los magnetómetros son utilizados en diversas aplicaciones como por ejemplo, la navegación, en automóviles, en robótica y detección de objetos metálicos [106]. Una de las limitaciones es que

son sensores susceptibles a ruidos, por lo tanto no se recomienda estar cerca a un objeto ferromagnético al realizar medidas con los sensores, ya que puede alterar las medidas obteniéndose el campo magnético de la Tierra sumado al del campo magnético que fluye por el elemento ferromagnético [51].

3.2. Dispositivos vestibles

Las propuestas de esta tesis doctoral se fundamentan en el uso de dispositivos vestibles. Por ello, en esta sección revisamos los dispositivos vestibles y sus aplicaciones en materia de salud. Los vestibles son el resultado de varias tecnologías como son, los avances en nanotecnología, el bajo costo y el incremento de funciones de los sensores, la evolución de sistemas operativos, la mejorar en baterías, la evolución de procesadores de menos consumo energético y la propagación de conexiones inalámbricas[111].

El término wearable es un término anglosajón que significa literalmente 'que se puede llevar puesto'[111] por lo tanto también es conocida como tecnología vestible. Se ha destacado la aplicación de los sensores wearables como herramientas útiles para recoger nuevos datos y señales vitales durante la actividad diaria y física [18] destacando el contexto de salud ya que permiten monitorizar o describir las necesidades de los pacientes de forma constante y poco invasiva [57].

Hoy en día existe un gran avance en tecnologías vestibles en el sector salud, debido a sus beneficios y herramientas de apoyo para

el diagnóstico, prevención y tratamiento de diferentes patologías, a continuación, relacionamos algunas de ellas.

- Los relojes y las pulseras inteligentes: son los dispositivos mas utilizados y vendidos en el mercado, por la popularidad que han alcanzado. En el sector salud son comúnmente utilizados para monitorizar el ritmo cardiaco, la presión arterial, los niveles de glucosa, calcular horas de sueño entre otras. Todos los datos son transmitidos a un App, el cual permite ser consultado por el paciente y el médico mejorando el seguimiento y la adherencia al tratamiento [58].
- Gafas inteligentes: también conocidas como “Google Glass”, no son muy utilizadas en el sector salud, el objetivo principal de estas gafas eran ser una herramienta que permitiera al personal médico ensayar técnicas específicas, para el tratamiento de algunas patologías o para transmitir cirugías en directo. También pueden funcionar como soporte para las personas con limitaciones visuales o con baja visión [6].
- Sensores: Uno de los grandes avances son los sensores adheridos al cuerpo, los cuales puedes medir diferentes signos vitales como es la temperatura, la humedad, la actividad cerebral entre otras. Además de ser dispositivos de tamaño reducido y cómodos de utilizar, además permiten un monitoreo continuo del paciente, sin ser incomodo para él. Un ejemplo de lo anterior es el tatuaje electrónico [1].
- Ropa inteligente: Entre las aplicaciones de salud destaca la

camiseta inteligente, creada por la Universidad Carlos III de Madrid. El dispositivo permite a los especialistas llevar un seguimiento diario, con el fin de obtener un registro electrocardiográfico de calidad médica, medir el ritmo de la respiración, la temperatura corporal y hasta saber si el paciente está de pie, caminando, tumbado o dormido, o si se ha caído [96].

Entre las ventajas de trabajar con vestibles se encuentran:

- **Objetivo natural:** Es una tecnología pensada en convertirse en una herramienta de apoyo para mejora la calidad de vida de las personas, actualmente es muy utilizada en el ámbito médico.
- **Almacenamiento de información:** con esta tecnología, permite registrar datos de forma local, transmitirla y luego procesarla, de igual forma se puede sincronizar en tiempo real con otros dispositivos o redes.
- **Baja radiación:** teniendo en cuenta que en su mayoría son dispositivos de tamaño pequeño, emiten menor radiación que otros dispositivos como los computadores y los teléfonos.
- **Aplicación a múltiples campos:** actualmente es una tecnología que se usa en diferentes sectores como salud, agricultura, educación, entre otros. Cada día, permite encontrar más nichos en el mercado, lo que impulsa a la creación de productos cada vez mejores.
- **Dispositivos multisensores:** una de las ventajas de este

tipo de tecnologías es que permite realizar medición de diferentes parámetros al mismo tiempo, esto hace posible tener información en tiempo real, apoyando la toma de decisiones del sector médico.

- Transparencia para el usuario: una de sus particularidades, es la interacción con el ambiente, el cual se puede llevar a cabo en tiempo real y sin intervención humana.
- Bajo peso. Una de las características principales es su tamaño reducido, convirtiéndose en tecnologías cómodas y fácil de llevar, en comparación de otras tecnologías como las tablets y teléfonos inteligentes.
- Alto grado de configuración. La mayoría de los dispositivos son altamente configurables, permitiendo al usuario la parametrización casi total del dispositivo respecto a qué funcionalidades quiere activar y cómo desea que se midan y presenten los datos [71].

Existen trabajos centrados en recolección de datos a través de dispositivos vestibles, que permiten transmitir información en tiempo real, generando alertas a los familiares o centros de salud. A continuación, revisaremos aquellas propuestas de dispositivos vestibles más relevantes. Uno de estos trabajos es el de Pierleoni et al. [78], presenta el desarrollo de un dispositivo con el propósito de generar alertas, cuando identifica que la persona mayor ha sufrido una caída, el dispositivo se ubica en el tobillo del usuario. Por otra parte, si el dispositivo detecta que la persona no se levantado por

un prologado tiempo, se genera automáticamente una segunda alerta por caída crítica. El dispositivo este compuesto por un acelerómetro triaxial, un giroscopio y un magnetómetro utiliza un algoritmo de fusión de datos conocido como filtro de orientación. Adicionalmente permite detectar la posición del usuario.

En el año 2018, Facal et al. [36] presentan el desarrollo de un dispositivo vestibular, cuyo objetivo es detectar la postura del torso del usuario y clasificar sus diferentes movimientos en rangos. EL dispositivo este compuesto por un acelerómetro digital, un microcontrolador, circuitos de alimentación e interfaz con el usuario. El proyecto se llevó a cabo a través de cuatro fases: a) se seleccionaron los componentes y se desarrollo el prototipo, además se generaron técnicas de calibración del acelerómetro y de posicionamiento del mismo, respecto al torso de la persona, b) se determino las posiciones y movimientos c) se realizo un estado en relación a los algoritmos para la detección del movimiento, D) finalmente se diseño el dispositivo de tamaño pequeño, ajustando a las necesidades del usuario. Asimismo, mediante el procesamiento de las aceleraciones medidas en el andar cotidiano de una persona, se desarrolló un algoritmo para la detección de movimiento específico para la aplicación deseada. Dicho algoritmo fue validado mediante pruebas objetivas y luego implementado en firmware embebido, obteniendo buenos resultados.

El objetivo de Molina et al. [65] fue testear el dispositivo inercial WIMU PROTM, el cual permite registrar la frecuencia cardiaca, comparándolo con un dispositivo validado como es Polar Team 2®. Para la validación se contaron con 15 jugadores de fútbol, los cuales

oscilan entre los 15 y 50 años, para llevar a cabo la evaluación los jugadores desarrollaron el test Repeat Sprint Ability el cual consta de 7 sprints de 30 metros con una recuperación activa entre ellos de 20 segundos, con el propósito de simular los requerimientos reales en la competencia de fútbol. Entre los resultados se obtuvieron una correlación muy buena entre los datos obtenidos por el dispositivo WIMU PROTM y Polar Team 2®, en conclusión, el dispositivo WIMU PROTM permite reconocer la variable de intensidad física dada por la frecuencia cardiaca en el fútbol.

Para finalizar, en el año 2019 Zebin et al. [113] presentaron un modelo de red neuronal recurrente profunda (RNN) de memoria a largo y a corto plazo (LSTM), para la clasificación de las actividades cotidianas mediante el uso de datos de un acelerómetro y un giroscopio de un teléfono inteligente. El modelo propuesto se puso a prueba mediante el uso de la biblioteca TensorFlow de código abierto, optimizado e implementado en un teléfono inteligente Android. Los requisitos de recursos de hardware para la implementación se investigaron empíricamente y se discutió el efecto de la cuantificación de datos sobre la precisión de la implementación.

3.3. Reconocimiento de actividades

En esta sección se revisa la metodología clásica de reconocimiento de actividades, en la cual se basan las metodologías propuestas en esta tesis doctoral.

El reconocimiento de una actividad es definido por Chen et al.

[107] como la habilidad de identificar o detectar la actividad que las personas desempeñan en diferentes entornos, basándose en el procesamiento de la información recibida de diferentes sensores, ya sea usando la tecnología vestible, o sensores incluidos en objetos de uso común o en el mismo entorno.

Durante la última década, los sensores, especialmente de baja potencia, bajo costo, alta capacidad y miniaturizados, así como la comunicación por cable, las redes inalámbricas [75] [5] [31] y las técnicas de procesamiento de datos han tenido un progreso sustancial. Los avances y madurez de estas tecnologías de apoyo han impulsado los enfoques de investigación en diferentes áreas, para transitar desde los datos de bajo nivel de recopilación y transmisión hacia sistemas de información de alto nivel, procesamiento de contexto y reconocimiento e inferencia de actividades.

Al mismo tiempo, las soluciones para una serie de problemas del mundo real se han vuelto cada vez más dependientes de la actividad de reconocimiento. Por ejemplo, la vigilancia y la seguridad intentan hacer uso de tecnologías de reconocimiento de actividad para abordar las amenazas terroristas. Por otra parte, la vida asistida ambiental tiene como objetivo explotar el reconocimiento de actividades y la asistencia como apoyo a situaciones de vida independiente y de envejecimiento en el entorno, entre otras.

El reconocimiento de actividades tiene como objetivo entender los comportamientos humanos que permiten a los sistemas informáticos ayudar a los usuarios en función de sus necesidades [116].

Teóricamente, supongamos que un usuario está realizando algunos tipos de actividades pertenecientes a un conjunto de actividades predefinidas [102]: $A = (A_j)_{j=1}^m$, donde el número m se asocia a los tipos de actividad. Además, se define una secuencia de lectura del sensor, flujo de datos, que captura la información de la actividad: $S = \{d_1, d_2, \dots, d_t, d_n\}$, de tal modo que d_t define la lectura de un sensor en un tiempo t .

El procedimiento general convencional para la identificación de actividades humanas se ilustra en la figura 3.2.




FIGURA 3.2: Procedimiento general basado en sensores para reconocer actividades humanas [102]

Este procedimiento se divide en las siguientes cuatro etapas:

3.3.1. Señal de actividad

El primer paso es la obtención de datos en crudo provenientes de actividades, sin ningún tipo de procesamiento. Estos datos pueden tener una naturaleza diferente en función de los dispositivos con sensores que se utilicen para capturarlos. Por tanto, se pueden

diferenciar entre dos tipos de extracción de datos: basados en sensores que miden magnitudes físicas (densa) y basados en sensores de visión.

El enfoque de detección densa realiza el reconocimiento de actividades a través de la inferencia de interacciones usuario-objeto, mediante el uso de múltiples sensores miniaturizados multimodales [11] [76]. El enfoque es particularmente adecuado para tratar con actividades que involucran una serie de objetos dentro de un entorno, así como actividades de la vida diaria [115]. Dentro de este ámbito podemos encontrar múltiples sensores que nos pueden ayudar en este proceso.

A continuación, se listan los dispositivos con sensores más populares:

- Basados en redes inalámbricas: RFID (identificación por radiofrecuencia), Bluetooth, WiFi, etc. Suelen usarse para saber cómo se está moviendo el usuario, dónde está o para el conteo de usuarios en caso de multiocupación [7].
- Sensores vestibulares: Los sensores portátiles generalmente se refieren a dispositivos que son colocados directa o indirectamente en el cuerpo humano, los cuales generan señales cuando el usuario realiza actividades. Como resultado, se pueden monitorear las características que describen el estado fisiológico o el movimiento de la persona.
- Dispositivos que tienen integrados múltiples sensores, como puede ser un dispositivo móvil o un reloj inteligente.
- Sensores como acelerómetros, sensores de proximidad,

ultrasónicos, de gas, de luz, entre muchos otros, de los cuales, los sensores de acelerómetro son probablemente los más frecuentemente usados para el monitoreo de la actividad. Ellos son particularmente eficaces en el seguimiento de acciones que involucran movimientos corporales repetitivos, como caminar, correr, sentarse, estar de pie o subir escaleras.



FIGURA 3.3: Ejemplos de sensores: smart watch y RFID (lector y tarjeta) [95]

3.3.2. Extracción de características

La extracción de características es el procedimiento general de representación de la acción. Implica la extracción de un conjunto de parámetros locales y globales de las señales de actividad, con el objetivo de encontrar características lo suficientemente robustas.

En la segunda fase se extraen manualmente características basadas en el conocimiento humano [11], como la media, la varianza y la amplitud en los enfoques tradicionales de aprendizaje automático [108]. Además, es posible extraer y elegir dicho conjunto de características de manera automática a través de métodos de

aprendizaje profundo. De este modo, la característica extraída depende fuertemente del tipo de la fuente de datos. Por ejemplo, para el caso de los dispositivos con sensores de visión las características varían con respecto a los dispositivos basados en sensores de densidad. En el caso de la extracción de características en imágenes, aunque es posible obtener la media, la varianza, etc., se deben extraer además otras características inherentes al tipo de dato con el que se trata (imágenes RGB y RGBD), como pueden ser puntos de interés espacio-temporal [98], formas [101], profundidad [72] o posturas [105].

3.3.3. Modelo de actividad

La tercera etapa en el proceso de reconocimiento de actividad es la construcción de un modelo que permita, a través de una entrada de lecturas de sensores, identificar la actividad realizada.

Es importante precisar que, a la hora de definir el modelo para reconocer la actividad, se pueden distinguir dos grandes categorías: modelos basados en conocimiento y modelos basados en datos, que utilizan métodos de aprendizaje automático o profundo. Estos últimos modelos, basados en datos, necesitan de un conjunto de datos previo con el conjunto de actividades a aprender y las señales de los sensores generadas en diversas instancias de la actividad.

Los otros **métodos dirigidos por conocimiento** fijan un conjunto de variables y reglas que definen el problema, con las cuales el sistema es capaz de extraer conclusiones aplicando métodos de lógica clásica sobre esta base, como reglas, ontologías, etc. La gran ventaja

de los modelos basados en conocimiento es que no necesitan un conocimiento previo ni un entrenamiento con un conjunto de datos, además de ser semánticamente claros y fáciles de utilizar. Pero, por otro lado, son débiles para manejar la incertidumbre y la dinámica temporal de información, por lo que podrían verse como estáticos e incompletos.

Por ejemplo, el sentido común indica que la actividad de hacer café consiste en una secuencia de acciones que involucran una cafetera, agua caliente, una taza, café, azúcar y leche; la actividad de cepillarse los dientes implica acciones que involucran un cepillo de dientes, pasta de dientes, grifo de agua, taza y toalla. Por otro lado, como los seres humanos tienen diferentes estilos de vida, hábitos o habilidades, pueden realizar diversas actividades de formas distintas. De este modo, una persona puede gustar del café fuerte con leche, y otra puede preferir una marca especial de café. Incluso para el mismo tipo de actividad (como, hacer café con leche), diferentes personas pueden usar diferentes elementos (tal vez, leche desnatada o leche entera) y en diferentes órdenes (por ejemplo, agregando leche primero y luego azúcar, o viceversa). Este conocimiento previo, específico de la actividad dependiente del dominio, proporciona información valiosa sobre cómo las actividades se pueden construir en general y cómo pueden ser realizadas por personas en situaciones específicas.

Los **modelos dirigidos por datos** se basan en un **aprendizaje automático** o profundo, siendo su objetivo clasificar automáticamente patrones complejos sobre la base de un entrenamiento previo. En este tipo de modelos existe un amplio abanico de clasificadores que

pueden ser utilizados, como el clasificador bayesiano, el modelo oculto de Markov o los árbol de decisión.

Las ventajas de los enfoques basados en datos están en las capacidades de manejo de la incertidumbre y en el manejo temporal de la información. Sin embargo, este modelo requiere grandes conjuntos de datos para el entrenamiento y aprendizaje, por lo que puede sufrir por la escasez de estos o el problema de cold start. También, resulta difícil replicar los modelos de aprendizaje de actividades de una persona a otra. Como tal, este método presenta también problemas de escalabilidad y reutilización.

Dentro de los modelos dirigidos por datos con aprendizaje automático destacan los métodos con **aprendizaje profundo** (deep learning). Este enfoque surge en 2011 a partir del aprendizaje automático, siendo muy parecido al original, cambiando los algoritmos o árboles de regresión por redes neuronales, que funcionan de forma muy parecida a las conexiones neuronales biológicas de nuestro cerebro.

Finalmente, en lo que refiere a los modelos dirigidos por datos, es posible hacer un aprendizaje **supervisado** en el que previamente se hayan etiquetado los datos, o bien un aprendizaje **no supervisado**, donde el mismo sistema los etiqueta a través de diversos algoritmos, basados en grupos o reglas.

3.3.4. Inferencia de la actividad

Un último paso en el procedimiento general para reconocer la actividad se encuentra en el proceso de inferencia o reconocimiento

de la actividad (figura 3.4); una vez se encuentra el modelo preparado para reconocer un conjunto de actividades, el sistema se basa en una entrada de datos de señales de sensores, a fin de proporcionar una salida con el tipo de actividad que el usuario está realizando. Como este modelo está impulsado por datos, el resultado de la inferencia de actividad se basa en cálculos probabilísticos o estadísticos. La clasificación a menudo se conoce como enfoque basado en datos, o de abajo hacia arriba.



FIGURA 3.4: Esquema general para la inferencia de actividades

Capítulo 4

Nueva metodología para la clasificación de cambios posturales con sensores inerciales

En este capítulo se presenta la primera de nuestras propuestas una metodología para el reconocimiento de los cambios posturales con sensores inerciales. Para ello, se presenta, la arquitectura, el modelo de procesamiento, el cual está basado en datos de posturas. Además, se presenta la evaluación de dicha metodología dividida en dos clases: prueba A y prueba B. El capítulo concluye con el análisis de las limitaciones y fortalezas sobre las pruebas realizadas.

4.1. Arquitectura

En esta sección se detalla la propuesta dirigida al desarrollo de una metodología para la prevención de Úlceras por Presión, y el monitoreo de cambios posturales mediante sensores inerciales.

Adicionalmente, se describe la configuración experimental y los resultados obtenidos en el UJAmI Smart Lab, del Centro de Estudios Avanzados en Tecnologías de la Información y las Comunicaciones (CEATIC) de la Universidad de Jaén (España), con el fin de evaluar la metodología propuesta. En el estudio de caso desarrollado, se incluyeron cuatro participantes para la recopilación de datos, una mujer y tres hombres utilizando dos sensores inerciales para detectar siete posiciones: supino, reclinado, lateral izquierdo, lateral derecho, sentado, caminando e inactivo, cada postura tuvo una duración de uno a dos minutos aproximadamente,

■ Dispositivos inerciales

La recolección de datos se realiza usando sensores inerciales, como el acelerómetro, los cuales se envían en tiempo real a la puerta de enlace a través del protocolo Bluetooth de baja energía (BLE). En esta metodología se utilizan dispositivos Android, para describir su orientación de forma no invasiva como se observa en la figura 4.1.

Se utilizaron dos dispositivos Polar M600, ubicados en el hombro y el tobillo de los participantes, y cada uno de ellos repitió el experimento dos veces, obteniendo así dos conjuntos

de datos por usuario. Un observador externo etiquetó la postura en tiempo real durante la recolección de datos y se recopilaron un total de 100 422 muestras.



FIGURA 4.1: Dispositivos Android, ubicados en el hombro y el tobillo

■ Placa Inteligente:

Una mini placa de bajo costo (como Raspberry PI 3, RP3) se configura como puerta para recibir datos de dispositivos portátiles bajo el protocolo BLE. Estos datos se almacenan en una base de datos local en el cual el tiempo y los tres ejes (x-y-z) del acelerómetro se recopilan en formato RAW. El procesamiento de datos es calculado con la placa inteligente para extraer las características de los datos del acelerómetro. Finalmente, las características son evaluadas por un clasificador, determinando la orientación/posición del paciente. En caso de que la orientación supere un umbral de tiempo predefinido, se envía una alerta al móvil de los cuidadores.

En la figura 4.2 se muestra la arquitectura junto con los componentes descritos anteriormente, así como las etapas del procesamiento de datos y de extracción de características para la clasificación de la

posición corporal de los pacientes, todo lo cual será descrito en la siguiente sección.




FIGURA 4.2: Arquitectura de componentes de la metodología para la prevención de úlceras por presión mediante monitorización de cambios posturales usando sensores inerciales

4.2. Modelo de procesamiento

En una definición formal, un sensor D recopila datos en tiempo real en forma de un par $\bar{s}_i = \{s_i, t_i\}$, en el cual s_i representa un valor o medida dado por el sensor y t_i indica el intervalo de tiempo. Por lo tanto, el flujo de datos obtenido por el dispositivo se define por $\overline{S_D} = \{\bar{s}_0, \dots, \bar{s}_i, \dots, \bar{s}_n\}$; en esta metodología, la aceleración está definida en tres ejes (x, y, z), a partir de tres tipos de flujos de datos S_X, S_Y, S_Z para cada sensor inercial y dispositivo portátil. Los datos recopilados se filtran para eliminar el ruido mediante un filtro de redondeo exponencial, que genera una predicción equivalente a un filtro de Kallman con un rendimiento más rápido [71].

$$S'_i = w.s_i + (1 - w).s_i - 1' \quad (4.1)$$

Por otra parte, la segmentación temporal es definida por el tamaño de la ventana L , seleccionando la medida más relevante y reciente $\overline{S_i}$ y aplicándola según [43] [22]. Las medidas relevantes y redondeadas S'_i se agregan usando la función $T_k(S_D, t_*)$, cuyo valor se define por la característica T_k de los sensores inerciales S_D en tiempo actual t_* .

$$T_k(S_D, t_*) = \bigcup_{\substack{\overline{S_i} \\ S_i}} s'_i, t_* - t_i < L, t_* \geq t_i \quad (4.2)$$

De este modo, partiendo de un conjunto de sensores $S = \{S_1, \dots, S_N\}$ y un conjunto de funciones de agregación representadas en la formula $T = \{T_1, \dots, T_M\}$, se definió un número total de características $N \times M$ para describir el sensor en cada punto dado de t_* .

$$T_1(S_1, t_*), \dots, T_j\{S_i, t_*\}, \dots, T_M\{S_N, t_*\} \rightarrow L(t^*), \quad (4.3)$$

Aquí, $L(t^*)$ define un valor discreto $L = \{L_1, \dots, L_l\}$ y L_l identifica una postura.

Esta metodología se enfocó en la clasificación de las siguientes posturas del paciente: supino, reclinado, lateral izquierdo, lateral derecho, sentado, caminando (para aquellos pacientes que tienen movilidad) e inactivo Idle (no etiquetado).

Finalmente, las características y etiquetas definidas previamente se utilizan para entrenar a un clasificador. En esta metodología, se evalúan los siguientes clasificadores: K vecino más próximo, Naïve Bayes, máquinas de vectores de soporte y árbol de decisión, usando

los lenguajes de programación Java y C ++ [43], [22], lo que permite la implementación en placas miniatura o dispositivos móviles.

4.3. Evaluación

En esta sección se presentan los resultados del estudio de caso. El desempeño de los clasificadores (precisión, Recall y F1-Score) se evalúa utilizando la validación cruzada de dejar a un participante fuera en dos configuraciones:

(A) La prueba se determina mediante datos inerciales y etiquetas de un participante dado, y el modelo de entrenamiento se compone solo por datos inerciales y etiquetas que no incluyen la tabla del sujeto objeto de esta investigación (estrictamente, se deja uno fuera, ver tablas 4.1 y 4.2).

(B) La mitad de los datos inerciales del participante se incluyen en el conjunto de entrenamiento para implementar la adaptación/personalización del modelo, lo que se conoce como modelo adaptado (ver tablas 4.3 y 4.4).

A continuación, se presentan las pruebas experimentales con casos reales que permitieron evaluar los enfoques de aprendizaje automático y validar la estimación de la posición a partir de un estudio de caso desarrollado con cuatro participantes.

4.3.1. Entrenamiento usando Leave-One-Out

En esta sección se presentan los resultados de la configuración experimental, sin incluir la personalización del usuario en el

aprendizaje. Es decir, se utilizan como entrenamiento los datos de otros usuarios y se evalúan los datos invisibles del usuario de prueba (cualquier dato para las escenas del caso de este usuario se incluye en el aprendizaje).

Además, se presentan los resultados de dos clases adicionales, caminando e inactivo, aunque no son tan importantes para monitorear las UPP, ya que el tiempo empleado en estas clases no requiere cambios de posición dentro de los protocolos de prevención.

4.3.2. Modelo adaptativo entrenado

En esta sección se detallan los resultados del montaje experimental, incluyendo uno de los dos casos repetidos por el participante en el entrenamiento. De este modo, el aprendizaje incluye la personalización de los datos inerciales y posturas para el usuario de prueba antes de la evaluación. En la tabla 4.1 se muestran los resultados para clasificar siete posturas propuestas. Adicionalmente, a los resultados se adicionan dos clases (caminando e inactivo), como se observa en la tabla 4.2.

Prueba A: Sin personalización

En la tabla 4.1 4.2 se muestran los resultados sin personalización de datos inerciales y etiquetas para clasificar siete posturas, dejando por fuera el participante que se evalúa, agregando las clases caminando e inactivo.

	SVM			NB			C4.5			KNN		
Class	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Inactivo	0.653	0.345	0.451	0.711	0.420	0.528	0.695	0.224	0.339	0.654	0.507	0.571
Supino	0.507	0.657	0.572	0.697	0.724	0.710	0.366	0.351	0.358	0.547	0.485	0.514
Reclinado	0.514	0.581	0.545	0.658	0.657	0.657	0.264	0.434	0.328	0.720	0.656	0.687
Lado Izq	0.608	0.932	0.736	0.644	0.959	0.771	0.183	0.850	0.302	0.652	0.934	0.768
Lado Der	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.891	0.955	0.922
Sentado	0.727	0.883	0.797	0.969	0.945	0.957	0.382	0.602	0.467	0.662	0.864	0.750
Caminando	0.896	0.740	0.810	0.977	0.953	0.965	0.927	0.861	0.893	0.852	0.731	0.787
AVG	0.702	0.791	0.736	0.787	0.866	0.820	0.482	0.675	0.533	0.721	0.771	0.738

TABLA 4.1: Resultados sin personalización para las siete posturas, incluyendo caminando e inactivo, agrupados según cuatro clasificadores: SVM, NB, C4.5, KNN

	SVM			NB			C4.5			KNN		
Class	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Supino	0.847	0.557	0.672	0.883	0.664	0.758	0.873	0.437	0.583	0.456	0.407	0.430
Reclinado	0.507	0.657	0.572	0.697	0.724	0.710	0.366	0.351	0.358	0.471	0.467	0.469
Lado Izq	0.514	0.581	0.545	0.658	0.657	0.657	0.264	0.434	0.328	0.709	0.635	0.670
Lado Der	0.608	0.932	0.736	0.644	0.959	0.771	0.183	0.850	0.302	0.643	0.876	0.741
Sentado	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.803	0.913	0.855
Caminando	0.727	0.883	0.797	0.969	0.945	0.957	0.382	0.602	0.467	0.495	0.760	0.600
AVG	0.694	0.761	0.713	0.772	0.818	0.786	0.473	0.604	0.481	0.596	0.676	0.627

TABLA 4.2: Resultados sin personalización, agregando movimiento (caminar)

Prueba B: Con personalización suave

En las tablas 4.3 se muestran los datos de los participantes que están incluidos en el modelo de entrenamiento con personalización suave para siete posturas, en la cual se evalúa la mitad de las muestras de los datos inerciales del participante para implementar la personalización suave del modelo.

	SVM			NB			C4.5			KNN		
Class	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Inactivo	0.447	0.495	0.470	0.762	0.417	0.539	0.856	0.238	0.372	0.757	0.761	0.759
Supino	0.976	0.903	0.938	0.000	0.000	0.000	0.000	0.000	0.000	0.796	0.961	0.871
Reclinado	1.000	0.883	0.938	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Lado Izq	1.000	0.819	0.900	1.000	0.940	0.969	0.000	0.000	0.000	0.999	0.979	0.989
Lado Der	1.000	0.888	0.940	1.000	0.964	0.982	0.057	0.877	0.107	1.000	0.944	0.971
Sentado	0.973	0.916	0.944	1.000	0.964	0.981	0.000	0.000	0.000	0.982	0.976	0.979
Caminando	0.447	0.495	0.470	0.977	0.955	0.966	0.934	0.969	0.951	0.964	0.886	0.923
AVG	0.899	0.817	0.855	0.829	0.795	0.812	0.184	0.474	0.211	0.957	0.949	0.951

TABLA 4.3: Resultados con personalización para las siete posturas, incluidas caminando e inactivo

Class	SVM			NB			C4.5			KNN		
	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Supino	0.808	0.980	0.886	0.872	0.576	0.694	0.924	0.359	0.517	0.888	0.862	0.875
Reclinado	0.988	0.949	0.968	0.000	0.000	0.000	0.000	0.000	0.0000	0.796	0.961	0.871
Lado Izq	1.000	0.938	0.968	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Lado Der	1.000	0.900	0.948	1.000	0.940	0.969	0.000	0.000	0.000	0.999	0.979	0.989
Sentado	1.000	0.940	0.969	1.000	0.964	0.982	0.057	0.877	0.107	1.000	0.944	0.971
Caminando	0.986	0.956	0.971	1.000	0.964	0.981	0.000	0.000	0.000	0.982	0.976	0.979
AVG	0.964	0.944	0.952	0.812	0.731	0.766	0.183	0.373	0.138	0.944	0.945	0.943

TABLA 4.4: Resultados con personalización
adicionando las clases inactiva y caminando

Class	SVM			NB			C4.5			KNN		
	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Inactivo	0.447	0.495	0.470	0.762	0.417	0.539	0.856	0.238	0.372	0.757	0.761	0.759
Supino	0.808	0.980	0.886	0.872	0.576	0.694	0.924	0.359	0.517	0.888	0.862	0.875
Reclinado	1.000	0.883	0.938	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Lado Izq	1.000	0.938	0.968	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Lado Der	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.891	0.955	0.922
Sentado	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.803	0.913	0.855
Caminando	0.986	0.956	0.971	1.000	0.964	0.981	0.000	0.000	0.000	0.982	0.976	0.979
AVG	0.447	0.495	0.470	0.977	0.955	0.966	0.934	0.969	0.951	0.964	0.886	0.923

TABLA 4.5: Resultados finales con personalización

Prueba B: Con personalización media

En la tabla 4.4, de la misma forma que en la tabla anterior, se tiene en cuenta la mitad de los datos inerciales de los participantes están incluidos en el modelo de entrenamiento. Se muestran los datos de los participantes con personalización, usando datos de los participantes, en la siguiente tabla se adicionaron las otras dos clases: caminando con personalización media del participante.

Prueba B: Con personalización fuerte

En la tabla 4.5 se muestran los resultados finales, según cada caso de los cuatro clasificadores utilizados, incluyendo todos los datos inerciales de participante de las siete posturas adicionando las clases caminar e inactivo.

En la figura 4.3 se pueden observar los tiempos y frecuencias de cada postura. Además, las figuras 4.4 y 4.5 presentan la matriz de confusión de la configuración para el clasificador SVM, incluida la personalización.




FIGURA 4.3: Reloj que indica tiempos de frecuencia sobre el cambio de postura [97]




FIGURA 4.4: Matriz de confusión para el clasificador SVM con personalización. Se definen siete posiciones: (a) inactivo, (b) en decúbito supino, (c) reclinado, (d) izquierda, (e) derecha, (f) sentado y (g) caminando




FIGURA 4.5: Matriz de confusión para el clasificador SVM con personalización. Se definen siete posiciones: (a) inactivo, (b) en decúbito supino, (c) reclinado, (d) izquierda, (e) derecha, (f) sentado y (g) se incluyen caminando e inactivo

Teniendo en cuenta los resultados de la tabla 4.5, se identificaron SVM y KNN como los clasificadores adecuados para inferir la posición del cuerpo del usuario con un F1 más cercano a 0.95. Además, se observó que la mejor clasificación se desarrolla mediante la personalización fuerte, lo que significa que es importante incluir algunos datos de entrenamiento del sujeto que está siendo objeto de la investigación para mejorar el desempeño de la precisión.

Por otra parte, los clasificadores de árbol de decisión se excluyeron de la comparación, ya que pueden resultar enfoques pobres para ser utilizados con sensores inerciales, debido a su limitación para manejar atributos no discretos [12].

Finalmente, la discriminación entre inactivo y caminando disminuye ligeramente el rendimiento. Esta distinción, sin embargo, no es relevante para el caso de prevención de las úlceras por presión; por lo tanto, un conjunto óptimo de actividades objetivo viene a ser el conjunto reducido.

Los resultados sugieren que se debe establecer un plan de cuidados para cada tipo de paciente según el nivel de la herida. Este plan debe desarrollarse en colaboración con los cuidadores en cuanto se complete su evaluación, y se debe actualizar siempre que haya un cambio en el estado médico del paciente o cuando la herida no progrese hacia la cicatrización. En el manejo de lesiones por presión las estrategias también deberían personalizarse, teniendo en cuenta las actitudes, creencias, cultura, necesidades diarias y preferencias personales del paciente.

Además, es fundamental la comunicación del equipo profesional y el paciente para que así este se empodere, ayude en su propia recuperación y se adhiera a su plan de cuidados.

4.4. Fortalezas y limitaciones

En esta investigación se ha presentado una metodología para la prevención de UPP, proponiendo una solución que consistía en dos sensores inerciales ubicados en el tobillo y el hombro, para proporcionar una estimación precisa de la orientación corporal de un paciente.

Los cambios de postura son considerados en ese sentido como el principal mecanismo de prevención, demostrándose que son necesarios y suficientes para evitar la aparición de úlceras por presión. A continuación se presentan algunas de las fortalezas de la implementación en un entorno del mundo real:

- Esta metodología permite proporcionar a los cuidadores un continuo monitoreo en tiempo real de la posición del cuerpo, reduciendo así el esfuerzo necesario gracias al control automático.
- La evaluación de diferentes enfoques de clasificación muestra que SVM y KNN proporcionan mejores resultados en la determinación de la posición del paciente, de acuerdo con los datos recopilados, la alta competencia y el diseño inherente para trabajar con atributos numéricos.
- Se implementa la personalización, incluyendo algunos datos del paciente objeto de estudio. Esto aumenta notoriamente la precisión y el rendimiento de recuperación.
- Se destaca la novedad de este trabajo, basado en la propuesta de uso de sensores inerciales para monitorear a los pacientes a través de una metodología que determina la posición en tiempo real de manera automática.

Las limitaciones de esta metodología se determinan por el uso de sensores comerciales no adecuados con las siguientes desventajas:

- Invasivas, se requiere la utilización de microsensores inerciales no invasivos.
- Los dispositivos tienen una batería de 8 horas, las cuales deben ser recargadas en tiempos muy cortos.
- No se calcula la prioridad de los cambios posturales fundamental para el monitoreo.
- No genera recordatorios en cuanto el grado de prioridad del cambio de postura alcanza un umbral configurable.

En el capítulo 5 se abordará el uso de sensores inerciales adheridos a la ropa, textiles, que describen la orientación de los pacientes y son instalados en zonas corporales de forma no invasiva, con el objeto de usarlos en estudios de caso con pacientes reales para evitar la aparición de úlceras por presión. Además, se incluirán las reglas lingüísticas y la configuración de las alertas según la frecuencia que necesita cada paciente y cada posición. Esta metodología es capaz de prevenir las UPP evaluando el riesgo y la movilidad del paciente, ayudando a que los hospitales sean más eficientes y optimizando el tiempo de las enfermeras y del personal de cuidado.

Capítulo 5

Nueva metodología para la clasificación de cambios posturales en textiles sensorizados

En esta sección se presenta la segunda metodología de esta tesis doctoral para para la clasificación de posturas en cama. Se integra un enfoque basado en lógica difusa para calcular la prioridad de cambios posturales. Así, los principales componentes de esta propuesta refieren a: i) sensores inerciales adheridos a la ropa, que describen la orientación de los pacientes y son instalados en zonas corporales de forma no invasiva; ii) un modelo basado en datos para el reconocimiento de las posturas, que segmenta los datos inerciales y la clasificación de las posiciones; iii) un enfoque basado en lógica difusa, que calcula la prioridad de los cambios posturales para cada

zona corporal de acuerdo con un protocolo definido y con el tiempo transcurrido desde la anterior postura en cama; y iv) un recordatorio para avisar a los cuidadores cuando el grado de prioridad del cambio de postura alcanza un umbral configurable.

5.1. Arquitectura

En la Figura 5.1 se muestra la arquitectura de los componentes descritos para este enfoque, que se detallan a continuación.




FIGURA 5.1: Arquitectura y componentes: i) sensores inerciales adheridos a la ropa, ii) modelo de datos para el reconocimiento de posturas, iii) aplicación del conocimiento difuso para calcular la prioridad de los cambios posturales para las zonas del cuerpo, y iv) configuración de un umbral de tiempo para las notificaciones a los cuidadores

5.1.1. Sensores inerciales adheridos a la ropa:

En esta sección se describen los microsensores inerciales propuestos para detectar posturas, los cuales se adhieren a la ropa de los pacientes de forma no invasiva. Para ello se ha seleccionado el dispositivo descrito en la referencia ¹ [93], por sus especificaciones: ligero (peso

¹Tactigon ONE device <https://www.thetactigon.com/products/>

del dispositivo: 2.5 g, y de la batería: 6.3 g) y pequeño ($5.0 \times 1.67 \times 0.56$ cm). Además, el precio asequible (78 €), así como su característica de SDK abierto, que permite codificar la placa para la configuración completa (frecuencia de muestreo, comunicación, sensores), fueron importantes factores adicionales a tener en cuenta en la selección del dispositivo. Para esta investigación, se adhirieron tres dispositivos Tactigon ONE a la tela exterior de dos calcetines y una camiseta del paciente, para identificar las diferentes posturas adoptadas por este durante un periodo de tiempo específico, como se describe en la figura 5.2. Los datos de aceleración y del giroscopio de las placas se envían a través de Bluetooth Low Energy (BLE), con una frecuencia de 20 muestras por segundo.



FIGURA 5.2: Tactigon ONE: izquierda), sensor inercial integrado en la placa; centro y derecha), Tactigon adherido a los calcetines y la camiseta del paciente, respectivamente.

5.1.2. Modelo basado en datos para el reconocimiento de posturas en cama

En primera instancia, se hizo uso del sensor s , recopilando los datos en tiempo real en forma de un par $\bar{s}_i = \{s_i, t_i\}$, donde s_i representa una medida dada y t_i el tiempo, respectivamente. Por lo tanto, el

flujo de datos del sensor s estuvieron definido por $\overline{S_s} = \{\overline{s_0}, \dots, \overline{s_i}\}$. En esta investigación en específico, se realizó la representación del dispositivo inercial en tres ejes (x, y, z), proporcionando tres flujos de datos $\overline{S_X}, \overline{S_Y}, \overline{S_Z}$, correspondientes a los datos de aceleración y de giroscopio de cada dispositivo inercial. A continuación, se definió la segmentación temporal mediante un tamaño de ventana W [10], con el fin de adicionar las muestras $\overline{s_i}$ por una función determinada $T_t(S_s, t^*)$. Finalmente, el valor de agregación se definió a partir de una característica T_t de los sensores inerciales S_s en un tiempo dado t^* .

$$T_t(S_s, t^*) = \bigcup_{s_i}^{\overline{s_i}} s_i, t^* - t_i > W, t^* \leq t_i \quad (5.1)$$

A partir de un conjunto de sensores $S = \{S_1, \dots, S_s, \dots, S_{|S|}\}$ y un conjunto de funciones de agregación $T = \{T_1, \dots, T_t, \dots, T_{|T|}\}$, se definió un número total de características $|S||T|$, que describen el segmento de datos del sensor W para cada punto de tiempo dado t^* [34]. Dado que el modelo se basó en un enfoque supervisado de los datos, las características que describen los sensores inerciales están asociadas con una etiqueta $L(t^*)$ para cada punto de tiempo t^* :

$$T_1(S_1, t^*), \dots, T_t(S_s, t^*), \dots T_{|T|}(S_{|S|}, t^*) \rightarrow L_l(t^*) \quad (5.2)$$

Aquí, $L_l(t^*)$ define un valor discreto para cada punto de tiempo t^* entre $L = \{L_1, \dots, L_l, \dots, L_{|L|}\}$, que hace referencia a una postura específica para pacientes en cama. En esta investigación se clasificaron seis posturas para la prevención de úlceras por presión:

supino, izquierda, derecha, semi sentado, supino con la pierna derecha doblada y supino con la pierna izquierda doblada, las cuales representan posturas comunes en cama para fines de evaluación, descritas en la figura 5.3 [66].



FIGURA 5.3: Clasificación de posturas de pacientes en cama para la prevención de úlceras por presión (de izquierda a derecha): supino, izquierda, derecha, semi sentado, supino con la pierna derecha doblada y supino con la pierna izquierda doblada

Finalmente, las características y etiquetas previamente definidas se usaron para entrenar los clasificadores basados en datos. Entre el amplio espectro de modelos se estudiaron principalmente los clasificadores ligeros y eficientes, que permitieron la capacitación y la evaluación en microplacas, en tiempo real y en entornos de computación de niebla [56]. Específicamente, en esta investigación se evaluaron tres clasificadores: K vecinos más cercanos, máquina de vectores de soporte y árbol de decisión, los cuales proporcionaron el mejor rendimiento en la clasificación de posturas a partir de sensores inerciales [66].

5.1.3. Método difuso basado en el conocimiento para calcular la prioridad de los cambios posturales

En este apartado se describe en profundidad el método difuso basado en el conocimiento, para calcular la prioridad de los cambios posturales a partir de un protocolo definido por expertos, definido mediante un conjunto de posturas L y cambios posturales en un intervalo de tiempo T .

Como primera medida, se identificaron las posturas de los pacientes en cama L_l , asociadas con una o más zonas del cuerpo

$Z = \{Z_1, \dots, Z_z, \dots, Z_{|Z|}\}$, a partir de la función $\mu_Z : \{Z \times L \rightarrow [0, 1]\}$,

la cual determinó el grado de presión sobre estas zonas entre 0 y 1.

Por ejemplo, para la zona del cuerpo $Z_1 = \text{omoplato}$ y las posturas en cama $L_1 = \text{Supino}$, $L_2 = \text{Semisentado}$, $L_3 = \text{PosicinLateral}$ se definió la siguiente función: $\mu_Z(Z_1, L_1) = 1, \mu_Z(Z_1, L_2) = 0,5, \mu_Z(Z_1, L_3) = 0$; teniendo en cuenta que las posturas se adoptan por un periodo de tiempo específico t^* , y que estas afectan una zona particular del cuerpo, según el grado de presión que se ejerce sobre esta, la representación de la función es la siguiente: $Z_z(t^*) = \bigcup_{L_l}^L Z_z(L_l(t^*))$.

En segundo lugar, se aplicó ventanas temporales difusas (Fuzzy Temporal Windows - FTW) y agregación temporal difusa [61] para calcular el nivel de presión ejercido en una zona específica del cuerpo $Z_z(t^j)$ durante un periodo dado de tiempo, desde las marcas de tiempo anteriores t^j a la hora actual t^* . Los FTW se describieron directamente, de acuerdo con la diferencia entre la hora actual t^* y las marcas de tiempo anteriores t^j , así: $\Delta t^j = t^* - t^j$, mediante la

función $\mu_{T_k(\Delta t^j)}$ [62]. Un FTW T_k dado puede definirse por cuatro valores $TS(T_{K_1}, T_{K_2}, T_{K_3}, T_{K_4})$ que determinan una función trapezoidal [61], como se detalla a continuación:

Representación de ventanas temporales difusas usando funciones de pertenencia trapezoidal

Cada FTW T_k se describe mediante una función trapezoidal basada en el intervalo de tiempo desde un tiempo anterior t^j a la hora actual t^* : $T_k(\Delta t^j)[l_1, l_2, l_3, l_4]$ y un conjunto difuso caracterizado por una función de pertenencia cuya forma corresponde a una función trapezoidal. Las funciones de pertenencia trapezoidal conocidas se definen por un límite inferior l_1 , un límite superior l_4 , un límite de soporte inferior l_2 , y un límite de soporte superior l_3 (referirse a la ecuación (5.3)):

$$TS(x)[l_1, l_2, l_3, l_4] = \begin{cases} 0 & x \leq l_1 \\ (x - l_1) / (l_2 - l_1) & l_1 < x < l_2 \\ 1 & l_2 \leq x \leq l_3 \\ (l_4 - x) / (l_4 - l_3) & l_3 < x < l_4 \\ 0 & l_4 \leq x \end{cases} \quad (5.3)$$

En términos concretos, se propone un FTW que cubre dos intervalos de tiempo T para cambios posturales, y cuya función está definida por: $\mu_{T_k(\Delta t^j)} = TS(0, 0, T, 2T)$.

La posición adicionada se representa por la función $Z_z \cup T_k$, la cual describe la zona del cuerpo Z_z dentro de la ventana temporal T_k . Esta

función se calculó utilizando un promedio ponderado difuso [32], que se detalla a continuación:

Agregación de ventanas temporales difusas

Para una zona corporal determinada Z_z y ventana temporal borrosa T_k , se define la agregación difusa $Z_z \cup T_k$ en un tiempo actual determinado t^* como:

$$Z_z \cap T_k(t^*) = Z_z(t^j) \cap T_k(\Delta t^*), \Delta t^* = t^* - t^j \quad (5.4)$$

$$Z_z \cup T_k(t^*) = \bigcup_{\substack{t^j < t^* \\ \tilde{t}^j}} Z_z \cap T_k(t^*) \quad (5.5)$$

Utilizando la media ponderada [61] como operación para modelar la t-norma y la co-norma, obtenemos:

$$Z_z \cup T_k(t^*) = \frac{1}{\sum_{t^j \in t^j < t^*} T_k(\Delta t^j)} \sum_{\substack{t^j < t^* \\ \tilde{t}^j}} Z_z(t^j) \times T_k(\Delta t^j) \in [0, 1] \quad (5.6)$$

Esto se propone como una representación adecuada para sensores de alta frecuencia de muestreo [61]. La posición temporal se definió como $Z_z \cup T_k(t^*)$, para cada punto de tiempo t^* . En la figura 5.4 se muestra un ejemplo de la posición añadida de las zonas corporales $Z_1 = \text{hombro}$ y $Z_1 = \text{cadera izquierda/derecha}$, dentro del FTW $T_1 = TS(0h, 0h, 2h, 8h)$ por minuto t^* , durante una línea de tiempo de 24 horas, utilizando un protocolo básico de posturas que se cambian en intervalos de dos horas *supino* $\rightarrow$ *lateral derecho* $\rightarrow$ *semisentado* $\rightarrow$ *lateralizquierdo*




FIGURA 5.4: Procesamiento difuso a partir de una secuencia básica de cambios posturales, para calcular el grado de presión de agregación de las zonas del cuerpo: hombro y cadera izquierda / derecha, durante dos intervalos de tiempo T de cambios posturales.

Por último, se aplicó un cuantificador difuso Q_z [112] para proporcionar una representación interpretable de la *prioridad de los cambios posturales para la zona del cuerpo Z_z* , desde el grado de agregación de una zona del cuerpo $Z_z \cup T_k$. Se definió directamente un cuantificador difuso para asociar ambos términos mediante una función que pertenece a $\mu_{Q_q} : [0, 1] \times [0, 1]$, y que debe cumplir los principios de monotonía y agregación cero [77].

Para diseñar el cuantificador difuso directamente, el experto solo

necesita definir dos o más puntos de control. Un punto de control se define por una 2-tupla $\{t^j, Q_*^j\}$, que asocia el grado de agregación de la zona del cuerpo en un punto de tiempo t^j con el grado de prioridad de cambio postural Q_*^j diseñado por el experto [64]. En aras de la simplicidad, los puntos de control fueron definidos por el experto en un punto inicial t_A y un punto final de tiempo t_B , para verificar el cambio postural que afecta a esta zona del cuerpo, como representación del grado de prioridad mínimo y máximo, respectivamente.

Para los valores restantes del grado agregado temporal de una zona del cuerpo $Z_z \cup T_k$, una interpolación lineal de los puntos de control definió la función de pertenencia, para calcular el grado prioritario de cambio postural $[0, 1]$. Se detalla a continuación:

Representación de cuantificadores difusos mediante puntos de control

En primer lugar, calculamos el grado de agregación de la zona del cuerpo $Z_z \cup T_k$ en el punto del tiempo t^j , obteniendo una nueva 2-tupla $Q'^j = \{d^j, r^j\} = \{Z_z \cup T_k(t^j), Q_*^j\}$.

A continuación, una interpolación lineal $L(x, Q'^j)$ de los puntos de control define la función de pertenencia $\mu_{Q_q} = L(\{Z_z \cup T_k(t^j), Q^j\})$, que se define a partir del dominio $Z_z \cup T_k \in [0, 1]$ al rango de grado de prioridad $[0, 1]$

$$L(x) = \begin{cases} 0 & x \leq d^0 \\ r^i + (x - d^i) / (r^i - d^i) & d^i x \leq d^{i+1} \\ 1 & d^N \leq x \end{cases} \quad (5.7)$$

En la figura 5.5 se muestra un ejemplo del cuantificador difuso, definido por dos puntos de control para la zona del cuerpo *cadera-izquierda* y cuyos grados de prioridad se definieron al principio y al final de la postura.




FIGURA 5.5: Cuantificación difusa definida por dos puntos de control: principio y final del cambio de postura, para calcular el grado de prioridad de los mismos para la zona del cuerpo. Además, se muestra el grado de prioridad de los cambios posturales durante un día, que evoluciona según los cambios realizados por los cuidadores.

5.1.4. Umbral configurable de cambios posturales, según las necesidades de los cuidadores

En la sección anterior se describió el enfoque basado en lógica difusa, con el cual se puede calcular el grado de *prioridad de los cambios posturales* de la zona corporal Z_z , a partir de las posturas definidas y clasificadas por los sensores inerciales para pacientes en cama. Estos sensores proporcionan información interpretable y valiosa a los cuidadores, para realizar los cambios posturales de una manera flexible y adecuada.

Además, el grado de prioridad para los cambios posturales se definió en el rango $[0, 1]$, mediante un $\alpha - cut$ en $[0, 1]$, para notificar al cuidador cuando el grado de presión sobre la zona supera el umbral aceptado. Si bien α_z se puede definir para cada zona del cuerpo Z_z , en aras de simplicidad se tomó α para referirse bien sea a alguna o a todas las zonas.

Dada la flexibilidad proporcionada por el enfoque mencionado para calcular el grado de prioridad en los cambios posturales, la formula α puede modificarse con el tiempo para definir un umbral más flexible o estricto y, por lo tanto, aumentar o reducir el tiempo entre cambios posturales, según las limitaciones de tiempo del cuidador o las necesidades del paciente. De esta manera, $\alpha \approx 0$ se asocia con el tiempo mínimo recomendado, cuando el cambio postural afecta la zona del cuerpo, mientras $\alpha \approx 1$ lo hace con el tiempo máximo recomendado.

Se observó entonces que el grado de prioridad para los cambios

posturales está modelado por: i) el cuantificador difuso definido por los expertos, usando puntos de control, razón por la que existe una relación de interpretabilidad entre las alertas obtenidas por α y el cuantificador difuso Q_q modelado; y ii) las ventanas temporales difusas, que definieron una agregación a largo plazo (generalmente en un rango de horas) del grado de presión en una zona del cuerpo. Entonces, si por ejemplo un cambio postural se ha retrasado, el modelo reduce el tiempo hasta el próximo cambio postural (para la misma zona del cuerpo), ya que el umbral α se alcanzó antes.

En la sección sobre modelado de protocolos posturales heterogéneos en cama se detallan varias etiquetas posturales que se han modelado utilizando la metodología descrita.

5.2. Evaluación

En esta sección se describen los resultados de un conjunto de datos y tres protocolos de cambio postural para la prevención de UPP, modelados bajo este enfoque.

5.2.1. Evaluación del reconocimiento de la postura en la cama mediante sensores inerciales conectados a la ropa

En primer lugar, se evaluó el reconocimiento de las posturas en cama mediante sensores inerciales conectados a la ropa de los participantes. El desarrollo experimental de este estudio de investigación tuvo lugar en el Centro de Estudios Avanzados en Tecnología de la Información y de la Comunicación (CEATIC), de la Universidad de Jaén, España.

Los tres dispositivos Tactigon ONE se integraron en los calcetines y la camiseta de los 7 participantes del proyecto de investigación, 3 hombres y 4 mujeres, estudiantes de la Universidad de Jaén, con una edad promedio de 24.75 años, una altura promedio de 1.68 m y un peso promedio de 73 kg. Durante el experimento, dos profesionales de Neurobase (clínica de neuro-rehabilitación) participaron en la recopilación de datos e indicaron a las personas el protocolo de cambio postural para la prevención de las úlceras por presión. Los participantes firmaron voluntariamente el formulario de consentimiento informado, mediante el cual aceptaron compartir sus datos, además de comprender los objetivos, posibles riesgos, procedimientos y beneficios de este tipo de investigación. Los resultados de este estudio se publican únicamente con fines académicos, razón por la cual se han omitido los nombres y datos personales de los participantes.

En este estudio de caso, como ya se dijo, se usaron sensores conectados en la ropa para identificar seis posturas diferentes en cama: supino, izquierda, derecha, semi sentado, supino con la pierna derecha doblada y supino con la pierna izquierda doblada, las cuales se detallan en la figura 5.3. Para fines de evaluación, se reunieron dos conjuntos de datos de acuerdo con las seis posturas en cama para cada participante, registrando aproximadamente 10 minutos por postura y 1 hora por participante.

Para este análisis se recolectaron más de 500 000 muestras de sensores inerciales, mientras que un observador externo etiquetó y cronometró las posturas. El conjunto de datos se encuentra disponible en acceso

abierto en el siguiente enlace ².

Los datos de los dispositivos inerciales se agruparon en segmentos de 2.5 segundos [66] y las funciones de agregación propuestas fueron: valores máximos, mínimos, promedio y desviación estándar [34]. Se hizo uso de tres clasificadores: K-vecino más próximo, árbol de decisión y máquina de vectores de soporte, los cuales también fueron evaluados.

5.2.2. Prueba A – Aprendizaje Personalizado

Se llevaron a cabo dos métodos de evaluación. Primero, una evaluación basada en *aprendizaje personalizado*, donde solo se usó un conjunto de datos por participante para el entrenamiento y pruebas. En este caso se usó un conjunto de datos para el entrenamiento y el otro para las pruebas (se recopilaron dos conjuntos de datos con seis posturas en la cama para cada participante) como se observa en la tabla 5.1 las métricas de precisión (P), Recall (R) y F1-Score (F1) en evaluación de datos con aprendizaje personalizado.

5.2.3. Prueba B – Evaluación basada en participante invisible

El segundo método de evaluación consistió en el análisis de una evaluación basada en participante invisible, para comparar las capacidades de aprendizaje y entrenamiento del modelo, utilizando datos invisibles para cada participante. Se usaron dos conjuntos de datos por participante como datos de prueba, mientras que los otros conjuntos de datos para el resto de los usuarios se usaron como datos

²Conjunto de datos de posturas en la cama para la prevención de úlceras por presión usando sensores inerciales conectados a la ropa <https://bit.ly/38Nm7Sz>

	SVM			kNN			J48		
	F1-sc	P	R	F1	P	R	F1	P	R
S1	1.00	1.00	1.00	1.00	1.00	1.00	0.37	0.33	0.41
S2	1.00	1.00	1.00	1.00	1.00	1.00	0.59	0.66	0.54
S3	1.00	1.00	1.00	1.00	1.00	1.00	0.49	0.63	0.40
S4	1.00	1.00	1.00	1.00	1.00	1.00	0.55	0.66	0.47
S5	1.00	1.00	1.00	1.00	1.00	1.00	0.36	0.33	0.41
S6	1.00	1.00	1.00	1.00	1.00	1.00	0.60	0.66	0.55
S7	1.00	1.00	1.00	1.00	1.00	1.00	0.61	0.52	0.74
Average	1.00	1.00	1.00	1.00	1.00	1.00	0.51	0.54	0.50

TABLA 5.1: Métricas de precisión (P), Recall (R) y F1-Score (F1) en evaluación de datos con aprendizaje personalizado

de entrenamiento. En la tabla 5.2 se muestra las métricas de precisión (P), Recall (R) y F1-Score (F1) con aprendizaje de participante invisible en la evaluación de datos.

	SVM			kNN			J48		
	F1-sc	P	R	F1	P	R	F1	P	R
S1	1.00	1.00	1.00	0.99	1.00	0.99	1.00	1.00	1.00
S2	1.00	1.00	1.00	1.00	1.00	1.00	0.85	1.00	0.75
S3	1.00	1.00	1.00	1.00	1.00	1.00	0.97	1.00	0.94
S4	1.00	1.00	1.00	0.99	0.99	0.99	1.00	1.00	1.00
S5	1.00	1.00	1.00	1.00	1.00	1.00	0.87	0.83	0.93
S6	0.97	1.00	0.94	0.99	1.00	0.99	0.96	1.00	0.93
S7	1.00	1.00	1.00	0.99	1.00	0.99	0.69	0.65	0.74
Average	0.99	1.00	0.99	0.99	0.99	0.99	0.91	0.87	0.90

TABLA 5.2: Métricas de precisión (P), Recall (R) y F1-Score (F1) con aprendizaje de participantes invisibles en la evaluación de datos.

Tanto para el aprendizaje personalizado como para el no personalizado, se realizó una validación cruzada dejando a un participante fuera, obteniendo los resultados descritos en las tablas 5.1 y 5.2. Además, la matriz de confusión para cada evaluación y clasificador se describe en la figura 5.6, 5.7, 5.8,5.9,5.10,5.11.




FIGURA 5.6: Matriz de confusión: SVM-Support Vector Machine con aprendizaje personalizado




FIGURA 5.7: Matriz de confusión: KNN con aprendizaje personalizado




FIGURA 5.8: Matriz de confusión: C4.5 Decision Tree con aprendizaje personalizado




FIGURA 5.9: Matriz de confusión: SVM Support Vector Machine con aprendizaje del participante invisible en la evaluación de datos




FIGURA 5.10: Matriz de confusión: KNN K-vecinos más próximos con aprendizaje del participante invisible en la evaluación de datos




FIGURA 5.11: Matriz de confusión: C4.5 Árbol de decisión con aprendizaje del participante invisible en la evaluación de datos

5.2.4. Modelo basado en conocimiento - Protocolos

Modelado de protocolos posturales heterogéneos en la cama

Posteriormente, se implementaron tres protocolos de cambios posturales heterogéneos bajo el enfoque de lógica difusa propuesto en este trabajo. Se siguió la misma metodología para los protocolos, lo cual se describe a continuación:

- Se definió un conjunto de posturas L y una secuencia de cambios posturales dentro de un intervalo de tiempo T para cada protocolo.
- El conjunto de zonas corporales Z se relacionó con cada postura L_l por un grado de presión.
- FTW, con un tamaño de dos intervalos de tiempo, cubrió una evaluación a largo plazo de los cambios posturales, a fin de calcular la presión de la zona corporal a lo largo del tiempo.
- Se definió un cuantificador difuso Q_z , para determinar el grado de prioridad de interpretación de los cambios posturales para cada zona del cuerpo.
- Se estableció un umbral configurable α , para notificar y recordarle al cuidador el cambio de la postura del paciente de acuerdo con sus necesidades.

Modelo A: protocolo postural básico con intervalos de tiempo de cambio de dos horas

En primer lugar, se definió un protocolo postural básico por cuatro posturas en la cama: decúbito lateral izquierdo, supino, decúbito lateral derecho y semi sentado, que se cambiaron en intervalos de dos horas [33].

Cada postura se asoció con las zonas corporales de los pacientes (hombro, talones, glúteo, cadera izquierda y cadera derecha) por un grado de presión Z_z , junto con las posturas y el ciclo de cambios posturales. Luego, dos puntos de control fueron definidos por el experto, al principio t_A y al final del tiempo t_B , para cambios posturales de dos horas de duración, lo cual determina el grado de prioridad Q_*^j del cambio postural para zonas del cuerpo $\{Q_*^A = 0, Q_*^B = 0,8\}$.

De esta manera, el umbral de notificación para los recordatorios se estableció en $\alpha - cut = 0,8$ para todas las zonas del cuerpo, alertando a los cuidadores cada dos horas si no cambiaban la postura del paciente. En la figura 5.12 se muestra la configuración completa para este protocolo postural y un ejemplo de prioridad de grado de los cambios posturales durante un día.




FIGURA 5.12: Protocolo postural básico para cuatro posturas en la cama en intervalos de dos horas

Modelo B: protocolo postural dinámico con intervalo de tiempo de cambio adaptativo

En segundo lugar, se definió un protocolo dinámico, de forma tal que el tiempo transcurrido para los cambios posturales puede extenderse parcialmente a cuatro horas [87] [49].

En este modelo se usaron las mismas posturas y zonas corporales de la sección anterior, si bien, para facilitar el sueño del cuidador, los cambios posturales en la noche (desde las 00:00 h hasta las 08:00 h) se extendieron a cuatro horas, mientras se mantenían en dos horas

durante el día (desde las 08:00 h hasta las 24:00 h). Para modelar este protocolo adaptativo se definió un tercer punto de control tC , en el punto final de los cambios posturales de cuatro horas, con el grado de prioridad máxima del cambio postural $Q_*^C = 1$, obteniendo $\{Q_*^A = 0, Q_*^B = 0,8, Q_*^C = 1,0\}$, para aplicar durante la noche.

Como forma de simplificar las tareas para los cuidadores, el umbral de notificación configurable de los recordatorios se estableció en $\alpha - cut = 0,8$ durante el día y $\alpha - cut = 1,0$ por la noche, a fin de permitir recordatorios dinámicos del modelo de lógica difusa para cambios posturales entre 2 y 4 horas, respectivamente. Se identificó además que los cuidadores pueden establecer $\alpha - cut \in [0,8, 1]$ para calcular recordatorios progresivamente de 2 a 4 horas.

La configuración de los parámetros de este modelo, junto con un ejemplo de grado de prioridad para los cuatro cambios posturales en la noche, realizado durante dos días, se muestra en la figura 5.13.




FIGURA 5.13: Protocolo dinámico para extender el intervalo de tiempo de cambio de dos horas durante el día a cuatro horas por la noche

Modelo C: protocolo postural para prevenir la presión sobre las zonas lesionadas del cuerpo

En tercer lugar, se presenta un modelo adaptado para prevenir la presión sobre las zonas lesionadas del cuerpo [117]. Entre las UPP, el sacro y los talones fueron los lugares más afectados. Como el uso de sensores inerciales conectados permite determinar la orientación de las zonas del cuerpo, cuando están ubicadas de manera apropiada, es posible el monitoreo particular de las áreas lesionadas. Para mostrar el reconocimiento de la orientación de la zona del cuerpo, en este trabajo se evaluaron las siguientes posturas adicionales en la cama: supino con pierna derecha doblada y supino con pierna izquierda doblada[79].

En este contexto, se describe un escenario en el que el paciente sufre una UPP emergente en el talón derecho. En este caso, la postura supino con pierna derecha doblada por flexión de rodilla evita la presión sobre el área lesionada [25]. Entonces, en este modelo adaptado, la postura clásica *supino* se reemplaza por supino con pierna derecha doblada, para proteger el talón derecho de la presión causada por las posturas descritas en secciones anteriores. Este pequeño cambio permite una reducción del 66 % en la presión promedio por unidad de tiempo en la zona dada, como se detalla en la tabla 5.3.

Para modelar la adaptación de la zona del cuerpo lesionada al protocolo se siguieron tres pasos: como primera medida, los talones izquierdo y derecho se incluyeron por separado en el modelo,

Zona del cuerpo	Modelo A/B	Modelo C
Glúteo	0.38	0.38
Talón Derecho	0.38	0.13
Talón Izquierdo	0.38	0.38
Hombros	0.38	0.38
Cadera Izquierda	0.25	0.25
Cadera Derecha	0.25	0.25

TABLA 5.3: Grado de presión promedio por unidad de tiempo para los modelos A, B y C

asociándose con las posturas en la cama: supino con la pierna derecha doblada, lateral izquierdo, semi sentado y lateral derecho, por un grado de presión Z_z .

En segundo lugar, los puntos de control para el talón izquierdo lesionado se redujeron a $\{Q_*^A = 0, Q_*^B = 0,25, Q_*^C = 0,5\}$, para representar la necesidad de atención especial, determinando la prioridad de cambio de tiempo tA , que indica un cambio postural a las dos horas tB y a las cuatro horas tC para la postura en la cama (semi sentado) que afecta esta zona del cuerpo (talón izquierdo).

En la sección anterior, el valor del umbral de notificación para recordatorios se estableció en $\alpha - cut = 0,8$ durante el día y $\alpha - cut = 1,0$ por la noche para todas las zonas del cuerpo, excepto para el talón izquierdo, cuyo umbral se estableció en $\alpha_{talnderecho} = 0,25$ durante el día y $\alpha_{talnderecho} = 0,5$ por la noche. En la figura 5.14 se describen los parámetros de este modelo. Se detalla el grado decreciente de los puntos de control y el umbral de notificación para el talón izquierdo que proporcionaría a los cuidadores información más interpretable sobre esta zona del cuerpo.




FIGURA 5.14: Protocolo adaptado para prevenir la presión sobre las zonas lesionadas del cuerpo

5.3. Fortalezas y limitaciones de la implementación en un entorno del mundo real

En este apartado se discuten las limitaciones y fortalezas de la metodología propuesta, para implementarla en un entorno real. Las fortalezas identificadas en el monitoreo, en tiempo real, de los cambios posturales para la prevención de UPP, utilizando sensores inerciales

no invasivos se indican a continuación:

- Se utilizaron microsensores inerciales, adheridos a la ropa de los pacientes de forma no invasiva, para detectar las diferentes posturas de cama. El algoritmo realizó un procesamiento ligero y optimizado que pudo integrarse en dispositivos de bajo costo, pues no requirió modelos de aprendizaje profundo. Entre el amplio espectro de modelos, el enfoque se centró en clasificadores ligeros y eficientes, que permitieron la capacitación y evaluación en tiempo real en micro-boards en entornos de computación de niebla.
- La extracción de características mediante ventanas deslizantes fue muy ágil (2.5 segundos). Se ha demostrado que este valor es adecuado para evaluar los datos de la actividad inercial y que el retraso en la respuesta a la estimación de la clasificación es insignificante. El conjunto de características extraídas de los sensores inerciales incluyó valores máximos, mínimos, promedios y desviación estándar. El uso de sensores inerciales en el reconocimiento de actividad demostró ser eficiente y adecuado, permitiendo la identificación y reconocimiento de acciones u objetivos de los usuarios. Por otra parte, el sistema de alerta de notificación a los cuidadores no requiere de una respuesta crítica que sea sensible a los retrasos en el proceso de comunicación de los sensores o en la clasificación de las posiciones. Como tal, un tiempo de respuesta cercano a algunos minutos es más que suficiente y permite trabajar en tiempo real.

- Adicionalmente, el sistema no requiere personalización para obtener un alto rendimiento, aunque la personalización de los datos es sensible a los clasificadores basados en el árbol de decisiones, observándose que es la mejor clasificación obtenida mediante este procedimiento. Por lo tanto, los datos de entrenamiento del paciente son clave para mejorar el rendimiento de precisión en condiciones reales, lo que requeriría una fase más corta para pre-entrenamiento del modelo.

A continuación, se indican las ciertas limitaciones, problemas y desafíos de la investigación, para avanzar en su aplicación en condiciones del mundo real:

- El análisis realizado en este trabajo se recopiló a partir de la observación de siete participantes del proyecto en entornos controlados de la Universidad de Jaén. Los cambios posturales de los pacientes con riesgo de sufrir UPP han sido guiados por expertos en rehabilitación, pero los trabajos futuros sobre pacientes sin movilidad se desarrollarán en condiciones reales y de acuerdo con criterios expertos, para evaluar las posibles diferencias entre los sujetos.
- El sistema inteligente integra una batería que dura 48 horas. Por lo tanto, se requiere el apoyo del personal médico para reemplazar o recargar los dispositivos inerciales cada dos días, evitando así la pérdida de datos.
- Uno de los puntos relevantes para el éxito del proyecto consiste en capacitar al personal médico sobre el uso correcto de los

dispositivos tecnológicos para, de esta manera, garantizar la correcta recopilación de datos y obtener los resultados deseados. En ese sentido, la capacitación del personal y su relación con las nuevas tecnologías y dispositivos pueden ser un factor determinante.

El sistema desarrollado en esta metodología constituye un sistema de soporte de decisiones, con los siguientes beneficios identificables:

- Mejora la eficiencia del personal médico: el sistema de alerta les permite monitorear la postura y los tiempos del paciente en tiempo real.
- Acelera el proceso de toma de decisiones: el dispositivo genera información que permite apoyar el diagnóstico y el tratamiento del paciente a través del proceso de análisis de datos.
- Presenta rápidamente soluciones a problemas: un equipo especializado puede monitorear efectivamente al paciente, porque están obteniendo datos en tiempo real.
- Conveniencia: es un dispositivo simple, fácil de instalar y manejar por el usuario final.
- Mejora la comunicación con la entidad hospitalaria: facilita la comunicación de información relevante al personal médico.
- Reduce costos para tareas que requieren decisiones: el tratamiento de las UPP puede generar altos costos para una institución médica; sin embargo, el uso del dispositivo y el

análisis oportuno de los datos pueden prevenir la aparición de UPP, acortando las estadías en el hospital para el paciente.

- El dispositivo desarrollado no requiere ningún conocimiento técnico para su uso o instalación.

Capítulo 6

Conclusiones y Trabajos Futuros

6.1. Conclusiones y trabajos futuros

En este capítulo cerramos la memoria de tesis con las conclusiones generales obtenidas a partir de las propuestas presentadas. De forma adicional planteamos líneas de investigación para trabajos futuros que podrían realizarse a partir de nuestros resultados. Por último, se muestra un conjunto de actividades científicas generadas a partir de la investigación realizada.

6.1.1. Conclusiones

En esta tesis doctoral hemos abordado el diseño y la evaluación de nuevas metodologías para el reconocimiento de cambios posturales a través de sensores.

En la primera de nuestras propuestas presentamos una metodología para la clasificación de cambios posturales con sensores inerciales, en el cual el sistema detecta la posición de los pacientes con movilidad reducida mientras se encuentran en cama, caminando o inactivo, y proporciona al personal médico y a los cuidadores información útil mediante notificaciones.

Esta metodología está constituida por un registro histórico de la actividad corporal y notificaciones cuando una posición persiste durante un periodo de tiempo prologado, con el fin de monitorear remotamente las posiciones y tiempos de los pacientes, convirtiéndose en una herramienta de soporte para el personal médico.

Los datos de los sensores han sido procesados en tiempo real para calcular las siguientes posturas: supino, reclinado, lateral izquierdo, lateral derecho, sentado, caminando e inactivo. Las características y etiquetas definidas previamente se utilizan para entrenar a un clasificador. En esta metodología, se evalúan los siguientes clasificadores: KNN, NB, SVM y C4.5, usando los lenguajes de programación Java y C ++, lo que permite la implementación en placas miniatura o dispositivos móviles. La evaluación de diferentes enfoques de clasificación muestra que SVM y KNN proporcionan mejores resultados en la determinación de la posición del paciente, de acuerdo con los datos recopilados, la alta competencia y el diseño inherente para trabajar con atributos numéricos.

Así, la principal novedad de esta propuesta ha radicado en el uso de sensores inerciales para monitorear a los pacientes a través

de una metodología que determina la posición en tiempo real de manera automática. Dicha innovación ofrece múltiples ventajas, como proporcionar a los cuidadores un continuo monitoreo en tiempo real de la posición del cuerpo, reduciendo así el esfuerzo necesario gracias al control automático. Además, se implementó la personalización, incluyendo algunos datos del paciente objeto de estudio. Esto aumentó notoriamente la precisión y el rendimiento de recuperación.

La propuesta presentada ha sido validada en el Smart Lab de la Universidad de Jaén, con la finalidad de evaluar la metodología planteada y constatar empíricamente el reconocimiento de posturas con el apoyo de un observador externo, quien etiquetó la postura en tiempo real durante la recolección de datos, para una recopilación total de 100 422 muestras.

En la segunda parte de nuestras propuestas en esta tesis doctoral nos hemos centrado también en el reconocimiento de cambios posturales. En este caso, hemos planteado una metodología para la clasificación de posturas en cama, además de un enfoque basado en lógica difusa para calcular la prioridad de cambios posturales.

Para ello, en esta segunda metodología hemos utilizado sensores inerciales adheridos a la ropa, que describen la orientación de los pacientes y son instalados en zonas corporales de forma no invasiva, además de un modelo basado en datos para el reconocimiento de las posturas, que segmenta los datos inerciales y la clasificación de las posiciones, y, por último, un enfoque basado en lógica difusa, que calcula la prioridad de los cambios posturales para cada zona corporal

de acuerdo con un protocolo definido y con el tiempo transcurrido desde la anterior postura en cama.

Para mostrar el potencial de la metodología propuesta hemos seleccionado el dispositivo Tactigon One, por sus especificaciones en cuanto tamaño, peso, y costo. Para esta investigación se adhieren tres dispositivos a la tela exterior de dos calcetines y una camiseta del paciente, para identificar las diferentes posturas adoptadas por este durante un periodo de tiempo específico. Los datos de aceleración y del giroscopio de las placas se envían a través de Bluetooth Low Energy, con una frecuencia de veinte muestras por segundo.

Las características y etiquetas definidas se usaron para entrenar los clasificadores basados en datos. Principalmente se estudiaron los clasificadores ligeros y eficientes, que permitieron la capacitación y la evaluación en microplacas, en tiempo real y en entornos de computación de niebla. Específicamente, se evaluaron tres clasificadores: KNN, SVM y C4.5, dado el mejor rendimiento proporcionado en la clasificación de posturas a partir de sensores inerciales.

El aporte principal de esta propuesta consiste en la utilización de microsensores inerciales, adheridos a la ropa de los pacientes de forma no invasiva, para detectar las diferentes posturas de cama. Entre sus múltiples ventajas, cabe resaltar que el algoritmo realizó un procesamiento ligero y optimizado que pudo integrarse en dispositivos de bajo costo, pues no requirió modelos de aprendizaje profundo. También, como ya se señaló, el sistema no requiere

personalización para obtener un alto rendimiento, aunque esta se muestra sensible a los clasificadores basados en el árbol de decisiones, obteniéndose de este modo la mejor clasificación.

La segunda de nuestras propuestas ha sido validada a través de una experimentación en el Smart Lab de la Universidad de Jaén, que evidencia su utilidad y beneficios. Además se implementaron tres protocolos de cambios posturales heterogéneos, bajo el enfoque de lógica difusa propuesto en este trabajo, el cual permite notificar al personal médico en tiempo real, siendo flexible y ajustándose a las necesidades de cada paciente.

Finalmente, discutimos los resultados de las evaluaciones realizadas. En primer lugar, se evaluó el reconocimiento de las posturas en cama mediante sensores inerciales conectados a la ropa de los participantes para identificar seis posturas diferentes en cama: supino, izquierda, derecha, semi sentado, supino con la pierna derecha doblada y supino con la pierna izquierda doblada. Durante el experimento, dos profesionales de Neurobase participaron en la recopilación de datos e indicaron a las personas el protocolo de cambio postural para la prevención de las úlceras por presión. Para este análisis se recolectaron más de 500 000 muestras de sensores inerciales.

6.1.2. Trabajos futuros

Dado que el uso de dispositivos inerciales y el reconocimiento de actividades constituyen un área en evolución y de gran utilidad en múltiples sectores, nuestros trabajos futuros se orientan en las siguientes áreas de investigación.

Las metodologías propuestas en esta tesis doctoral han sido validadas en escenarios simulados, principalmente en el Smart Lab de la Universidad de Jaén. Como trabajo futuro, nos planteamos realizar pruebas en pacientes reales con poca movilidad, desarrollando un sistema embebido para la monitorización en tiempo real de cambios posturales integrado al centro médico, para lo cual se realizará una alianza con el Hospital Universitario de Jaén y con el Centro de Rehabilitación Neurobase, quienes nos han apoyado con la verificación de posturas y tiempos en las pruebas validadas en el laboratorio. Las pruebas estaban programadas para el año 2021, pero debido a la actual crisis sanitaria estas se han visto afectadas.

Además, uno de los retos de nuestra propuesta es la transferencia tecnológica a Colombia, con el objetivo de poder realizar un pilotaje. Para ello se realizaron visitas a diferentes centros médicos, a fin de identificar necesidades específicas, obteniendo como resultado que las metodologías desarrolladas en esta tesis doctoral podrían resultar de significativo apoyo a esta problemática en el país. La idea entonces en este sentido es gestionar una financiación del gobierno colombiano, a través de convocatorias nacionales, que nos permitan realizar dicho pilotaje, con el apoyo de los investigadores del Grupo de Investigación ASIA de la Universidad de Jaén.

6.2. Publicaciones relacionadas con la tesis doctoral

Para finalizar esta memoria de investigación, presentamos la serie de publicaciones realizadas durante la elaboración de esta memoria tesis

6.2.1. En revistas internacionales

*Fuzzy Monitoring of In-bed Postural Changes for the Prevention of
Pressure Ulcers using Inertial Sensors Attached to Clothing*

Revista: Journal of Biomedical Informatics

Año: 2020

Volumen: 107

Página: 103476

DOI: <https://doi.org/10.1016/j.jbi.2020.103476>

Autores: Edna Berna Monroy, Aurora Polo Rodríguez, Macarena
Espinilla, Javier Medina Quero

Índice de impacto (ISI): 6.317

Cuartil (SCImago): Q1

6.2.2. En congresos internacionales de alta relevancia.

UJA Human Activity Recognition multi-occupancy dataset

Nombre del congreso: Hawaii International Conference on System
Sciences 2021

Clave: Publicación considerada muy relevante

Editorial: Hamilton Library - University of Hawaii

Tipo de evento: Comunicación en congreso

Ámbito: Internacional

Año: 04/01/2021 - 08/01/2021

Lugar: Hawaii, Estados Unidos

Autores: Macarena Espinilla, Emiro De-La-Hoz-Franco, Edna Bernal,
Paola Ariza-Colpas, Fabio Mendoza-Palechor

Volumen: HCISS - 2021

Páginas: 1938 - 1947

ISBN: 978-0-9981331-4-0

DOI: <https://www.doi.org/10.24251/HICSS.2021.236>

Clase: 1

Rating: (A+Q2)

En congresos internacionales

*Intelligent system for the prevention of pressure ulcers by monitoring
postural changes with wearable inertial sensors*

Nombre del congreso: 13th International Conference on Ubiquitous
Computing and Ambient Intelligence

Tipo de evento: Comunicación en Congreso

Ámbito: Internacional

Año: 02/12/2019 - 05/12/2019

Lugar: Toledo

Autores: Edna Bernal, Macarena Espinilla Estévez, Ian Cleanland,
Federico Cruciano, Chris Nugent y Javier Medina Quero

Volumen: 31

Número: 81

Páginas: 79

DOI: <https://doi.org/10.3390/proceedings2019031079>

**Sistema inteligente de monitoreo remoto aplicado en la prevención de
úlceras por presión**

Nombre del congreso: III Congreso Nacional de Prevención y Cuidado de Lesiones de Piel y el XII Congreso Ibero-Latinoamericano de la Sociedad Ibero-Latinoamericana sobre Úlceras y Heridas (Silauhe)

Tipo de evento: Póster en Congreso

Ámbito: Internacional

Año: 25/09/2019 - 27/09/2019

Lugar: Cartagena - Colombia

Autores: Edna Rocío Bernal Monroy, Alba Lucia Torres Hinestroza, Javier Medina Quero, Ángel Martínez Nogueras, Macarena Espinilla

Página Web: <https://www.colegioenfermeriahuesca.org/>

Intelligent system for the monitoring of pressure ulcers (PU)

Nombre del congreso: The European Pressure Ulcer Advisory Panel and Société Française de l'Escarre Joint Annual Meeting 2019 Lyon

Tipo de evento: Póster en Congreso

Ámbito: Internacional

Año: 18/09/2019 - 20/09/2019

Lugar: Lyon - Francia

Autores: Edna Rocío Bernal Monroy, Macarena Espinilla
Javier Medina Quero

Página Web: <https://epuap2019.org/>

La tecnología al servicio de las personas para la solución de problemas de contexto desde la universidad – caso de aplicación salud IoT

Nombre del congreso: Retos en la formación de ingenieros en la era digital, el Encuentro Internacional de Educación en Ingeniería ACOFI 2019 (EIEI ACOFI 2019)

Tipo de evento: Póster y Comunicación en Congreso

Ámbito: Internacional

Año: 10/09/2019 - 13/09/2019

Lugar: Cartagena Colombia

Autores: Edna Rocío Bernal Monroy

Página Web: <http://www.acofi.edu.co/>

Diseño de modelo de monitoreo clínico – tecnológico para la prevención de úlceras por presión

Nombre del congreso: I International Worksho2019, 28 Foro Internacional de la OES, 4 Foro Regional Latinoamericano ISQua

Tipo de evento: Póster en Congreso

Ámbito: Internacional

Año: 29/05/2019 - 31/05/2019

Lugar: Cartagena - Colombia

Autores: Bernal Edna Rocío; Moranti Gigliola; Rodríguez Steve; Espinilla Macarena; Medina Javier.

Página Web: <https://foro2019.oes.org.co/>

Monitoreo a través de las TIC para prevenir la formación de úlceras corporales por presión

Nombre del congreso: III Encuentro Internacional de E-Research y V Encuentro Interzonal de Investigación

Tipo de evento: Comunicación

Ámbito: Nacional

Año: 6/09/2018 - 8/09/2018

Lugar: Bogotá D.C

Autores: Edna Bernal, Macarena Espinilla, Javier Medina,
Sixto Campaña

Página Web: <https://noticias.unad.edu.co/>

IoT y Ambientes Inteligentes – Aplicación a pacientes diabéticos e
hipertensos en modalidad domiciliaria

Nombre del congreso: Red de Computación para el desarrollo
COMPDES 2018

Tipo de evento: Comunicado

Ámbito: Internacional

Año: 25/07/2018 - 27/07/2018

Lugar: San Carlos - Costa Rica

Autores: Edna Bernal, Macarena Espinilla, Javier Medina,
Sixto Campaña, Carlos Gómez

Página Web: <http://www.compdes.org/compdes2018/about>

Modelo IoT para monitoreo remoto de pacientes diabéticos e
hipertensos

Nombre del congreso: EXPOTECH 2018 y III Encuentro de Ciencias
Básicas

Tipo de evento: Ponencia

Ámbito: Nacional

Año: 7/06/2018 - 9/06/2018

Lugar: Medellín - Colombia

Autores: Bernal M, Edna Rocío, Campaña B, Sixto Enrique, Espinilla E, Macarena, Medina Javier

Página Web: <https://eventos.unad.edu.co/expotech-2018>

6.2.3. Seminarios y conferencias impartidos

IoT devices and monitoring through Machine Learning applied in health

Nombre del congreso: Salud Digital

Tipo de evento: Curso corto

Ámbito: Internacional

Año: 26/10/2020 - 04/12/2020

Lugar: México D.C

Autores: Edna Bernal Monroy

Página Web: <https://www.cedia.edu.ec/es/>

Experiences in the development of IoT devices and monitoring through Machine Learning applied in Telemedicine

Nombre del congreso: Congreso Virtual de Telemedicina - Argentina

Tipo de evento: Conferencia

Ámbito: Internacional

Año: 6/08/2020 - 7/08/2020

Lugar: Buenos Aires - Argentina

Autores: Edna Bernal Monroy

Página Web: <https://www.risadsaluddigital.org/>

IoT devices applied in health, case applied in Preeclampsia and Pressure Ulcers (UPP)

Nombre del congreso: I International Workshop On Sciences and

Engineering 2019, Cali Colombia

Tipo de evento: Conferencia

Ámbito: Internacional

Año: 12/04/2019 - 13/04/2019

Lugar: Cali - Colombia

Autores: Edna Bernal Monroy

Página Web: <https://www.cecep.edu.co/>

Experiencia Proyecto REMIND 2020

Nombre del congreso: Congreso de telemedicina y Telesalud en Jaén

Tipo de evento: Conferencia

Ámbito: Internacional

Año: 2/06/2017

Lugar: Jaén - España

Autores: Edna Bernal Monroy

Página Web:

<https://estudios.unad.edu.co/III-congreso-telesalud-telemedicina>

6.2.4. Estancias de investigación

Estancias de movilidad: Firenze University

Entidad financiadora: Programa H2020 - Marie Skłodowska-Curie
actions - RISE - REMIND

Fecha inicio: 09/09/2019

Fecha fin: 10/11/2019

Lugar: Florencia - Italia

Temas: Ambientes Inteligentes, Dispositivos Inerciales, Sensores

Estancias de movilidad: Universidad Halmstad

**Entidad financiadora: Programa H2020 - Marie Skłodowska-Curie
actions - RISE - REMIND**

Fecha inicio: 21/06/2018

Fecha fin: 19/08/2018

Lugar: Center for Applied Intelligent Systems Research (CAISR)
Halmstad - Suecia

Temas: Ambientes Inteligentes, Dispositivos Inerciales, Sensores,
Computación Ubicua

Lista de Abreviaciones

UPP	Úlceras por Presión
GNEAUPP	Grupo Nacional para el Estudio y el Asesoramiento en UPP
IoT	Internet of Things
CNN	Redes Neuronales Convolucionales
KNN	Kvecinos más Cercanos
LSH	Local Sensitive Hashing
SVM	Support Vector Machine
RF	Random Forest
IoMT	Internet of Medical Things
RFID	Identificación de Radiofrecuencia
BLE	Bluetooth Low Energy
RP3	Raspberry PI3
NB	Naïve Bbayes
C4.5	Árbol de Decisión
FTW	Fuzzy Temporal Windows
CEATIC	Centro de Estudios Avanzados en TIC
AR	Reconocimiento de Actividad

Apéndice A

English Summary

This appendix contains an English summary of the thesis entitled: New methodologies for intelligent environments with fuzzy techniques as partial fulfilment for obtaining the International Ph.D.

First of all, the motivation for carrying out this research and the proposed objectives are outlined. Secondly, it is highlighted the structure of the whole thesis. After that, the proposals and results derived from the research are described. The appendix finalises with concluding remarks, future work and the publications related to this research

A.1. Introduction

The purpose of this doctoral thesis report is to generate a solution to improve the living conditions of the population with reduced mobility, which presents pathologies of pressure ulcers, based on the advances in technology in fields such as wearable smart devices

with inertial sensors and artificial intelligence techniques. For this, the development of methodologies for the recognition of postural changes is proposed, using inertial wearable sensors that support the monitoring and caring for these patients, so that they can become a resource or tool for support and follow-up by the medical team. as well as for caregivers and family members.

The research project, in which this report is framed, is entitled "Intelligent system for the prevention of pressure ulcers based on non-invasive wearable devices", evaluated in the Health Announcement of the Andalusian Health Service of the Junta de Andalucía, and funded by the Andalusian Public Foundation for Biosanitary Research of Eastern Andalusia (FIBAO, in its acronym in Spanish) in 2018, with code *PI* – 0387 – 2018.

A.1.1. Motivation

At first, the problem of pressure ulcers did not attract the attention of medical systems, but due to the high costs that these represent for the system, due to the days of hospitalization of each patient, it has become a field of opportunity for research [70].

This cost is focused on the expenditure of resources, and the economic value includes the total amount of patient care. This means taking into account direct costs, that is healthcare resources, both medical and non-medical; indirect costs related to the fact of suffering from UPPs; and intangibles linked to the patient's quality of life, that affect his family and/or her caregiver. At present, there are not many studies that measure the economic impact of the UPPs; the existing ones

mostly relate the cost of pressure injuries to a specific treatment, a product or a specific preventive care [30].

The costs of care rise when technological devices have to be used to remedy PUs, in addition to the fact that the cost of treatment increases with the severity of the ulcer, because it increases the healing time and the incidence of complications, implying in some cases additional surgical interventions, as well as an increase in hospitalization days and care times, among others, [90]. These costs could be lower, if preventive measures and organized and structured institutional programs are proposed that aim to prevent the appearance of PUs in patients at risk of suffering them [88], as well as mitigating legal aspects and lawsuits [91]. On the other hand, it is important to analyze the world prevalence of pathologies in patients with reduced mobility, for which some relevant statistics are mentioned below.

In Spain, the prevalence of PU remains stable between 7 % and 8 %, in hospitals; It has increased to a range of 7.9 % to 9.1 % among people linked to home care programs, and 2 % in social and health centers (CSS). Most of the lesions, 65 %, are of nosocomial origin, that is, they occur during the patients' stay in the hospital. Regarding the profile of patients with PU, the female sex predominates, except in hospitals, where they are more frequent in males aged over 72 years [73].

Regarding the European context, in Germany, the general prevalence rate of diseases associated with pressure ulcers in hospitals was estimated at 10.2 % [49]. Another study carried out in Belgium, Portugal, Italy, the United Kingdom, and Sweden calculated the

prevalence of this type of disease at 18.1 % [97]. In the Netherlands, the estimated mean prevalence was 23.1 % [16].

In the United States [28] this situation was calculated in a surgical intensive care unit, where 10.6 % of the patients presented diseases with the presence of PUs due to maintaining the same position for a long time. In Canada, a systematic review on this condition established a general prevalence of 26 % [104], while in Mexico [38] a prevalence of 1.5 % was established, in a cardiological institution, for diseases associated with lack of movement; In Brazil, a study determined the incidence of this type of disease in a hospital institution in São Paulo with a result of 23.1 % prevalence [84].

In Colombia, according to a study carried out by the Faculty of Medicine of the National University of Colombia, PUs occur mostly at the hospitalization site, with 54 %, while 33 % occur at home and 13 % originate in the place where the patient was referred. Position changes, as a preventive measure for PUs, are carried out in 95 % of cases: 61 % are carried out every 120 minutes and 12 % every 180 minutes [40].

Concerning age, there is a higher prevalence of these alterations in older people; 51 % of these people have diseases associated with movement and have pressure ulcers; the age range of people with this type of disorder is between 62 and 80 years of age [42]. The reported prevalence data are high in most of the countries mentioned, despite the importance of this problem and its approach it is not a priority in the health systems.

However, in Spain the problem of pressure ulcers has increased

compared to previous years, and has even doubled; For this reason, it has been described as a “lively and alarming epidemic that lives under the sheets of patients at different levels of care” and has shown important shortcomings in its prevention [74]. Hence, many care guides appropriately place changes in posture as the main prevention mechanism [82], and it has been shown that “preventive care is necessary and sufficient to avoid the appearance of pressure ulcers” [21]. These cares have been described in a protocol way in the field of nursing, for diagnosis, treatment, and rehabilitation with the use of taxonomies [39].

Despite the seriousness of the problem, there are few works based on technology that allows improving care and postural changes to prevent pressure ulcers. The most important work in this field in Spanish: in [109] a specific computer application for PU management is presented that allows the assessment of the risk of suffering from these ulcers and a screening of the nutritional status of patients, to favor the exchange of data between professionals and healthcare levels. A little more prolific have been the patents filed in this regard. It stands out as an innovative proposal that of [50] (1985), who devised the first proposal on remote databases. In [18] the design of a device is presented without specifying the sensors or the control mechanism and the pressure measurement is made and not the time or orientation. In [46] a recent patent was filed that assesses whether “a patient’s movement is correct”, but does not describe their caregivers or the alert system based on the time and duration of a posture.

Regarding the prevention of PUs, there are plenty of opportunities

to implement different technologies for the support, monitoring, and follow-up of patients with reduced mobility. Changes in posture are an essential component in the prevention and treatment of PUs. Therefore, the methodologies proposed in this research focus on the recognition of postural changes through sensors, which become a real-time monitoring tool, which allows avoiding the appearance and complication of PUs.

As previously indicated, this research proposal has made use of devices with inertial sensors; for the case of this study, the accelerometer and gyroscope have been used. Taking into account that an important factor is the recognition of the daily activity of patients, the accelerometer has become the most widely used sensor, due to the data it provides when generating a signal when there is movement or absence thereof, and for identifying the orientation to gravity [19]. Similarly, the gyroscope measures the angular velocity of an object and allows the analysis of human movement, identifying the transitions of postures or falls [23].

Taking into account the previous prevalence indicators and the importance of postural changes, this doctoral thesis is considered an innovative and highly useful technological proposal due to the following key points:

- **Intelligent environments** defined as physical spaces in which information and communication technologies are ubiquitously combined to achieve specific objectives for the user, the environment, or both. [63].

- **Identification of wearable technologies with inertial sensors.**

These solutions are studied within modern information paradigms such as ubiquitous computing (Ubiquitous Computing) [103] and ambient intelligence (Ambient Intelligence) [114], where increasingly intelligent, integrated technologies are developed in the environment, which are sensitive and responsive to the needs of people in an interactive and contextualized way. These paradigms include other definitions, so that smart objects, made up of actuators, sensors, and displays, communicate with each other Internet of Things (IoT) [35], creating a cooperation network that configures an intelligent environment (Smart Environments) [17].

Specifically, wearable technologies, with inertial sensors, have been pointed out as a solution with multiple advantages: i) reduced size, since this type of technology is stick to the user, attached to his body as if it were a part of it, that is, you can wear it; ii) it allows grouping different sensors in the same device, as in our case study, where we use accelerometer and gyroscope, which automatically and non-invasively detect the posture and length of stay of the patient; iii) treatment can be customized according to the needs of each patient. In addition, these technologies are useful for collecting new data and vital signs during daily physical activity [18], standing out in the health area, as they allow monitoring or describing the needs of patients in a constant and minimally invasive way [54].

- **Activity recognition** are solutions that can detect the physical

activity that people have in different environments [107], based on the processing of information received from different sensors, either using wearable technology, including sensors in objects of common use or the same environment [13].

Activity recognition approaches are classified into data-driven environments, knowledge-based environments, and hybrid environments. For this doctoral thesis report, we will use data-based approaches and knowledge-based approaches for the recognition of positions.

- **Recognition of postural changes** In this thesis report, two methodologies are proposed for the recognition of postural changes: from sensors worn by the patient or through sensors attached to clothing, which allow real-time monitoring.

The proposed methodologies presented will have an important impact on the following dimensions: first, designing protocols and sending notifications adapted to each patient, allowing greater flexibility; secondly, to provide a support tool that allows nursing staff or family members to carry out continuous monitoring through the use of sensors; finally, the burden on caregivers has reduced thanks to automatic sensor-based control.

A.2. Ph.D. thesis proposal

Based on the motivation and considerations set out above, this doctoral thesis proposal is based on the design and evaluation of methodologies for the recognition of postural changes, based on the

data obtained by wearable devices with sensors, which are processed through artificial intelligence techniques.

A.3. Specific objectives

To carry out this research, the following specific objectives are proposed:

- To Identify the monitoring needs and problems of patients with pressure ulcers, by reviewing the state of the art, taking into account the implementation of wearable devices with inertial sensors.
- To Carry out a state of the art on sensors, in the context of the application, as support tools in the monitoring and care of patients at risk of suffering from PU.
- To Propose and evaluate methodologies for the recognition of postural changes. The first methodology with sensors attached to the human body, and the second with sensors attached to the patient's clothes.

A.4. Structure

To achieve the objectives set out in this doctoral thesis report, this document is structured as follows:

- **Chapter 1.** This chapter presents the introduction, motivation, and proposal, as well as the specific objectives established during the investigation.

- **Chapter 2.** This chapter presents the state of the art concerning the subject of pressure ulcers. In the first place, reference is made to the most relevant data that highlight the great challenge for the society that occupies the PU. Secondly, relevant projects are presented in the context of UPPs, mobile applications for monitoring, prevention, and training of medical personnel in protocols and postural changes, the main support tools for treatment, and, finally, methodologies regarding artificial intelligence approaches to PU.
- **Chapter 3.** In this chapter, inertial devices, and wearable devices are presented, which will be used to propose methodologies for posture recognition. In addition, the classical methodology for the recognition of activity is described, which is the basis of the proposals presented in this doctoral thesis.
- **Chapter 4.** This chapter proposes a methodology for the recognition of postural changes with inertial sensors; The methodology, the architecture, the processing model (based on data - postures), and the evaluation are presented, divided into two classes: test A (without the customization) and test B (with customization). The chapter concludes with an analysis of the limitations and strengths of the tests carried out.
- **Chapter 5.** Continuing with what was stated in the previous chapter, the methodology for the recognition of postural changes in sensorized textiles is presented. First, the methodology with inertial sensors attached to clothing is discussed;

second, architecture; In a third moment, the processing model is presented, which is divided into two subtopics: i) a data-based model for the recognition of positions in bed, and ii) a knowledge-based model (protocols) according to the particularities of the patient. Finally, the evaluation is presented, which is divided into two classes: i) test A (without personalization); ii) Test B (with customization). The chapter concludes with the limitations and strengths of the methodology in a real environment.

- **Chapter 6** In this chapter the conclusions obtained in this doctoral thesis research are exposed, together with the delimitation of the research projects planned for the future.
- **Annex A.** This annex presents the summary of the thesis report in English to comply with the international mention of the thesis. Likewise, the motivation, the proposed objectives, and the structure are exposed. Also, the proposed methodologies and the results obtained are described. Finally, the conclusions of the research are presented and reference is made to future works that could be the starting point for future investigations.

A.5. Research proposals

A.5.1. New methodology for postural change classification with inertial sensors



Intelligent System for the Prevention of Pressure Ulcers by Monitoring Postural Changes with Wearable Inertial Sensors [†]

Edna Bernal Monroy ^{1,*}, Daniel Zafra Romero ², Macarena Espinilla Estévez ², Federico Cruciani ³, Ian Cleland ³, Chris Nugent ³ and Javier Medina-Quero ²

¹ Universidad Nacional Abierta y a Distancia CI, 14 Sur 23, 111931 Bogotá, Colombia

² Department of Electronic Engineering, Campus Las Lagunillas, 23071 Jaén, Spain; dzafra@ujaen.es (D.Z.R.); mestevéz@ujaen.es (M.E.E.); jmquero@ujaen.es (J.M.-Q.)

³ School of Computing, Ulster University, Newtownabbey BT37 0QB, UK; f.cruciani@ulster.ac.uk (F.C.); i.cleland@ulster.ac.uk (I.C.); cd.nugent@ulster.ac.uk (C.N.)

* Correspondence: edna.bernal@unad.edu.co; Tel.: +57-3125173298

[†] Presented at the 13th International Conference on Ubiquitous Computing and Ambient Intelligence UCAmI 2019, Toledo, Spain, 2–5 December 2019.

Published: 21 November 2019

Abstract: Pressure ulcers affect the quality of life and health level of patients while causing a cost increase for the health system. Despite all of this, there is no monitoring system for this disease, even though it is very common in hospitalized patients. To resolve this issue, in this work, we present a prototype for monitoring and caring of pressure ulcers, through an intelligent system based on wearable inertial devices. The system detects the position of patients with reduced mobility while in bed, walking, or standing; providing, to medical staff and caregivers, useful information by means of mobile devices, in particular: (i) A historical record of body activity and (ii) notifications when a single position persists for a prolonged period of time. The following contributions are presented in this paper. Firstly, a technological survey of healthcare systems applied to pressure ulcers is presented. Secondly, an architecture and a methodology for modelling wearable inertial sensors for classifying body position are proposed. Finally, experimental tests with real cases were conducted to evaluate machine learning approaches and to validate the position estimation of the case study developed with four participants.

Keywords: body monitoring; elder care; wearables; sensor; pressure ulcers

1. Introduction

Pressure Ulcers (PUs) as a medical condition are defined as localized lesions on the skin or underlying dermic tissue, usually over a bone prominence, as a result of pressure [1]. PUs affect the health level and life quality of patients, reducing their independence for self-care, causing low self-esteem, affecting negatively upon their families and caregivers, and even causing death in extreme cases [1]. Body position and postural changes are the main preventive mechanism [2], and it has been shown that “preventive care is necessary and sufficient to prevent the onset of pressure ulcers” [3]. Therefore, the conventional way of preventing and controlling PUs nowadays is to avoid maintaining a sole body position for a long period of time. Generally, persistence in the same position must not exceed two hours [3]. Patients, where possible, need to change the position by themselves or with the support of an assistant. Handling these changes of postures; however, could result in excessive physical and emotional stress for the caregivers [4].

In this work, an intelligent system to monitor body position of patients using wearable inertial sensors is presented as a tool to support this assistance. Inertial wearable devices are located on a

patient's shoulder and ankle to monitor their posture in an automatic way. Acceleration data from these inertial sensors are then aggregated and evaluated by machine learning approaches to determine the patients posture behavior in real-time.

1.1. Motivation

The problem of PUs has increased over the years and has been described as a “living and alarming epidemic that lives under the sheets of patients at different levels of care”. Consequently, it has been identified as a critical shortcoming in patients' care [5]. Table 1 shows the prevalence of PU patients around the world. For adults over 60 years, there is a higher prevalence of PUs (51%) [6]. PUs also can appear in patients with limited movement, such as amyotrophic lateral sclerosis and paraplegias cases. For PUs, care treatments need to be customized and planned individually for each patient [7]. For PU lesion treatment, the intervention methods involve electrical or ultrasounds applied directly to the lesions, making the process painful for patients and expensive for the health system. Studies on the cost analysis of PUs were conducted by Palfreyman and Stone [7]. This systematic review was carried out on the economic impact of this intervention for PUs, concluding that: (i) The cost of treatment increases with the severity of the ulcer because of the longer healing/recovery time; and (ii) this cost is composed by expenses in materials inputs, nursing time, and hospitalization charges for the health system, resulting in a significant impact of PUs into the national care system and governmental budget; therefore, prevention is the best strategy to address this public health problem.

Table 1. Prevalence of pressure ulcers (PUs) in patients in the world.

Country	Prevalence of Pus	Source
United States	10.6%	[8]
Canada	26%	[9]
México	1.5%	[10]
Brazil	23.1%	[11]
Germany	10.2%	[12]
Belgium, Portugal, Italy, United Kingdom, and Sweden	18.1%	[12]
The Netherlands	23.1%	[13]
Spain	7.2%	[14]
Colombia (Bogotá, Bucaramanga, Cartagena)	18%, 5.27%, 24%, respectively	[15]

Currently, despite the seriousness of the problem, there is a lack of technology-based work to improve the care and monitor postural changes to prevent PUs. Some of most relevant advancements in this sense, for example, have been developed in Spain [16] as an ad-hoc computer application for PU management. This system allows for risk assessment of patient's suffering from PUs and to make a screening of the nutritional status of the patient, favoring the exchange of data between professionals and levels of care to support decision making. Additionally, a wider range of solutions have been looking for a patent in this regard. The first developments were in 1995 when the authors of [17] generated a primitive idea based on remote databases. In [18], the design of a device was presented without specifying neither the type of sensors, nor the control mechanism. Instead the approach simply aimed at measuring the “pressure”, rather than the time lapse or body orientation. In [19], a recent patent has been submitted that assesses whether “the movement of a patient is correct”, but without providing an alert system based on the time spent in the same position. Taking into account all related work described, this research is targeting the development of technology, coupled with intelligent systems, with the perspective of ensuring improved treatment for the population that presents this pathology.

1.2. Related Works about Technologies for Pressure Ulcers (PUs)

In recent years, academic and industrial research initiatives have been developed on smart systems for healthcare, with the scope of supporting future healthcare demands for the elderly population, improving the quality of life, reducing healthcare costs, and complementing specific medical delivery services [20].

Table 2 shows four kinds of technologies proposed between 2012 and 2018, which have been published in international journals, and presents support tools for the monitoring and treatment of PUs.

Firstly, it shows information systems for monitoring patients who are in bed and hospitalized. Secondly, the usual support tools for the treatment of PUs are surfaces such as mattresses, cushions, heel pads, mittens, and others. Mobile applications in relation to prevention, management, risk, and PU monitoring are also described. Finally, there is an overview about applications and tools used for training of medical personnel.

Table 2. Summary of the technological projects for the follow-up and treatment of PUs.

	Title	Authors	Type and Number of Sensors	The Data Processing Techniques	Population and Sample
Systems Information for Monitoring PUs	Electronic-assisted system for the rehabilitation of pressure ulcers [21].	Hugo Daniel Aguagüña Pilataxi—Cesar Granizo	Pressure sensors and accelerometer, piezoelectric sensor, optical sensor (camera) video graphics array pixel complementary metal oxide Semiconductor	Main processing card, a webcam, 7" liquid cristal display digital image processing, artificial vision.	Population and sample will not be required.
	Measurement of the area of venous ulcers by means of two types of software [22].	Thais Dresch Eberhardt ² Suzinara Beatriz Soares de Lima ³ Luis Felipe Dias Lopes ⁴ Eline de Lima Borges ⁵	Does not use sensors.	To use software Autocad e Image Tool.	The data were collected from 21 patients with venous ulcers.
	Systems information for management PUs [23].	Olga Bueno Yáñez, Jimena Rodríguez Arrieta ^b , Miren I. Bagüés Bafaluy ^b y Juan José Calvo Aguirrec	Does not use sensors.	Computer application.	The sample is made up of people over 65 with a total of 69 people.
Support Tools for PU Treatment	Clock as position tool: revolving clock for help in the prevention of ulcers [24].	Ortopedia Moverte	Bed sensor, chair sensor.	At the moment the patient gets up from the bed or chair, the monitor emits a signal that reaches the wireless receiver to notify the assistant/caregiver, allowing him to manage the situation.	Does not specify.
	The special surfaces of pressure management in the prevention and treatment of pressure ulcers. Literature review [25].	Laura Herrero Boil	Bed sensor.	Clinical instruments for monitoring pressure ulcers	Eight systematic reviews, published between 2005 and 2012.

Nuevas metodologías para el reconocimiento de cambios posturales a través de sensores

Proceedings 2019, 31, 79

5 of 13

Mobile A Applications	Application: “wound analysis” [26].	Care and Wound	Does not use sensors.	Application—email monitored data for the doctor.	Does not specify.
	Guía PU mobile (at the foot of the bed) [26].	Pérez-Barreno David, Arantón-Areosa Luis	Does not use sensors	Application	Does not specify
	Smart PU integrated system for the prevention of pressure ulcers [27].	Society for the regional development of Cantabria, government of Cantabria.	Does not specify.	Application	Does not specify.
	Application “Integrated system for wound management (HELCOS) [28]	Grupo Nacional para el Estudio y Asesoramiento en Úlceras por Presión y Heridas Crónicas GNEAUPP—Foundation Sergio Juan Jordán	Does not use sensors.	Application	Does not specify.
Training Application	Caring for the skin through a weblog—Universidad Javeriana de Colombia. [29]	Renata Virginia González-Consuegra, María Alejandra Chauta Salguero, Lady Catalina Cruz Peña	Does not use sensors.	Weblog.	Does not specify.
	Consultation of tele ulcers in a complex wound unit in the treatment of ulcers [30].	Casals Zorita, Marta	Does not use sensors.	Telemedicine system for remote monitoring of UPP.	Does not specify.
	Use of information and communication technologies (ICTs) in Teaching about chronic wounds in nursing [31].	Cristina Castanedo Pfeiffer y J.M. Zamanillo Sainz de la Maza, Member,	Does not use sensors.	Information system.	Does not specify.

According to the design carried out by Aguagüña and Granizo [21], the objective of this technology is contributing to patients' care during rehabilitation. The system detects body movements and positions using video acquired through a Raspberry PI 3 card, receiving image data through a webcam located in front of the patient's bed at a predetermined distance. Some limitations were observed, since the camera must have a proper/suitable position, avoiding vibrations and poor illumination, or else it can trigger false alarms for caregivers. In the study carried out by Dresch, the purpose was to compare the measurement level of venous ulcers' area through the software Autocad and the software Image Tool. The data were collected from 21 patients with ulcers. These data were collected by nurses who took pictures of the wounds. In another study conducted by [16], a computer application was presented aimed at standardizing the criteria for prevention, treatment, and follow-up of PU during the patient's hospitalization. The system consists of an application used by nurses to collect information in real-time, with software capable of interpreting through decision algorithms, evaluating the type of control performed on the patient.

On the other hand, the company ortopedia moverte [24] has a product described as a rotating wall clock to prevent ulcer formation, allowing for the creation of a personalized protocol of postural changes for each patient at risk, by using graphic illustrations of patient positions within a timeframe to be interpreted easily and intuitively. It is composed of six rotating analogic wheels to select between the three resting positions of a patient in bed according to a time moment, serving as a reminder to the caregiver for compliance with the care protocol. The authors Herrero and Sanjuan present a literary review of special surfaces for pressure management in the prevention and treatment of PUs, such as cushions, beds, mattress covers, mattresses foam, static, alternating air pressure, and devices called Special pressure handling surfaces, which allows the redistribution of pressure and; therefore, a relief of it in patients' bodies who have PUs, or are at risk of developing them, comparing the effectiveness between low pressure alternating air mattresses and mattresses of overlap. The product wound analysis application is a system with the following characteristics: It generates photographs and records of the patients, authorized by patients in a written consent to carry out the treatment. This application defines an objective curve about the evolution of the wounds, and also aids consultations between professionals sharing cases through this application. The version patient application has the option of empowering patients with self-registration of their wounds and gives notifications to their device to identify anomalies in their treatment.

Another product named integrated system for the prevention of pressure ulcers (smart PUs) uses artificial intelligence as disruptive technologies for those patients at risk of suffering PU [27]. The application collects information from the patient and applies risk scales to elaborate a personalized guide of preventive actions. The application named "integrated system for the management of wounds" (HELCOS) [28] is a tool that targets both professionals and patients for the management of wounds. The application allows for tele-consultation with experts from other disciplines, through a chat function in the application for a specific case. The application "pressure ulcer guide" provides information and prevention strategies on pressure ulcers, eschars, or wounds. It uses a tool called Braden's Scale to evaluate the risk of pressure ulcers or decubitus eschar. The Mobile PU guide (at the foot of the bed) [26].

Addresses all the problems related to deterioration of the cutaneous and tissue integrity and risk of suffering it, as well as assessment modalities, approach, and treatment options. The contents of this application are developed in six large blocks: Classification, epidemiology, etiopathogeny, risk factors, PU classification, location, and characteristics of the PUs.

2. Architecture and Implementation

This section details a proposed methodology followed for the development of an intelligent system for PU prevention, by monitoring postural changes using wearable inertial sensors.

2.1. The Components Involved in the Intelligent System

- Wearable inertial devices. They collect accelerometer data from an inertial sensor, sending them in real-time by Bluetooth low energy (BLE) to a gateway. In this work, we propose the use of android wear devices, located on the shoulder and ankle of patients, in order to describe the orientation of patients in a non-invasive way.
- Smart board. A low-cost mini board, such as Raspberry PI 3 (RP3), is configured as a gateway to receive data from wearable devices under BLE protocol. These data are stored in a local database where the time and three-axis of the accelerometer are collected in raw format. Then, data processing is computed with the smart board to extract the features from accelerometer data of signals. Finally, features are evaluated by a classifier, determining the orientation/position of the patient. In case the orientation exceeds a predefined time threshold, an alert is sent to the mobile device of caregivers.
- Mobile application. Caregivers can access detailed information on the orientation and postures estimated by the classifier, in the form of a visual timeline. Finally, a notification service allows to be informed by the intelligent system in case of persisting postures exceeding recommended time limits.

Figure 1 shows the architecture along with the described components, the steps of data processing, and feature extraction for classifying the body position of patients, which will all be described in the next section.




Figure 1. Architecture of components for the prevention of pressure ulcers by monitoring postural changes with wearable inertial sensor.

2.2. Data Processing, Feature Extraction, and Intelligent Systems Classifiers

In formal definition, a sensor D collects data in real-time in the form of a pair $\bar{s}_i = \{s_i, t_i\}$, where s_i represents a given value/measure of the sensor and t_i is the time-stamp. Thus, the sensor data stream of the device is defined by $S_D = \{\bar{s}_0, \dots, \bar{s}_i, \dots, \bar{s}_n\}$. In this work, three-axial acceleration (x, y, z), providing three data streams S_x, S_y, S_z for each for each inertial sensor and wearable device.

Collected data are then filtered for removing noise by means of an exponential smoothing filter, which generates an equivalent prediction to a Kallman filter with faster performance [32].

$$s'_i = w \cdot s_i + (1 - w) \cdot s_{i-1}'. \quad (1) \quad (2)$$

Then, temporal segmentation defined by a window size L to select the relevant and recent measures $\bar{s}_i$ is applied [33,34]. Relevant and smoothing measures s'_i are aggregated by a given function $T_k(S_D, t_*)$ whose value defines a feature T_k of the inertial sensors S_D in current time t_* .

$$T_k(S_D, t_*) = \bigcup_{s'_i} \bar{s}_i, t_* - t_i < L, t_* \geq t_i. \quad (3) \quad (4)$$

Therefore, starting from a set of sensors $S = \{S_1, \dots, S_N\}$ and a set of aggregation functions $T = \{T_1, \dots, T_M\}$, we define a total number of features $N \times M$ to describe the sensor for each given point of time t_* .

Since our model is based on a data-driven supervised approach, the features describing the wearable sensors are related to a label $L(t_*)$ for each given time t_* :

$$T_1(S_1, t_*), \dots, T_j(S_i, t_*), \dots, T_M(S_N, t_*) \rightarrow L(t_*), \quad (5) \quad (6)$$

where $L(t_*)$ defines a discrete value $L = \{L_1, \dots, L_l\}$, and L_l identifies a posture. Here, we focus on classifying the next postures of the patient: Supine, inclined, left lateral, right lateral, sitting, partially incorporated (stretched legs and elevated torso), and walking (for those patients who has partial mobility).

Finally, the features and labels previously defined are used to train a classifier. In this work, we evaluated some classifiers, such as K-nearest neighbors (KNN), naïve Bayes (NB) support vector machine (SVM), or decision trees (C4.5), whose implementation in Java and C++ [33–34] enable embedding/deployment in miniature boards or mobile devices.

3. Experimental Setup

In this section, we describe the experimental setup and results of a case study developed in the Smart Lab of the Center for Advanced Studies in Information and Communication Technologies-CEATIC University of Jaen (Spain), in order to evaluate the proposed methodology. In the case study, four participants were included for data collection, using two wearable inertial sensors to detect eight given target classes: Supine, inclined, left lateral, right lateral, sitting, partially incorporated (stretched legs and elevated torso), walking, and idle (changes between positions).

Two Polar M600 devices, located on the shoulder and ankle of participants, were used. Each participant repeated the experiment twice, thus obtaining two cases for each user. An external observer labeled the posture in real-time during data acquisition. A total of 100.422 samples were collected.

On the preprocessing of data, the following parameters were used: The exponential filter ‘w’ was set to 0.01 to smooth and remove noise, and the window size L was defined as $L = 2.5$ s, since this has been demonstrated as a suitable configuration for evaluating inertial data in activity recognition [35]. The features set extracted from inertial sensors included Max–min values, averages, and standard deviation, which have been proven to be efficient and suitable features to describe inertial sensors in Activity Recognition (AR), and allow for the identification and recognition of the actions or goals of the habitant. AR is usually used in monitoring the activities of elderly residents to support management and prevention of diseases [36]. This feature set, with two wearable three-axial inertial sensors, corresponds to a total of 24 features.

4. Results

In this section we present the results of the case study. We evaluated the performance (precision, recall, and F1 score) using leave-one-participant-out cross-validation in two configurations: (A) The test is determined by inertial data and labels from a given participant and the training model is composed only by inertial data and labels not including the target subject (strict leave-one-out) table 3 and table 4; and (B) half of the inertial data from the participant is included in the training set to implement the model’s adaptation/personalization (adapted model), table 5 and table 6.

4.1. Training Using Leave-One-Out

In this section, we present the results of the experimental setup without including personalization of the user in learning. That is, using, as training, the data from other users and evaluating the data for the unseen data of the test user (any data for the case scenes of this user is included in learning).

In addition, we present the results aggregating two classes—walking and idle—which are not key to monitoring PUs, as the time spent in these classes does not require position changes within prevention protocols.

4.2. Training-Adapted Model.

In this section we detail the results from the experimental setup, including one of the two cases repeated by the participant in training. Thus, learning includes personalization of inertial data and postures for the test user prior to evaluation. First, in Table 3, we show the results for classifying the seven proposed postures.

Moreover, we report results aggregating the two classes—walking and idle, in Table 4.

Table 3. Results without personalization for the seven postures including walking and idle. Grouped in four classifications: SVM (Support Vector Machines), NB (Naive Bayes), C4.5 (Decision tree), KNN (K-nearest neighbor's algorithm).

Class	SVM			NB			C4.5			KNN		
	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Idle	0.653	0.345	0.451	0.711	0.420	0.528	0.695	0.224	0.339	0.654	0.507	0.571
Supine	0.507	0.657	0.572	0.697	0.724	0.710	0.366	0.351	0.358	0.547	0.485	0.514
Reclined	0.514	0.581	0.545	0.658	0.657	0.657	0.264	0.434	0.328	0.720	0.656	0.687
Left side	0.608	0.932	0.736	0.644	0.959	0.771	0.183	0.850	0.302	0.652	0.934	0.768
Right side	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.891	0.955	0.922
Standing	0.727	0.883	0.797	0.969	0.945	0.957	0.382	0.602	0.467	0.662	0.864	0.750
Walking	0.896	0.740	0.810	0.977	0.953	0.965	0.927	0.861	0.893	0.852	0.731	0.787
AVG	0.702	0.791	0.736	0.787	0.866	0.820	0.482	0.675	0.533	0.721	0.771	0.738

Table 4. Results without personalization aggregating idle and walking.

Class	SVM			NB			C4.5			KNN		
	Pre	Recal l	F1	Pre	Recal l	F1	Pre	Recal l	F1	Pre	Recal l	F1
Supine	0.847	0.557	0.672	0.883	0.664	0.758	0.873	0.437	0.583	0.456	0.407	0.430
Reclined	0.507	0.657	0.572	0.697	0.724	0.710	0.366	0.351	0.358	0.471	0.467	0.469
Left side	0.514	0.581	0.545	0.658	0.657	0.657	0.264	0.434	0.328	0.709	0.635	0.670
Right side	0.608	0.932	0.736	0.644	0.959	0.771	0.183	0.850	0.302	0.643	0.876	0.741
Standing	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.803	0.913	0.855
Movement	0.727	0.883	0.797	0.969	0.945	0.957	0.382	0.602	0.467	0.495	0.760	0.600
AVG	0.694	0.761	0.713	0.772	0.818	0.786	0.473	0.604	0.481	0.596	0.676	0.627

Besides in the Table 5 and 6, data from the participant is included in the training model's. In the same way as in the previous tables, we will show the results in Table 5 without personalization, while in Table 7 we will show the participant data with personalization.

Using patient data, in the following table we aggregating add two classes walking and indl with personalization of participant.

Finally, in Table 7, below are the best final results according to each position within the four classifiers used.

Table 5. Results with personalization for the seven postures including walking and idle.

	SVM			NB			C4.5			KNN		
	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Idle	0.447	0.495	0.470	0.762	0.417	0.539	0.856	0.238	0.372	0.757	0.761	0.759
Supine	0.976	0.903	0.938	0.000	0.000	0.000	0.000	0.000	0.000	0.796	0.961	0.871
Reclined	1.000	0.883	0.938	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Left side	1.000	0.819	0.900	1.000	0.940	0.969	0.000	0.000	0.000	0.999	0.979	0.989
Right side	1.000	0.888	0.940	1.000	0.964	0.982	0.057	0.877	0.107	1.000	0.944	0.971
Standing	0.973	0.916	0.944	1.000	0.964	0.981	0.000	0.000	0.000	0.982	0.976	0.979
Walking	0.447	0.495	0.470	0.977	0.955	0.966	0.934	0.969	0.951	0.964	0.886	0.923
AVG	0.899	0.817	0.855	0.829	0.795	0.812	0.184	0.474	0.211	0.957	0.949	0.951

Table 6. Results with personalization aggregating idle and walking.

Class	SVM			NB			C4.5			KNN		
	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Supine	0.808	0.980	0.886	0.872	0.576	0.694	0.924	0.359	0.517	0.888	0.862	0.875
Reclined	0.988	0.949	0.968	0.000	0.000	0.000	0.000	0.000	0.000	0.796	0.961	0.871
Left side	1.000	0.938	0.968	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Right side	1.000	0.900	0.948	1.000	0.940	0.969	0.000	0.000	0.000	0.999	0.979	0.989
Standing	1.000	0.940	0.969	1.000	0.964	0.982	0.057	0.877	0.107	1.000	0.944	0.971
Movement	0.986	0.956	0.971	1.000	0.964	0.981	0.000	0.000	0.000	0.982	0.976	0.979
AVG	0.964	0.944	0.952	0.812	0.731	0.766	0.183	0.373	0.138	0.944	0.945	0.943

Table 7. Final results with personalization.

Class	SVM			NB			C4.5			KNN		
	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1	Pre	Recall	F1
Idle	0.447	0.495	0.470	0.762	0.417	0.539	0.856	0.238	0.372	0.757	0.761	0.759
Supine	0.808	0.980	0.886	0.872	0.576	0.694	0.924	0.359	0.517	0.888	0.862	0.875
Reclined	1.000	0.883	0.938	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Left side	1.000	0.938	0.968	0.999	0.945	0.971	0.115	1.000	0.206	1.000	0.946	0.972
Right side	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.891	0.955	0.922
Standing	0.959	0.956	0.958	0.779	0.959	0.860	0.769	0.949	0.849	0.803	0.913	0.855
Walking	0.986	0.956	0.971	1.000	0.964	0.981	0.000	0.000	0.000	0.982	0.976	0.979
AVG	0.447	0.495	0.470	0.977	0.955	0.966	0.934	0.969	0.951	0.964	0.886	0.923

In Figure 2 we can observe the frequency guideline of each posture. additionally, that in Figure 3 we present the confusion matrix of best configuration for SVM including personalization.



**Figure 2.** Frequency guideline tool on posture change [2].

Figure 3. Confusion matrices for SVM with personalization. **(Left)**, defines the seven classes (a) idle, (b) supine, (c) reclined, (d) left, (e) right, (f) standing, and (g) walking. **(Right)**, (a) includes walking and idle.

5. Discussion

Based on the results of table 7, we identified SVM and KNN as suitable classifiers for inferring the body position of user with a F1 closer to 0.95. In addition, we observe that the best classification is developed using personalization, meaning it is key to include some training data of the target subject to enhance accuracy performances. Decision trees were excluded in the comparison since they may not be the best approach using inertial sensors, due to their limitation to handle non-discrete attributes [37]. Finally, the discrimination between idle and walking slightly decreases the performance. This distinction; however, is not relevant for the case of preventing ulcer pressures; therefore, an optimal set of target activities is the reduced set.

Results suggest that a care plan should be established for each type of patient according to the wound level. This care plan needs to be developed in collaboration with the caregivers once the initial assessment is completed, and it will be updated whenever there is a change in the patient's medical situation or when the wound does not progress towards healing. Pressure injury management strategies should also be customized considering attitudes, beliefs, culture, daily needs, and the personal preferences of the patient. In addition, it is essential that the control passes from the interprofessional team to the person to empower them to help themselves to adhere to their care plan.

6. Limitations

The causality of the formation of PUs is associated to types of forces: pressure, friction, and shearing; PUs Type 2 are associated with friction, and Types 3 and 4 to shear and pressure forces. In this work, we focus on PUs Type 4.

7. Conclusions and Future Work

In this work we presented a prototype intelligent system for the prevention of PUs. A solution based on two wearable inertial sensors on the ankle and shoulder was proposed to provide an accurate estimation of a patient's body orientation. Changes in posture are considered as the main prevention mechanism and it has been shown that it "is necessary and sufficient to avoid the appearance of pressure ulcers". This work aimed to provide the caregivers with real-time continuous body position monitoring, thus reducing the required effort thanks to automatic control.

The evaluation of different classification approaches showed that SVM and KNN provide better results in determining the position of the patient according to the data collected, the high competence, and the inherent design to work with numerical attributes. Personalization was implemented including some data of the target patient. This increased the precision and recall performance notably.

In future work we will address the use of the integrated inertial sensor in an Internet of Things device to present a less invasive approach that could be used in case studies with patients to avoid pressure ulcers. In addition, we will include linguistic rules and configuration of the alerts according to the frequency that each patient needs and the position; the intelligent system is able to prevent the ulcer by evaluating the risk and the mobility of the patient. This intelligent system would help hospitals to be more efficient and would optimize nurses' time.

We note the novelty of this work is that it proposes the use of wearable inertial sensors to monitor patients through an intelligent system which determines the position in real-time in an automatic fashion.

Acknowledgments: This research has received funding under the REMIND project Marie Skłodowska-Curie EU Framework for Research and Innovation Horizon 2020, under grant agreement No. 734355. Furthermore, this contribution has been supported by the Spanish government by means of the projects PI-0387-2018, PI-0203-2016, RTI2018-098979-A-I00, and CAS17/00292, and the postdoctoral research grant Action-6 of the University of Jaén.

References

1. Ministerio de Salud y de la Protección Social. *Herramientas Para Promover la Estrategia de la Seguridad del Paciente en el Sistema Obligatorio de Garantía de Calidad de la Atención en Salud*; Ministerio de Salud y de la Protección Social: Bogotá, Colombia, 2007.
2. Vanderwee, K. Pressure Ulcer Prevention and Repositioning. In *Science and Practice of Pressure Ulcer Management*; Springer: Basel, Switzerland, 2006; pp. 67–73.
3. Gillespie, B.M.; Chaboyer, W. P.; McInnes, E.; Kent, B.; Whitty, J.A.; Thalib, L. Repositioning for pressure ulcer prevention in adults. *Cochrane Database Syst Rev.* **2014**, doi:10.1002/14651858.CD009958.pub2.
4. Anders, J.; Heinemann, A.; Leffmann, C.; Leutenegger, M.; Pröfener, F.; von Renteln-Kruse, W. Decubitus ulcers: Pathophysiology and primary prevention. *Deutsches Ärztebl. Int.* **2010**, *107*, 371.
5. Pancorbo-Hidalgo, P.L.; García-Fernández, F.P.; i Bou, J.E.T.; Soriano, J.V.; Soldevilla-Agreda, J.J. Epidemiología de las úlceras por presión en España en 2013: 4.º Estudio Nacional de Prevalencia. *Gerokomos* **2014**, *25*, 162–170.
6. Undesa. *Population Ageing 2006*; Department of Economic and Affairs, Population Division: New York, NY, USA, 2006.
7. Zuo, X.L.; Meng, F.J. A care bundle for pressure ulcer treatment in intensive care units. *Int. J. Nurs. Sci.* **2015**, *2*, 340–347.
8. Dare, A.; Moorer, A.; Flynn, M. Peer-to-Peer Nursing Rounds and Hospital-Acquired Pressure Ulcer Prevalence in a Surgical Intensive Care Unit. *J. Wound Ostomy Cont. Nurs.* **2012**, *39*, 152–157.
9. Gail, M.; Houghton, E. Prevalence of pressure ulcers in Canadian healthcare settings. *Ostomy Wound Manag.* **2004**, *50*, 22–38.
10. Flores, I.; De La Cruz, S.; Ortega, M.; Hernández, S.; Cabrera, M. Prevalencia de úlceras por presión en pacientes atendidos en el Instituto Nacional de Cardiología Ignacio Chávez. *Rev. Mex. Enferm. Cardiol.* **2010**, *18*, 13–17.
11. Rogenski, N.; Kurcgant, P. The incidence of pressure ulcers after the implementation of a prevention protocol. *Rev. Lat. Am. Enferm.* **2012**, *20*, 333–339.
12. Kottner, J. Pressure ulcer prevalence rates from 2002 to 2008 in German long-term care facilities. *Aging Clin. Exp. Res.* **2010**, *22*, 152–156.
13. Bours, G.J.; Halfens, R.J.; Candel, M.J.; Grol, R.T.; Abu-Saad, H.H. A pressure ulcer audit and feedback project across multi-hospital settings in the Netherlands. *Int. J. Qual. Health Care* **2004**, *16*, 211–218.
14. Posnett, J.; Agreda, J.J.S.; i Bou, J.E.T.; Soriano, J.V. Una aproximación al impacto del coste del tratamiento de las úlceras por presión en España. In *Epidemiología, Coste y Repercusiones Legales de las Úlceras por Presión en España Años 2005–2006*; Agreda, J.J.S., i Bou, J.E.T., Soriano, J.V., Eds.; Smith & Nephew: Sant Joan Despí, Spain, 2007.
15. Bautista, I.; Bocanegra, L. Prevalencia y Factores Asociados de las Úlceras Por Presión en Pacientes Hospitalizados en los Servicios de Medicina Interna, Neurología y Unidad de Cuidados Intensivos de una Institución Prestadora de Servicios de Salud de III Nivel de la Ciudad de Bogotá en el Año 2009. Bachelor's Thesis, Universidad Javeriana, Bogotá, Colombia, 2009.
16. Yáñez, O.B.; Arrieta, J.R.; Bafaluy, M.I.B.; Aguirre, J.J.C. Evaluación e impacto del uso de las tecnologías de la información y comunicación para la gestión clínica y seguimiento compartido y consensuado de las úlceras por presión. *Rev. Esp. Geriatr. Gerontol.* **2015**, *50*, 179–184.
17. Kress, D.W. Pressure Sensing Device and Method for Preventing Ulcer Formation. U.S. Patent No. 4,554,930, 26 November 1985.
18. Rosser, J.; Scott, G. U.S. Device for the Prevention or Treatment of Ulcers. Patent Application No. 10/861,701, 6 January 2005.
19. Kaikenger, P.; Williamson, R.L.; Ventrola, T.S.; Tallent, D.R.; Leigh, S.C.I.; Stebbins, K.L. Pressure Ulcer Prevention with Wearable Monitoring. Patent Application No. 15/822,532, 31 May 2018.
20. Sundaravadivel, P.; Kougiannos, E.; Mohanty, S.P.; Ganapathiraju, M.K. Everything you wanted to know about smart health care: Evaluating the different technologies and components of the Internet of Things for better health. *IEEE Consum. Electron. Mag.* **2007**, *7*, 18–28.
21. Aguagüña, H. *Sistema Electrónico Para Asistir A Pacientes en Proceso de Rehabilitación de Úlceras Por Presión*; Universidad Técnica de Ambato, Facultad de Ingeniería en Sistemas, Electrónica e Industrial, Carrera de Ingeniería en Electrónica y Comunicaciones: Ambato, Ecuador, 2018.

22. Dresch, T.; Beatriz, S.; Dias, F.; Lima, E.; Heck, T.; Portella, G. Measurement of the area of venous ulcers using two software programs. *Rev. Latino Am. Enferm.* **2016**, *24*, doi:10.1590/1518-8345.1673.2862
23. Yáñez, O.B.; Arrieta, J.R.; Bafaluy, M.I.B.; Aguirre, J.J.C. Evaluación e impacto del uso de las tecnologías de la información y comunicación para la gestión clínica y seguimiento compartido y consensuado de las úlceras por presión. *Rev. Esp. Geriatr. Gerontol.* **2015**, *50*, 179–184.
24. Ortopedia Moverte, Reloj Control Cambios Posturales, Referencia 3948. Available online: <https://www.moverte.com/equipamiento-sociosanitario/3948-reloj-control-cambios-posturales.html> (accessed on 7 April 2019).
25. Herrero, L.; Sanjuán, A. Las Superficies Especiales de Manejo de Presión en la Prevención y Tratamiento las Úlceras por Presión. Bachelor's Thesis, Universidad de Alicante, Alicante, Spain, 2015.
26. GNEAUPP Grupo Nacional Para el Estudio y Asesoramiento en Úlceras Por Presión y Heridas Crónicas. Software y Apps. 2019. Available online: <https://gneaupp.info/seccion/software-y-apps/> (accessed on 7 April 2019).
27. Smart UPP, Sistema Integrado para la Prevención de Úlceras por Presión, Sociedad para el Desarrollo Regional de Cantabria, Gobierno de Cantabria, I+C+=C, GNEAUPP. Available online: <https://www.smartupp.es/> (accessed on 10 March 2019).
28. Helcos, La APP Sistema Integrado para el Manejo de Heridas (HELCOS), 2017 GNEAUPP—Fundación Sergio Juan Jordán. Available online: <https://helcos.net/users/login> (accessed on 20 March 2019).
29. González-Consuegra, 2 Caring for the Skin through a Weblog 2015, Universidad Javeriana de Colombia. Available online: <https://integridaddelostejidosun.wordpress.com/> (accessed on 5 March 2019).
30. Casals, M. Eficiencia de Una Consulta de Teleúlceras en Una Unidad De Heridas Complejas en el Tratamiento de Úlceras de Extremidad Inferior. Universidad de Cantabria. 2018. Available online: <http://hdl.handle.net/10902/14385> (accessed on 20 April 2019).
31. Castanedo, C.; Zamanillo, J.M. *Uso de las TICs Para la Docencia Sobre Heridas Crónicas en Enfermería*; Dpto. de Enfermería Universidad de Cantabria, Escuela Universitaria de Enfermería “Casa de Salud Valdecilla”: Cantabria, Spain, 2009.
32. Ordóñez, F.J.; Roggen, D. Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition. *Sensors* **2016**, *16*, 115.
33. Hall, M.; Frank, E.; Holmes, G.; Pfahringer, B.; Reutemann, P.; Witten, I.H. The WEKA data mining software: An update. *ACM SIGKDD Explor. Newslett.* **2009**, *11*, 10–18.
34. Chang, C.C.; Lin, C.J. LIBSVM: A library for support vector machines. *ACM Trans. Intell. Syst. Technol. (TIST)* **2011**, *2*, 27.
35. Espinilla, M.; Medina, J.; Hallberg, J.; Nugent, C. A new approach based on temporal sub-windows for online sensor-based activity recognition. *J. Ambient Intell. Humaniz. Comput.* **2018**, *19*, 1–13.
36. Espinilla, M.; Medina, J.; Salguero, A.; Irvine, N.; Donnelly, M.; Cleland, I.; Nugent, C. Human Activity Recognition from the Acceleration Data of a Wearable Device. Which Features Are More Relevant by Activities? In Proceedings of the 12th International Conference on Ubiquitous Computing and Ambient Intelligence (UCAmI 2018), Punta Cana, Dominican Republic, 4–7 December 2018; Volume 2, No. 19, p. 1242.
37. Beck, J.; Garcia, M.; Zhong, M.; Georgiopoulos, M.; Anagnostopoulos, G. A Backward Adjusting Strategy and Optimization of the C4.5 Parameters to Improve C4.5's Performance. In Proceedings of the Twenty-First International FLAIRS Conference, Orlando, FL, USA, 15–17 May 2008; pp. 35–40.



© 2019 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).


**A.5.2. New methodology for the classification of postural
postural changes in textiles sensorised textiles**



Contents lists available at ScienceDirect

Journal of Biomedical Informatics

journal homepage: www.elsevier.com/locate/yjbin



Fuzzy monitoring of in-bed postural changes for the prevention of pressure ulcers using inertial sensors attached to clothing



Edna Bernal Monroy^a, Aurora Polo Rodríguez^b, Macarena Espinilla Estevez^b,
Javier Medina Quero^{b,*}

^a Universidad Nacional Abierta y a Distancia, Colombia

^b Department of Computer Science, University of Jaen, Spain

ARTICLE INFO

Keywords:

Inertial sensors

Pressure ulcers

Pose recognition

Fuzzy logic

ABSTRACT

Postural changes while maintaining a correct body position are the most efficient method of preventing pressure ulcers. However, executing a protocol of postural changes over a long period of time is an arduous task for caregivers. To address this problem, we propose a fuzzy monitoring system for postural changes which recognizes in-bed postures by means of micro inertial sensors attached to patients' clothes. First, we integrate a data-driven model to classify in-bed postures from the micro inertial sensors which are located in the socks and t-shirt of the patient. Second, a knowledge-based fuzzy model computes the priority of postural changes for body zones based on expert-defined protocols. Results show encouraging performance in the classification of in-bed postures and high adaptability of the knowledge-based fuzzy approach.

1. Introduction

Pressure ulcers (PUs), as a medical condition, are defined as localized lesions on the skin or underlying dermal tissue, usually appearing over a bone prominence as result of body pressure [1]. The problem of PUs has been on the rise recently and has been described as a *living and alarming epidemic that lives under the sheets of patients at different levels of care*. Consequently, it has been identified as a critical shortcoming in the care of patients [2]. There is a higher prevalence of PUs among adults over 60 years of age (51%) [3]. PUs also appear in patients with limited movement, such as cases of amyotrophic lateral sclerosis or paraplegia. Treatments need to be customized and planned individually for each patient [3]. For PU lesion treatment, intervention methods involve electrical stimulation or ultrasound applied directly to the lesions, making the process painful for patients and expensive for the healthcare system.

Studies on the cost analysis of PUs [4] have concluded that: (i) the cost of treatment increases with the severity of the ulcer because of the longer healing/recovery time; and (ii) this cost includes expenses in material inputs, nursing time and hospitalization charges for the healthcare system, resulting in a significant impact of PUs on the national healthcare system and government budget; therefore, (iii) prevention is the best strategy to address this public health problem [5].

Postural changes are the main method for preventing pressure ulcers [6], whereby patients need to change their position by themselves or with the support of an assistant. Handling these changes of posture, however, can result in excessive physical and emotional stress for caregivers [7]. Given the existence of advanced technologies that aim to improve living conditions, we face the challenge of creating new technological health models to monitor in-bed postural changes for the prevention of PUs. In this work, we present [8] an intelligent system to monitor in-bed posture of patients using wearable inertial sensors as a control and decision-making tool.

The goal of this paper is to develop a data-driven classification for in-bed postures using inertial sensors attached to clothing, which enable us to describe the posture of the patient and orientation of body zones accurately and in a non-invasive way. Second, modeling a secure and flexible approach to compute the priority of postural changes according to a given expert-defined protocol is key to the knowledge-based fuzzy approach.

The remainder of the paper is organized as follows: in Section 2 we detail the review of works related to our proposal; Section 3 presents the proposed methodology to develop a data-driven classification for in-bed postures using inertial sensors attached to clothing; Section 4 introduces the results of a dataset with postural change protocols modelled under our approach. Finally, conclusions and ongoing works are

* Corresponding author.

E-mail addresses: edna.bernal@unad.edu.co (E. Bernal Monroy), apolo@ujaen.es (A. Polo Rodríguez), mestevez@ujaen.es (M. Espinilla Estevez), jmquero@ujaen.es (J. Medina Quero).

<https://doi.org/10.1016/j.jbi.2020.103476>

Received 28 February 2020; Received in revised form 9 May 2020; Accepted 3 June 2020

Available online 18 June 2020

1532-0464/ © 2020 Elsevier Inc. All rights reserved.

discussed in Section 6.

2. Related works

In recent years, academic and industrial research initiatives on smart systems have been developed for healthcare with the aim of supporting future healthcare demands for dependent people to improve their quality of life, reduce healthcare costs, and complement specific medical delivery services [9].

In the scope of this work, despite the impact of the problem, there are not many technology-based works aimed at improving care and monitoring postural changes for PU prevention. We outline the most relevant below.

One of the first developments was proposed in 1995, where the authors [10] defined a pressure sensing device to evaluate the periods during which the skin has been exposed to the measured pressure. Following this initial idea, in [11], the design of a pressure sensor placed between skin and surface was proposed. In [12], an ad-hoc computer application for PU management enabled monitoring of patients suffering from PUs for risk assessment by collecting images and recording PU data, thus favoring the exchange of data between professionals and different levels of care to support decision-making.

Recently, in [13], patient body movement was recorded over time to determine whether the movement of the patient is adequate so as to prevent PUs. However, this patent lacks a description of the methodology to process the data, generate a classification of in-bed postures and configure the protocol of postural changes. In [14], the company *Ortopedia Moverte* developed a product which is described as a rotating wall clock to prevent ulcer formation by allowing the creation of a personalized protocol of postural changes for each patient, by using graphic illustrations of patient positions within a timeframe to be interpreted easily and intuitively. The product [15], a wound analysis application, collects patients' photographs and records, authorized by patients who provide written consent to carry out the treatment. This application defines an objective curve on the evolution of the wounds and also enables consultations among professionals by sharing cases through the application. Another product for patients at risk of suffering PUs [16] is called *integrated system for the prevention of pressure ulcers (smart PUs)*. This application collects information from the patient and applies risk scales to create a personalized guide of preventive actions.

The application *integrated system for the management of wounds (HELCOS)* [17] is a tool that targets both professionals and patients for wound management. The application allows for teleconsultation with experts from other disciplines through a chat function provided for each specific case. The application *pressure ulcer guide* [15] provides information and prevention strategies on pressure ulcers, eschars or wounds. It uses a tool called Braden's Scale to evaluate the risk of pressure ulcers or decubitus eschar.

In [18], the design carried out by Aguagüña and Granizo had the objective of contributing to patient care during rehabilitation. The system detected body movements and positions using video footage acquired through a Raspberry PI 3 card, receiving image data through a webcam located in front of the patient's bed at a certain distance. In another study conducted by [12], a computer application was presented to standardize the criteria for the prevention, treatment, and follow-up of PUs during patient hospitalization. The system consists of an application used by nurses to collect information in real time, using software capable of interpreting and evaluating the type of control performed on the patient through decision algorithms.

Another noteworthy project is In-bed Pose classification from Pressure Mat Sensors for the Prevention of Pressure Ulcers using Convolutional Neural Networks [19]. In this work, the authors propose a methodology to classify in-bed human positions for the prevention of pressure ulcers using pressure mat sensors. First, they provide a visual representation using fuzzy processing from raw pressure data to gray

scale. Second, they define CNN Convolutional Neural Networks models to evaluate the impact of layers on the performance of in-bed posture classification.

In the previous work [20], in the previous work a prototype for monitoring and care of pressure ulcers through an intelligent system based on smart inertial watches was presented. The system detects the position of patients with reduced mobility while in bed, walking or standing, providing data to medical staff and caregivers. In this work, we present a substantial development of the previous prototype by evaluating ad hoc in-bed postures and including a knowledge-based fuzzy approach computing the priority of postural changes in real-time, which enables clinicians to model postural protocols and configure reminders. In order to provide a summary of the strengths and limitations of previous works, we present a table with the most relevant works on technological approaches for PU prevention.

In this work, a new methodology to monitorize in-bed postural changes for PU prevention with inertial sensors attached to clothing is presented. In this way, taking into account all the described literature and previous works, we propose:

- Integration of non-invasive inertial sensors attached to clothing, which send inertial data in real-time. A data-driven model to classify in-bed postures from the micro inertial sensors.
- A knowledge-based fuzzy approach to compute the priority of postural changes in real-time.
- The approach enables clinicians to model postural protocols to configure reminders to be notified in an interpretable and personalized way for injured body zones.

We describe the proposed methodology in detail in the following section.

3. Methodology

In this section, the proposed methodology is presented to classify human in-bed posture for the ONE devices were integrated into two socks and one t-shirt, as described in prevention of pressure ulcers using inertial sensors attached to clothing and a knowledge-based fuzzy approach to compute the priority of postural changes. The main components configuring the approach are: (i) inertial sensors attached to clothing, which describe the orientation of patients' body zones in a non-invasive way; (ii) a data-driven model for recognizing in-bed postures, which segments inertial data and classifies the poses; (iii) a knowledge-based fuzzy approach, which computes the priority of postural changes for each body zone according to a defined protocol and the time elapsed from previous in-bed postures; and (iv) a reminder to advise caregivers when the degree of priority of postural change reaches a configurable threshold. In Fig. 1, we show the architecture of components described in the approach, which are detailed in the following sections.

3.1. Inertial sensors attached to clothing

In this section, we describe the micro inertial sensors proposed for sensing in-bed postures, which were attached to patients' clothes in a non-invasive way. In this line, e-textiles [21] have provided a new perspective for wearable non-invasive data sensing from patients. In particular, integrating low-cost micro inertial measurement units [23], which have been demonstrated to describe 105 patient postures [20] or gait speed [22].

For this purpose, we selected the Tactigon ONE device¹ [24] due to its suitable specifications: lightweight (2.5 g device and 6.3 g battery) and small size (5.0 × 1.67 × 0.56 cm). Moreover, the affordable price

¹ Tactigon ONE device <https://www.thetactigon.com/products/>.




Fig. 1. Architecture of components: (i) inertial sensors attached to clothing, (ii) data-driven model for recognizing in-bed postures, (iii) knowledge-based fuzzy approach to compute the priority of postural changes for body zones, and (iv) a configurable threshold for notifications to caregivers.



Fig. 2. Tactigon ONE: (left) inertial sensor embedded into board; center and (right) Tactigon ONE attached to socks and t-shirt of patient, respectively.

(78 euros) and the open SDK, which enables us to code the board for full configuration (sample rate, communication, sensors, etc.), were the key points in selecting the device.

Three Tactigon ONE devices were integrated into two socks and one t-shirt, as described in Section 2. Acceleration and gyroscope data from the miniature boards were sent under Bluetooth Low Energy (BLE) at a frequency of 20 samples per second.

3.2. Data-driven model for recognition of in-bed postures

Following a formal definition, a sensor s collected data in real time in the form of a pair $\bar{s}_i = \{s_i, t_i\}$, where s_i represents a given measurement and t_i the time-stamp, respectively. Thus, the data stream of the sensor s is defined by $\bar{S}_s = \{\bar{s}_0, \dots, \bar{s}_i\}$. In this work, a tri-axial inertial representation (x,y,z) provided three data streams $\bar{S}_X, \bar{S}_Y, \bar{S}_Z$ from the sensors on acceleration and gyroscope for each inertial device.

Next, a temporal segmentation was defined by a window size W [25] to aggregate the samples $\bar{s}_i$ by a given function $T_i(S_s, t^*)$. The aggregation value defines a feature T_i of the inertial sensors S_s in a given time t^* .

$$T_i\left(S_s, t^*\right) = \bigcup_{s_i} \bar{s}_i, t^* - t_i > W, t^* \leq t_i \quad (1)$$

Therefore, starting from a set of sensors $S = \{S_1, \dots, S_s, \dots, S_{|S|}\}$ and a set of aggregation functions $T = \{T_1, \dots, T_s, \dots, T_{|T|}\}$, we defined a total number of features $|S| \times |T|$ which describe the segment of sensor data W for each given point of time t^* [26]. Since our model is based on a data-driven supervised approach, the features which describe the inertial sensors are associated with a label $L(t^*)$ for each point of time t^* :

$$T_1(S_1, t^*), \dots, T_i(S_s, t^*), \dots, T_{|T|}(S_{|S|}, t^*) \rightarrow L_i(t^*) \quad (2)$$

where $L_i(t^*)$ defines a discrete value for each point of time t^* between $L = \{L_1, \dots, L_i, \dots, L_{|L|}\}$, which identifies a given in-bed posture. In this work, six in-bed postures for the prevention of pressure ulcers were classified: supine, left-side, right-side, Fowler's, supine with bent right leg and supine with bent left leg, which are described in Fig. 3 and represent common in-bed postures for evaluation purposes [27].

Finally, the previously defined features and labels were used to train a data-driven classifier. Among the broad spectrum of models, we

focused on light and efficient classifiers, which enable training and evaluation on micro boards in real time under Fog Computing environments[28]. Specifically, in this work, we evaluated three classifiers: K-nearest neighbors (kNN) and support vector machine (SVM) as they provide the best performance in posture classification from inertial sensors [20], together with decision tree (C4.5).

3.3. Knowledge-based fuzzy approach to compute the priority of postural changes

In this section, we detail a knowledge-based fuzzy approach to compute the priority of postural changes from an expert-defined protocol, which is defined by a set of postures L which are changed every time interval T .

First, a given in-bed posture L_i was associated with one or more body zones of the patient $Z = \{Z_1, \dots, Z_z, \dots, Z_{|Z|}\}$ by a membership function $\mu_z: Z \times L \rightarrow [0, 1]$ which determines a degree of pressure between 0 and 1. For example, for body zone $Z_1 = \text{shoulderblade}$ and in-bed postures $L_1 = \text{Supine}$, $L_2 = \text{Fowler}$, $L_3 = \text{lateralposition}$, we defined $\mu_z(Z_1, L_1) = 1$, $\mu_z(Z_1, L_2) = 0.5$, $\mu_z(Z_1, L_3) = 0$. Then, as the postures are recognized in a point of time t^* , a body zone is affected by a pressure degree over time as $Z_z(t^*) = \bigcup_{L_i} \mu_z(L_i(t^*))$.

Second, we applied Fuzzy Temporal Windows (FTW) and fuzzy temporal aggregation [29] over time to compute the degree of pressure of the body zone $Z_z(t^*)$ from previous time-stamps t^j to the current time t^* . FTWs were described straightforwardly according to the distance from the current time t^* to the previous timestamps t^j as $\Delta t^j = t^* - t^j$ using a membership function $\mu_{T_k}(\Delta t^j)$ [30]. Intuitively, a given FTW T_k can be defined by four values $TS(T_{k1}, T_{k2}, T_{k3}, T_{k4})$, which determine a trapezoidal membership function [8] (referred to in Appendix B. In concrete terms, we propose a FTW which covers two time intervals T of postural changes, whose membership function is defined by: $\mu_{T_k}(\Delta t^j) = TS(0, 0, T, 2T)$.

The aggregated degree $Z_z \cup T_k$ of body zone Z_z within temporal window T_k was computed using a fuzzy weighted average [31] (detailed in Appendix A), which is proposed as a suitable representation for high sample rate sensors[29]. The temporal aggregated degree was defined as $Z_z \cup T_k(t^*)$ for each point of time t^* . In Fig. 4, we show an example of the aggregated degree of body zones $Z_1 = \text{shoulder}$ and $Z_1 = \text{left/right hip}$ within the FTW $T_1 = TS(0h, 0h, 2h, 8h)$ per minute t^* over a 24-h timeline using a basic protocol of postures that are changed in two-hour time intervals *supine*→*right lateral*→*fowler*→*leftlateral*.

Finally, a fuzzy quantifier Q_z [32] was applied in order to provide an interpretable representation of the *priority of postural changes for body zone* Z_z from the aggregated degree of a body zone $Z_z \cup T_k$. A fuzzy quantifier was directly defined to associate both terms by a membership function $\mu_{Q_z}: [0, 1] \times [0, 1] \rightarrow [0, 1]$, which should fulfill the principles of monotony and zero-aggregation [33]. In order to model the fuzzy quantifier straightforwardly, the expert only needs to define two or



Fig. 3. Classified in-bed postures for the prevention of pressure ulcers (from left to right): supine, left-side, right-side, Fowler's, supine with bent right leg and supine with bent left leg.

more control points [34]. A control point is defined by a 2-tuple $\{t^j, Q_s^j\}$, which associates the aggregation degree of the body zone in a point of time t^j with the degree of priority of postural change Q_s^j modeled by the expert. For the sake of simplicity, the control points were defined by the expert in a beginning t_A and an end point of time t_B for the postural change which affects this body zone, representing minimum and maximum priority degree, respectively. For the remaining values of the temporal aggregated degree of a body zone $Z_z \cup T_k$, a linear interpolation of the control points defines the membership function (detailed in Appendix C) to compute the priority degree of postural change [0, 1]. In Fig. 5, we show an example of the fuzzy quantifier defined by two control points for the body zone *left-hip* whose degrees of priority were defined at the beginning and end of the postural change.

3.3.1. Configurable threshold of postural changes according to caregivers' needs

In the previous Section 3.1, we have described a knowledge-based fuzzy approach to compute the degree of *priority of postural changes* for body zone Z_z from the in-bed postures classified by the inertial sensors. This degree provides interpretable and valuable information to caregivers in order to make the postural changes in a flexible and suitable way.

Moreover, the priority degree for postural changes was defined in the range [0, 1], an α - cut $\in [0, 1]$ to notify the caregiver when the degree surpasses the threshold. We note α_z can be defined for each body zone Z_z ; however, for the sake of simplicity, we take α to refer to any or all of them.

So, given the flexibility provided by the knowledge-based fuzzy approach in computing the priority degree for postural changes, the α -cut can be modified over time in order to define a more relaxed or strict threshold and therefore increase or reduce the time between postural changes, depending on the caregiver's time constraints or the patient's wishes. In this way, $\alpha \approx 0$ is associated with the minimum time when postural change affects the body zone, and $\alpha \approx 1$ is associated with maximum recommended time, respectively.

We note the priority degree for postural changes is ultimately modeled by: (i) the fuzzy quantifier defined by experts using controls points, so there is a relation of interpretability between the alerts obtained by α and the fuzzy quantifier Q_q modelling; and (ii) the Fuzzy Temporal Windows, defining a long-term aggregation (usually in a range of hours) of the degree of pressure in a body zone. So, for example, if a postural change has been delayed, the model wisely reduces the time to the next postural change (for the same body zone) since




Fig. 4. Fuzzy processing from a basic sequence of postural changes to compute the aggregation degree of pressure of the body zones shoulder and left/right hip over two time intervals T of postural changes.




Fig. 5. Fuzzy quantification defined by two control points, defined at the beginning and end of the postural change, to compute the priority degree of postural changes for the body zone. In figure, we show in Fig. 5 the priority degree of postural changes over one day, which evolves according to the postural changes made by caregivers.

threshold α was reached earlier.

In Section 4.2, we detail several in-bed postural protocols which have been modelled using the described methodology.

4. Evaluation

In this section, we describe the results of a dataset and three postural change protocols for PU prevention which have been modelled under our approach.

4.1. Evaluation of in-bed posture recognition by inertial sensors attached to clothing

Firstly, the in-bed posture recognition by inertial sensors attached to clothing was evaluated.

The experimental development of this research study took place at the CEATIC (Centro de Estudios Avanzados en Tecnologías de la Información y de la Comunicación)² of the University of Jaen (Spain). Three Tactigon ONE devices were integrated into two socks and one t-shirt, as described in Section 3.1. There were 7 participants (3 male and

4 female). For this case study, the total sample comprised 7 students: 4 women and 3 men with an average age of 24.75 years, an average height of 1.68 m and an average weight of 73 kg. The subjects were students and staff of the University of Jaen Campus. During the experiment, two professionals from Neurobase, a neuro-rehabilitation clinic, participated in the data collection and indicated the postural change protocol for preventing pressure ulcers. They voluntarily signed a consent form to share their data, agreeing to be part of the research effort, understanding the objectives, possible risks, the procedures and benefits. The results of this research study are reported or published for academic purposes, so the names and personal data of the participants have been omitted. In the case study, they wore the clothes with attached sensors in six different in-bed postures: supine, left-side, right-side, Fowler's, supine with bent right leg and supine with bent left leg, which are detailed in Fig. 2. For evaluation purposes, we gathered two datasets of the six in-bed postures for each participant, recording approximately 10 min per posture and 1 h per participant. More than 500,000 samples were collected from inertial sensors in the case study, during which an external observer labelled and timed the postures. The dataset is publicly available in³ <https://github.com/AmsterdamVibes/>

² UJAmI Smart Lab <https://ceatic.ujaen.es/ujami/en/smartlab>.

³ Dataset of In-bed Postures for the Prevention of Pressure Ulcers using

Table 1

Metrics of precision (P), recall (R) and f1-score (F1) with personalized learning in data evaluation.

	SVM			kNN			J48		
	F1-sc	P	R	F1	P	R	F1	P	R
S1	1.00	1.00	1.00	1.00	1.00	1.00	0.37	0.33	0.41
S2	1.00	1.00	1.00	1.00	1.00	1.00	0.59	0.66	0.54
S3	1.00	1.00	1.00	1.00	1.00	1.00	0.49	0.63	0.40
S4	1.00	1.00	1.00	1.00	1.00	1.00	0.55	0.66	0.47
S5	1.00	1.00	1.00	1.00	1.00	1.00	0.36	0.33	0.41
S6	1.00	1.00	1.00	1.00	1.00	1.00	0.60	0.66	0.55
S7	1.00	1.00	1.00	1.00	1.00	1.00	0.61	0.52	0.74
Average	1.00	1.00	1.00	1.00	1.00	1.00	0.51	0.54	0.50

inertial-inbedpostures.

The inertial data were divided into 2.5 s segments [20] and the proposed aggregation functions were: maximal, minimal, average and standard deviation [26]. Three classifiers: K-nearest neighbors (kNN), decision tree (C4.5) and support vector machine (SVM) were evaluated.

Two evaluation methods were carried out. First, an evaluation based on *personalized learning*, where only one dataset per participant was used for training and testing. In this case, one dataset was used for training and the other one for testing (two datasets with six in-bed postures were collected for each participant). Second, an evaluation based on *unseen participant* was analyzed to compare learning and training capabilities using unseen data for each participant. In this case, two datasets for each participant were used as testing data and the other datasets for the rest of the users were used as training data. Both in personalized and non-personalized learning, a leave-one-participant-out cross-validation was performed, obtaining the results described in Tables 1 and 2, respectively. In addition, the confusion matrix for each evaluation and classifier is described in Fig. 6.

4.2. Modelling of heterogeneous in-bed postural protocols

Next, we implemented three heterogeneous in-bed postural protocols under the knowledge-based fuzzy approach proposed in this work. The same methodology was followed for both in-bed postural protocols:

- A set of postures L and sequence of postural changes within a time interval T were defined for each protocol.
- A set of body zones Z were related to each posture L_i by a degree of pressure.
- FTW Fuzzy Temporal Windows with a size of two time intervals covered a long-term evaluation of postural changes to compute body zone pressure over time.
- A fuzzy quantifier Q_z was defined to determine an interpretable priority degree of postural changes for each body zone.
- A configurable threshold α was set for the notification to remind the caregiver to change the patient's posture according to their wishes.

4.2.1. Model A: basic postural protocol with two-hour change time intervals

First, a basic postural protocol was defined by 4 in-bed postures: supine, left lateral decubitus, Fowler's and right lateral decubitus, which were changed between two-hour time intervals [35]. Each posture was associated with the body zones of the patients - shoulder, heels, gluteus, left hip and right hip - by a degree of pressure Z_z , which is described in Fig. 7 together with the postures and the cycle of postural changes. Next, two control points, which were defined by the

(footnote continued)

Inertial Sensors Attached to Clothing. <https://github.com/AmsterdamVibes/inertial-inbedpostures>.

Table 2

Metrics of precision (P), recall (R) and f1-score (F1) with unseen participant learning in data evaluation.

	SVM			kNN			J48		
	F1-sc	P	R	F1	P	R	F1	P	R
S1	1.00	1.00	1.00	0.99	1.00	0.99	1.00	1.00	1.00
S2	1.00	1.00	1.00	1.00	1.00	1.00	0.85	1.00	0.75
S3	1.00	1.00	1.00	1.00	1.00	1.00	0.97	1.00	0.94
S4	1.00	1.00	1.00	0.99	0.99	0.99	1.00	1.00	1.00
S5	1.00	1.00	1.00	1.00	1.00	1.00	0.87	0.83	0.93
S6	0.97	1.00	0.94	0.99	1.00	0.99	0.96	1.00	0.93
S7	1.00	1.00	1.00	0.99	1.00	0.99	0.69	0.65	0.74
Average	0.99	1.00	0.99	0.99	0.99	0.99	0.91	0.87	0.90

expert in the beginning t_A and end point of time t_B for two-hour long postural changes, determine the degree of priority Q^j_* of postural change for the body zones $\{Q^A_* = 0, Q^B_* = 0.8\}$. In this way, the notification threshold for reminders was set to $\alpha - cut = 0.8$ for all body zones, alerting caregivers every two hours if they did not change the patient's posture. The complete configuration for this postural protocol and an example of priority degree for postural changes over one day is shown in Fig. 7.

4.2.2. Model B: Dynamic postural protocol with adaptive change time interval

Second, we defined a dynamic protocol where the elapsed time for postural changes can be partially extended to four hours [36,37]. The same postures and body zones from the previous section were used here; however, in order to facilitate the caregiver's sleep, postural changes at night (from 00 h to 8 h) were extended to four hours while keeping to two hours during the day (from 8 h to 24 h). To model this adaptive protocol, a third control point t_C was defined in the end point of four-hour postural changes with the maximal priority degree of postural change $Q^C_* = 1$, obtaining $\{Q^A_* = 0, Q^B_* = 0.8, Q^C_* = 1.0\}$ to be applied at night. To make things simple for caregivers, the configurable notification threshold of reminders was set to $\alpha - cut = 0.8$ during the day and $\alpha - cut = 1.0$ at night to enable knowledge-based fuzzy model dynamic reminders for postural changes between 2 and 4 h respectively. We note that $\alpha - cut \in [0.8, 1]$ can be set by caregivers to compute reminders progressively from 2 to 4 h.

The configuration of parameters of this model together with an example of priority degree for postural changes over 2 days is shown in Fig. 8. We note that in this model we detail 2 days of postural changes to show the four in-bed postures at night.

4.2.3. Model C: postural protocol for preventing pressure over injured body zones

Third, an adapted model for preventing pressure on injured body zones is presented. Among PUs, the sacrum and heels were the most affected locations [38]. As the use of attached inertial sensors enables us to determine the orientation of body zones when they are located appropriately, the particular monitoring of injured areas is made possible. In order to show the recognition of body zone orientation, in this work the following additional in-bed postures were evaluated: supine with bent right leg and supine with bent left leg [27].

In this context, we describe a scenario where the patient suffers an emerging PU in the right heel. In this case, supine posture with bent right leg by knee flexion [39] avoids pressure on the injured area over time. So, in this adapted model, the classic posture *supine* is replaced with *supine with bent right leg* to protect the right heel from pressure caused by the postures described in previous sections. This small change enables a 66% reduction in average pressure per time unit in the given zone, as detailed in Table 3.

Nuevas metodologías para el reconocimiento de cambios posturales a través de sensores

E. Bernal Monroy, et al.

Journal of Biomedical Informatics 107 (2020) 103476




Fig. 6. Confusion matrix: (A) SVM- Support Vector Machine with personalized learning, (B) KNN K-nearest neighbors with personalized learning, (C) C4.5 Decision Tree with personalized learning, (D) SVM Support Vector Machine with unseen participant learning in data evaluation, (E) KNN K-nearest neighbors with unseen participant learning in data evaluation and (F) C4.5 Decision Tree with unseen participant learning in data evaluation.

In order to model the adaptation of the injured body zone to the protocol, three steps were followed. First, the left and right heels were included separately as new body zones, which were then associated with the in-bed postures: supine with bent right leg, left lateral, Fowler's and right lateral by a degree of pressure Z_z . Second, the control points for the injured left heel were decreased to $\{Q^A_* = 0, Q^B_* = 0.25, Q^C_* = 0.5\}$ to represent the need for special attention, determining the priority degree of change in the

beginning tA , indicating postural change at two-hours tB and at four-hours tC for the in-bed posture (Fowler's) which affects this body zone (left heel). As in the previous section, the value of the notification threshold for reminders was set to $\alpha - cut = 0.8$ during the day and $\alpha - cut = 1.0$ at night for all body zones except the left heel whose threshold was set to $\alpha_{rightheel} = 0.25$ during the day and $\alpha_{rightheel} = 0.5$ at night. In Fig. 9, we describe the parameters of this model. We note that the decreasing degree of control points and the




Fig. 7. Basic postural protocol for 4 in-bed postures changed over two-hour time intervals.




Fig. 8. Dynamic protocol for extending the change time interval from two hours during the day to four hours at night.

Table 3

Average pressure degree per time unit for models A, B and C.

Body zone	Model A/B	Model C
Gluteus	0.38	0.38
Heel right	0.38	0.13
Heel left	0.38	0.38
Shoulder	0.38	0.38
Left hip	0.25	0.25
Right hip	0.25	0.25

notification threshold for the left heel would provide caregivers with more interpretable information on this body zone.

5. Discussion: limitations and strengths of deployment in a real-world environment

In this section, we discuss the limitations and strengths of the proposed methodology to be deployed in a real-world environment. First, we detail the strengths identified in real-time monitoring of postural changes for PU prevention using non-invasive inertial sensors:

- We use inertial micro-sensors to detect bed postures, which adhere to patients' clothes in a non-invasive way. The algorithm performs lightweight and optimized processing, which can be integrated into low-cost devices, since it does not require deep learning models. Among the wide spectrum of models, we focus on lightweight and efficient classifiers, which enable real-time training and evaluation on micro-boards in fog computing environments.
- Feature extraction by sliding windows is very agile (2.5 s). This has been shown to be suitable for evaluating inertia activity data and the delay in the response to estimating the classification is negligible. The set of features extracted from the inertial sensors included

maximum and minimum values, averages and standard deviation, which have proven to be efficient and suitable to describe inertial sensors in Activity Recognition (AR) and allow the identification and recognition of actions or objectives of the inhabitant. The alert system notifying caregivers does not require a critical response that is sensitive to delays in the communication process of sensors or in the classification of positions. A response time close to some minutes is more than enough and allows work in real time.

- The system does not require customization to obtain high performance, although customization of data is sensitive to decision tree-based classifiers and we observed that the best classification is obtained using customization. So, training data from the patient is key to improve precision performance in real conditions, which would require a shorter phase for pre-training the model.

Having discussed the strengths, it is also necessary to advance in solving certain limitations, issues and open challenges to deployment in real-world conditions:

- The case study carried out in this work was collected from 7 users in controlled environments at the University of Jaen. Although the postural changes of patients at risk of suffering PUs have been guided by rehabilitation experts, future works on patients without mobility will be developed in real conditions according to expert criteria in order to evaluate potential differences between subjects.
- The intelligent system integrates a battery that lasts 48 h. Therefore, support by medical staff is required to replace or recharge the inertial devices every two days and to avoid loss of data.
- One of the relevant points for the success of the project is training medical staff regarding the correct use of the technological devices in order to guarantee correct data collection and obtain the desired results. Staff training and their relationship with new technologies and devices can be a determining factor.

Nuevas metodologías para el reconocimiento de cambios posturales a través de sensores

E. Bernal Monroy, et al.

Journal of Biomedical Informatics 107 (2020) 103476




Fig. 9. Adapted protocol for preventing pressure over injured body zones.

- Taking into account that the proposed intelligent system is considered a tool to support medical staff decision-making, it does not present an intervention protocol considering that it does not comply with medical device regulations.

The device developed in this proposal is a decision support system with many benefits such as:

- Improving medical staff efficiency: the alert system allows them to monitor patient posture and times in real time.
- Speeding up the decision-making process: the device generates information that makes it possible to support patient diagnosis and treatment through the data analysis process.
- Faster problem solving: a specialized team can effectively monitor the study because they are getting data in real time.
- Convenience: it is a simple device that is easy to install and use by the end user.
- Improving internal organizational communication: it makes it easy to communicate relevant information with medical staff.
- Cost reduction for tasks that require decisions: the treatment of PUs can generate high costs for a medical institution; however, use of the device and timely data analysis can prevent the appearance of PUs, shortening patient hospital stays.
- The developed device does not require any technical knowledge for its use or installation.

5.1. Towards a clinical and technological deployment protocol for PU prevention

Future works could evaluate an inclusive care service model for preventing PUs at home based on the proposed methodology for patients and the involved stakeholders. However, in order to advance in the future deployment of the proposed system in real conditions,

involving the health systems, caregivers, clinicians and patients at risk of suffering pressure ulcers, we propose the following actions for the deployment of a PU prevention protocol integrated in the phases outlined below.

Phase 1: Defining the patients at risk of pressure ulcers. This phase consists of the following actions:

- Action 1: Defining and applying a patient assessment tool using the Braden Scale which allows the risk of developing pressure ulcers to be evaluated.
- Action 2: Previous approval from a research ethics committee, determining the number of participants, duration and supervision of clinical trials.
- Action 3: Sharing and signing voluntary consent forms containing personal data, information related to the project, the objective of the research study, the risks, procedures, and benefits of participating in the study.

Phase 2: Defining and classifying the patient care model with clinics and caregivers according to the devices designed in the system.

- Action 1: Designing the protocol according to the patient's condition. In this stage, it is important to consider the Braden scale to predict the risk of pressure ulcers, which identifies patients as: high risk, moderate risk or low risk.
- Action 2: Designing the levels of care or protocol according to the patient's score through the evaluation of different aspects such as sensory perception, exposure to moisture, activity, mobility, nutrition, friction and risk of injury.
- Action 3: Defining the type of alerts issued by the devices for each level of care. A notification in the information system will record the

time and position of the patient.

Phase 3: Design and implementation of service provision in the administrative structure of ulcer rehabilitation clinics and health systems. The system will be integrated with the clinical history of the patient to prevent it from being isolated under secure cloud services for health data, which is key in the development of Sensor-Based Health Systems [40].

- Action 1: Modeling the extramural service that incorporates the use of the device and system in the care provided within the institutional portfolio. Designing a medical protocol for use of the device and data collection at home is required for the proper functioning of the intelligent system.
- Action 2: Generation of medical performance indicators, such as reduction of hospital complications, adherence to treatment, service satisfaction, and administrative management indicators.

Phase 4: Training all the actors involved in the care of PU patients. It is relevant to make device manuals and train the medical team and caregivers to guarantee the proper functioning of the proposed system.

Phase 5: Continuing the evaluation and monitoring of the proposed model over 6 months, bearing in mind the previous phases, which is crucial.

- Action 1: Performing tests, applying the designed model, and using the devices created to verify the proper functioning of the system and make the appropriate adjustments.

Phase 6: Evaluation and monitoring the performance of the technological device. Ulcer rehabilitation experts have defined a checklist to validate the device.

- Action 1: Analysis and evaluation of the information obtained during the application of the proposed model.
- Action 2: Readjusting the parameters of the model which define the time and sequence of patient postural changes by clinicians on a personalized basis.

Finally, we note that in this work we propose the implementation of clinical decision support systems for the prevention of PUs. The support devices aim to aid healthcare professionals in decision-making and contribute to improving the interaction between scientific evidence and patient information. The data is presented in an organized way and is available for medical and nursing staff at the appropriate times and in order to improve the quality of care, patient safety and efficiency of hospital processes. This research study proposes a system that works as a clinical support tool, as it allows PU monitoring without interfering in treatment or diagnosis and does not satisfy the requirements of medical devices established by the World Health Organization.

Appendix A. Aggregating Fuzzy Temporal Windows and Terms

For a given body zone Z_z and fuzzy temporal window T_k , we define the fuzzy aggregation $Z_z \cup T_k$ in a given current time t^* as:

$$\begin{aligned} Z_z \cap T_k(t^*) &= Z_z(t^j) \cap T_k(\Delta t^*), \Delta t^* = t^* - t^j \\ Z_z \cup T^k(t^*) &= \bigcup_{t^j: t^j < t^*} Z_z \cap T_k(t^*) \end{aligned} \quad (A.1)$$

Using weighted average [29] as an operation to model the t-norm and co-norm, we obtain:

$$Z_z \cup T_k(t^*) = \frac{1}{\sum_{t^j \in t^j < t^*} T_k(\Delta t^j)} \sum_{t^j \in t^j < t^*} Z_z(t^j) \times T_k(\Delta t^j) \in \left[0, 1 \right] \quad (A.2)$$

6. Conclusions and ongoing works

In this work, a fuzzy monitoring system for postural changes which recognizes in-bed postures by means of non-invasive inertial sensors attached to patients' clothes has been proposed. First, an evaluation of six in-bed postures by inertial sensors attached to clothing has been performed. The case study shows excellent performance in classifying in-bed postures both in personalizing learning using individualized data for each user and unseen data among users. The performance of the SVM Support Vector Machine classifier is higher than 99%. Second, we have modeled three heterogeneous in-bed postural protocols under the knowledge-based fuzzy approach described in this work. From (i) a basic protocol for 4 in-bed postures changed over two-hour time intervals, we have modeled more complex real and practical contexts: (ii) a dynamic model for extending the change time interval from two hours during the day to four hours at night; and (iii) an adapted protocol for preventing pressure over injured body zones, where the use of attached inertial sensors has successfully described the orientation of patients' heels. Taking into account that the outcome was obtained using a low-cost device, in future work we will analyze the possibility of evaluating the device in other regions or developing countries. Moreover, we are working on attracting interested parties to provide patients so that we can carry out an evaluation of one or several protocols of postural changes within certain segments of patients. Finally, we will explore the application of multi-granular fuzzy linguistic approaches [41] to compare the findings of experts with different criteria on the modeling of postural changes.

CRedit authorship contribution statement

Edna Bernal Monroy: Investigation, Writing - review & editing, Formal analysis. **Aurora Polo Rodríguez:** Resources, Data curation, Formal analysis. **Macarena Espinilla Estevez:** Supervision, Validation, Funding acquisition. **Javier Medina Quero:** Methodology, Conceptualization, Writing - original draft.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgments

This contribution has been supported by the Andalusian Health Service by means of project PI-0387-2018. Furthermore, funding for this research is provided by EU Horizon 2020 with grant agreements No. 857188 and 734355. Finally, it has been supported by the Spanish government under RTI2018-098979-A-I00 and Action 1 of the University of Jaén EI-TIC1-2019.

Appendix B. Representation of fuzzy temporal windows using trapezoidal membership functions

Each FTW T_k is described by a trapezoidal function based on the time interval from a previous time t^j to the current time t^i : $T_k(\Delta t^j)[l_{-1}, l_{-2}, l_{-3}, l_{-4}]$ and a fuzzy set characterized by a membership function whose shape corresponds to a trapezoidal function. The well-known trapezoidal membership functions are defined by a lower limit l_{-1} , an upper limit l_{-4} , a lower support limit l_{-2} , and an upper support limit l_{-3} (refer to Eq. (B.1)):

$$TS(x) \begin{bmatrix} l_{-1}, l_{-2}, l_{-3}, l_{-4} \end{bmatrix} = \begin{cases} 0 & x \leq l_{-1} \\ (x - l_{-1}) / (l_{-2} - l_{-1}) & l_{-1} < x < l_{-2} \\ 1 & l_{-2} \leq x \leq l_{-3} \\ (l_{-4} - x) / (l_{-4} - l_{-3}) & l_{-3} < x < l_{-4} \\ 0 & l_{-4} \leq x \end{cases} \quad (B.1)$$

Appendix C. Representation of fuzzy quantifiers using control points

A control point is defined by a 2-tuple $Q^j = \{t^j, Q^j_{-} * \}$, where t^j is a point of time and $Q^j_{-} *$ is the degree of priority of postural change defined by the expert.

First, we compute the aggregation degree of the body zone $Z_{-} \cup T_k$ in the point of time t^j obtaining a new 2-tuple $Q^j = \{d^j, r^j\} = [Z_{-} \cup T_k(t^j), Q^j_{-} *]$.

Next, a linear interpolation $L(x, Q^j)$ of the control points defines the membership function $\mu_{-} Q_{-} q = L([Z_{-} \cup T_k(t^j), Q^j])$ which is defined from the domain $Z_{-} \cup T_k \in [0, 1]$ to the range of priority degree $[0, 1]$

$$L(x) = \begin{cases} 0 & x \leq d^0 \\ r^i + (x - d^i) / (r^i - d^i) & d^i x \leq d^{i+1} \\ 1 & d^N \leq x \end{cases} \quad (C.1)$$

References

- [1] M.S.P. Social, Herramientas para promover la estrategia de la seguridad del paciente en el sistema obligatorio de garantía de calidad de la atención en salud, Ministerio de salud gobierno de Colombia 65 (2007) 60–64.
- [2] P.L. Pancorbo-Hidalgo, F.P. García-Fernández, J.-E. Torra i Bou, J. Verdú Soriano, J. Soldevilla-Agreda, Epidemiología de las úlceras por presión en España en 2013: 4. estudio nacional de prevalencia, Gerokomos 25 (2014) 162–170.
- [3] U. Nations, Department of economic and affairs undesa. Population ageing, 2006.
- [4] X.-L. Zuo, F.-J. Meng, A care bundle for pressure ulcer treatment in intensive care units, Int. J. Nurs. Sci. 2 (2015) 340–347.
- [5] L. Demaré, A. Van Lancker, A. Van Hecke, S. Verhaeghe, M. Gryndonck, J. Lemey, L. Annemans, D. Beekman, The cost of prevention and treatment of pressure ulcers: a systematic review, Int. J. Nurs. Stud. 52 (2015) 1754–1774.
- [6] S. Sprigle, S. Sonnenblum, Assessing evidence supporting redistribution of pressure for pressure ulcer prevention: a review, J. Rehabil. Res. Dev. 48 (2011) 203–213.
- [7] T. Defloor, K. Vanderwee, T. Dassen, Pressure ulcer prevention and repositioning, in: Science and Practice of Pressure Ulcer Management, Springer, Basel, Switzerland, 2006, pp. 67–73.
- [8] J. Medina-Quero, S. Zhang, C. Nugent, M. Espinilla, Ensemble classifier of long short-term memory with fuzzy temporal windows on binary sensors for activity recognition, Expert Syst. Appl. 114 (2018) 441–453.
- [9] P. Sundaravadi, E. Kougiannos, S.P. Mohanty, M.K. Ganapathiraju, Everything you wanted to know about smart health care: Evaluating the different technologies and components of the internet of things for better health, IEEE Consum. Electron. Mag. 7 (2017) 18–28.
- [10] D.W. Kress, US Patent 4,554,930, U.S. Patent and Trademark Office, Washington, DC, 1985.
- [11] J. Rosser, G. Scott, G. Scott, US Patent App. 10/861,701, 2005.
- [12] O.B. Yáñez, J.R. Arieta, M.I.B. Bafaluy, J.J.C. Aguirre, Evaluación e impacto del uso de las tecnologías de la información y comunicación para la gestión clínica y seguimiento compartido y consensuado de las úlceras por presión, Revista Española de Geriatria y Gerontología 50 (2015) 179–184.
- [13] P. Kaikenger, R.L. Williamson, T.S. Ventrola, D.R. Tallent, I.L.S. Coleman, Stebbins, K.L. C. LAI, US Patent App. 15/822,532, 2018.
- [14] O. Moverte, Reloj control cambios posturales referencia 3948, 2006. Available online: <https://www.moverte.com/equipamiento-sociosanitario/3948-reloj-control-cambios-posturales.html>.
- [15] D. Gneupp, Grupo nacional para el estudio y asesoramiento en úlceras por presión, Revisión de febrero de 2019 (2003).
- [16] g. d. C. Sociedad para el desarrollo regional de Cantabria, Smart upp, sistema undesa. population ageing 2006 para la prevención de Úlceras por presión, 2019. Online: <https://www.smartupp.es/> (accessed on 10 March 2019).
- [17] Helcos, App: Sistema integrado para el manejo de heridas (helcos), 2019. Available online: <https://helcos.net/users/login>.
- [18] A. Pilatxi, H. Daniel, Sistema electrónico para asistir a pacientes en proceso de rehabilitación de úlceras por presión (bachelor's thesis universidad técnica de ambato. facultad de ingeniería en sistemas electrónica e industrial. carrera de ingeniería en electrónica y comunicaciones), 2018.
- [19] C.N. Aurora Polo Rodríguez, David Gil, J. Medina, In-bed pose classification from pressure mat sensors for the prevention of pressure ulcers using convolutional neural networks (2018) 11.
- [20] E.B. Monroy, D.Z. Romero, M.E. Estévez, F. Cruciani, I. Cleland, C. Nugent, J. Medina-Quero, Intelligent system for the prevention of pressure ulcers by monitoring postural changes with wearable inertial sensors, in: Multidisciplinary Digital Publishing Institute Proceedings, vol. 31, 2019, p. 79.
- [21] A. Fleury, M. Sugar, T. Chau, E-textiles in clinical rehabilitation: a scoping review, Electronics 4 (2015) 173–203.
- [22] F. Lin, A. Wang, Y. Zhuang, M.R. Tomita, W. Xu, Smart insole: A wearable sensor device for unobtrusive gait monitoring in daily life, IEEE Trans. Industr. Inf. 12 (2016) 2281–2291.
- [23] K. Jedrasiak, K. Daniec, A. Nawrat, The low cost micro inertial measurement unit, in: 2013 IEEE 8th Conference on Industrial Electronics and Applications (ICIEA), IEEE, 2013, pp. 403–408.
- [24] Tactigon, The Tactigon ONE, www.thetactigon.com/, 2020 [Online; accessed 1-02-2020].
- [25] O. Banos, J.-M. Galvez, M. Damas, H. Pomares, I. Rojas, Window size impact in human activity recognition, Sensors 14 (2014) 6474–6499.
- [26] M. Espinilla, J. Medina, A. Salguero, N. Irvine, M. Donnelly, I. Cleland, C. Nugent, Human activity recognition from the acceleration data of a wearable device. which features are more relevant by activities?, in: Multidisciplinary Digital Publishing Institute Proceedings, vol. 2, 2018, p. 1242.
- [27] M.B. Pouyan, J. Birjandtalab, M. Heydarzadeh, M. Nourani, S. Ostadabbas, A pressure map dataset for posture and subject analytics, 2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI), IEEE (2017) 65–68.
- [28] M.Á. López Medina, M. Espinilla, C. Paggeti, J. Medina Quero, Activity recognition for iot devices using fuzzy spatio-temporal features as environmental sensor fusion, Sensors 19 (2019) 3512.
- [29] J. Medina, L. Martínez, M. Espinilla, Subscribing to fuzzy temporal aggregation of heterogeneous sensor streams in real-time distributed environments, Int. J. Commun. Syst. 30 (2017) e3238.
- [30] J. Medina, M. Ruiz-Lozano, M. Delgado, A. Vila, A fuzzy temporal rule-based system for handling the nursing process on mobile devices, Expert Syst. Appl. 39 (2012) 10479–10488.
- [31] W. Dong, F. Wong, Fuzzy weighted averages and implementation of the extension principle, Fuzzy Sets Syst. 21 (1987) 183–199.
- [32] L.A. Zadeh, A computational approach to fuzzy quantifiers in natural languages, in: Computational linguistics, Elsevier, 1983, pp. 149–184.
- [33] M.D. Peláez-Aguilera, M. Espinilla, M.R. Fernández Olmo, J. Medina, Fuzzy linguistic protoforms to summarize heart rate streams of patients with ischemic heart disease, Complexity 2019 (2019).
- [34] J. Medina, M. Espinilla, Á. García-Fernández, L. Martínez, Intelligent multi-dose medication controller for fever: From wearable devices to remote dispensers, Comput. Electr. Eng. 65 (2018) 400–412.
- [35] K.D. Duncan, Preventing pressure ulcers: the goal is zero, The, Joint Commis. J. Quality Patient Saf. 33 (2007) 605–610.

Nuevas metodologías para el reconocimiento de cambios posturales a través de sensores

E. Bernal Monroy, et al.

Journal of Biomedical Informatics 107 (2020) 103476

- [36] C. Searle, F. McInerney, Nurses' decision-making in pressure area management in the last 48 hours of life, *Int. J. Palliative Nurs.* 14 (2008) 432–438.
- [37] M. Clark, Repositioning to prevent pressure sores—what is the evidence?, *Nursing Standard* (through 2013) 13 (1998) 58.
- [38] Y. Yoshikawa, N. Maeshige, M. Sugimoto, M. Uemura, M. Noguchi, H. Terashi, Positioning bedridden patients to reduce interface pressures over the sacrum and great trochanter, *J. Wound Care* 24 (2015) 319–325.
- [39] F. Collins, Sitting: pressure ulcer development, *Nursing Standard* (through 2013) 15 (2001) 54.
- [40] M.D. Peláez, M. López-Medina, M. Espinilla, J. Medina-Quero, Key factors for innovative developments on health sensor-based system, in: *International Conference on Bioinformatics and Biomedical Engineering*, Springer, 2017, pp. 665–675.
- [41] F.J. Cabrerizo, J.A. Morente-Molinera, W. Pedrycz, A. Taghavi, E. Herrera-Viedma, Granulating linguistic information in decision making under consensus and consistency, *Expert Syst. Appl.* 99 (2018) 83–92.

**A.5.3. UJA Human Activity Recognition multi-occupancy
dataset**

UJA Human Activity Recognition multi-occupancy dataset

Emiro De-la-Hoz-Franco
Universidad de la Costa –
CUC
edelahoz@cuc.edu.co

Edna Rocio Bernal Monroy
Universidad Nacional
Abierta y a Distancia -
UNAD
edna.bernal@unad.edu.co

Paola Ariza-Colpas
Universidad de la Costa –
CUC
pariza1@cuc.edu.co

Fabio Mendoza-Palechor
Universidad de la Costa – CU
fmendoza1@cuc.edu.co

Macarena Espinilla Estévez
Universidad de Jaén
mestevez@ujaen.es

Abstract

Activity Recognition Systems - ARS are proposed to improve the quality of human life. An ARS uses predictive models to identify the activities that individuals are performing in different environments. Under data-driven approaches, these models are trained and tested in experimental environments from datasets that contain data collected from heterogeneous information sources. When several people interact (multi-occupation) in the environment from which data are collected, identifying the activities performed by each individual in a time window is not a trivial task. In addition, there is a lack of datasets generated from different data sources, which allow systems to be evaluated both from an individual and collective perspective. This paper presents the SaMO – UJA dataset, which contains Single and Multi-Occupancy activities collected in the UJAmI (University of Jaén Ambient Intelligence, Spain) Smart Lab. The main contribution of this work is the presentation of a dataset that includes a new generation of sensors as a source of information (acceleration of the inhabitant, intelligent floor for location, proximity and binary-sensors) to provide an excellent tool for addressing multi-occupancy in smart environments.

1. Introduction.

A very high percentage of people use the Home Help Service (HHS) in Spain, they are elderly people who present a state of frailty or have a significant risk of suffering it in the future. HHS is based on the approach

of keeping older people in their usual environment for as long as possible, covering those needs that may arise from situations of dependency. The HHS offers personal help and a series of services at home to people who have a certain level of dependency or who suffer a personal or family crisis. With this service it is intended that this person has an adequate degree of independence or autonomy in carrying out activities of daily life. And although it is not an exclusive service for the elderly, around 90% of the users of it are.

The basic objective of HHS is to increase personal autonomy in the usual way of life, it aims to develop to the maximum the possibilities of the elderly person to continue controlling their own life, even if it is someone who is dependent for certain activities of daily life. It is a service that is practically implemented in all municipalities, which is well known and highly valued by users and their families, and has proven its usefulness in guaranteeing the quality of life of the elderly.

In this proposal we set ourselves the objective of deepening the knowledge of the recognition Activities of Daily Life (ADL) and Recognition of Human Activities (HAR) as a solution that can help the monitoring of daily activities at home as a support to improve the quality of life of the elderly people.

The recognition ADL or HAR in assisted living indoor environments is an important basic service that requires the attention of researchers. From this line of research, different functional applications can be found that improve elderly people's quality of life. Therefore, as a baseline of research that supports future applied developments, it is necessary to recognize ADL in indoor environments.

The scenario becomes much more complex when in such environments several inhabitants interact simultaneously (multi-resident or multi-occupancy environments). Now days, there are very few multi-

occupancy datasets and even fewer generated from heterogeneous data sources. It is evident that merging heterogeneous data sources to obtain data sets is a complex task due to the heterogeneity and complexity of the data to be integrated [1,2]. Additionally, after a thorough review of the state of the art, the existence of a dataset that labels activities on two levels of granularity (detailed and general) has not been evidenced. The SaMO - UJA dataset; proposed in this study, presents a solution to these two situations: the integration of heterogeneous data and labelling of data instances on two levels of granularity.

The presented datasets will be a key tool to assess the performance of activity recognition approaches in an experimental context and build and apply models that facilitate HAR in real scenarios, seeking to improve people's quality of life. Such models are classified into Data-Driven Approaches (DDA) and Knowledge-Driven Approaches (KDA). Learning techniques are in the context of DDA. These approaches use a dataset with sensor data streams generated in a smart environment [3,37,39, 40]. Expert knowledge are in the context of KDA [4,35,36, 38]. These approaches use domain knowledge, ontologies or rule-based models to perform activity recognition.

A systematic review of literature on sensor-based datasets was presented in [5]. Seven datasets were identified as the most widely used in the recognition of ADL: VanKasteren [6], CASAS Kyoto [7], CASAS Aruba [8], CASAS Multi-resident [9], UCI-HAR [10], Opportunity [11] and mHealth [12]. From these, only CASAS Aruba and CASAS Multi-resident are multi-occupancy and the Opportunity dataset is interleaved. In [5], a detailed compilation and analysis of the research based on the seven aforementioned datasets was presented, indicating for each of them: segmentation techniques, feature representation, classification, feature selection and quality metrics evaluated.

In this work, we present a multi-occupancy dataset called SaMO - UJA, which was collected in the UJAmI Smart Lab [34]. This dataset includes a new generation of sensors with heterogeneous data sources to provide a new point of view on the multi-occupancy problem. Concretely, we have included four information sources (binary sensors in some objects in the space, proximity between the inhabitant and the Bluetooth Low Energy (BLE) beacons in the space, acceleration of the inhabitant with the wearable device and intelligent floor for location) collected using different sensor technologies. The SaMO - UJA dataset is integrated by a Single-occupancy dataset, with data over 10 days, and a Multi-occupancy dataset, with data over 9 days, in total integrating 19 days of data collected in three sessions per day (morning, afternoon and night). The SaMO - UJA dataset contains 25 different types of

activities grouped into 7 categories. There is a total of 620 activities (451 multi-occupancy and 169 single-occupancy).

This paper is organized into five sections: section 2 contains related works, section 3 outlines the proposed methodology, section 4 describes the process of data preparation, Section 5 contains conclusions and future works. Finally, the acknowledgments and references are presented.

2. Related research.

In the work [13], International Conference on Ubiquitous Computing and Ambient Intelligence UCAmI Cup is presented as a single-inhabitant dataset for researchers to analyze HAR using different machine learning methods and comparing their results with others colleagues. In the 1st UCAmI Cup, 26 authors from ten countries obtained the dataset.

This dataset integrated multiple activities of a single inhabitant in a smart lab at the University of Jaén (Spain) with a heterogeneous set of devices with sensors. The most relevant proposals were based on the techniques: bagging classifier [14], finite state machine [15], filtered classifier [16], finite automata and regular expressions [17], naive Bayes classifier [18] and hidden Markov model + definition-based model [19].

In [14], the dataset was processed using six classification methods (Decision Tree (C4.5), 1 Nearest-Neighbor (1-NN), Support Vector Machine SVM, random forest, AdaBoostM1 and bagging), developing the Cross Industry Standard Process for Data Mining methodology. In this experimentation, the accuracy in the recognition of the 24 activities was 92.10% with an evaluation model based on 10-fold cross validation. However, an accuracy of 60.10% was achieved on the test dataset.

A finite state machine is proposed in [15], carrying out activity recognition by means of binary sensor data. The presented model obtained a precision of 81.30%. To do so, a small subset of operations was used, providing an appropriate approach to the resource-constrained devices that are common in intelligent environments.

A method based on fusion was presented in [16], fusion is presented both at the feature level and at the decision level for heterogeneous sensors by pre-processing and predicting activities in the context of training and test data sets using filtered classifiers. The proposed fusion method obtained 94.00% precision for training dataset and 47.00% accuracy for test dataset.

In [17] was presented a method based on the user's behavioral models and activity sensor models in order to build weighted finite automata with regular expressions. So, the location of the inhabitant was obtained for each activity by means of the floor sensor

data. This proposal achieved 90.65% precision in the test dataset.

A multi-event naive Bayes method was proposed in [18] for recognizing activities in real time. 24 types of activities were classified and the results obtained show a performance of true positives around 68.00%.

A hybrid method was presented in [19] that mixes a probabilistic model and a definition-based model. The probabilistic model is based on Hidden Markov Model with a neural network. The results obtained were not very promising as they reached an accuracy of 45.05%.

In our study, we present a new multi-occupation dataset that have been carried out in the UJAml Smart Lab of the University of Jaén where a heterogeneous set of sensors collect environmental information.

This new dataset complements the initial dataset presented in [13] with new instances of activities that are carried out simultaneously by two inhabitants at the same time. We shall refer to this integrated dataset as the “Single and Multi-Occupation dataset”, which we will call SaMO - UJA. Currently the identification of ADL in multi-resident indoor environments (also called multi-occupancy) has not been widely studied. The best-known multi-resident datasets are those that have been generated from the CASAS project [7] (Aruba [8], Cairo [20], Twor [20], Tulum [20] and ADL multi-resident [9]) and the ARAS dataset [21]. The ARAS dataset implies two datasets generated in two apartments, recording data over 1 month for two inhabitants.

Different studies are described below in which the multi-resident dataset of the CASAS family and the ARAS dataset have been evaluated, using several techniques for activity recognition. For example, a classifier based on Red Green Blue (RGB) activity image by using a Deep Convolutional Neural Network [22], Probabilistic Support Vector Machine [23], a method focused on dynamic Bayesian networks [24] and Random Forest [2, 25]. In addition, in [26-27] a complementary study is presented, which proposes the annotation of multi-resident datasets using the Long Short Term Memory method.

A very relevant issue in the recognition of activities is the unobtrusive and non-invasiveness of the devices in the smart environment [22]. For this reason, the authors proposed the use of RGB activity image by using the Cairo open dataset offered by the CASAS Project. Cairo was generated while two inhabitants with a pet were living for 55 days in a smart home. The results were very promising due to the fact that they reached up to 95.2% accuracy. This required pre-processing of the data, segmentation of activities and multi-conversion of images.

A method based on windows was presented in [23] to classify human activities for multiples inhabitant in smart environments. To do so, the presented methods

are focused on the study of sensor data stream in order to detect the sensors most relevant to each specific window. Multiple spatial-temporal statistical features were processed to classify human activities. The data set used to test the presented method was the CASAS dataset (Aruba and Twor) as well as an artificial dataset by using the High-Bandwidth Motion Simulator (HBMS) simulator. A comparative study was conducted using multiple classifiers (SVM, Naive Bayes, logistic regression and Recurrent Neural Network (RNN)), the best accuracy was 92.0% with the P-SVM classifier with the HBMS dataset

A rule-based method to identify complex activity was proposed in [2] in a multi-inhabitant context in smart environments. The proposed method was based on a multi-label classification technique, using as base classifier an extension of the random forest method that generated the Enhanced Label Combination method. This proposal was tested by using the ADL Multi-resident dataset from CASAS of Washington State University (WSU) [20]. The main advantage of this proposal is its capability to address conflicts in the complex activity recognition in multi-inhabitant contexts with parallel as well as cooperative activities. The accuracy obtained reached up to 70.3% in the dataset used. Furthermore, a multi-label classifier was proposed to recognize the actions and monitoring the inhabitant in a multi-occupancy context [1] in the same dataset, obtaining 71.7% accuracy.

A method based on the approaches of multi-task learning and zero-shot learning was proposed in [28] to address the multi-occupancy context in smart environments. To do this, this method considers each activity of each inhabitant as a learning action, and learns all actions.

Multiple methods were proposed and compared in [21] with the ARAS datasets: Respective method for each inhabitant, the Cartesian product and average prototype method, Cartesian product and concatenation prototype model and, finally, multi-inhabitant with Unseen-Activity-Class recognition method with class tags, the highest accuracy obtained was 64.27% when applying this last method.

Dynamic Bayesian networks was proposed in [24] by using an extension of the Coupled Hidden Markov Models. To do so, vertices are added to the model to include single activities as well as multi-occupancy activities. The proposed method was tested using the multi-inhabitant dataset CASAS [7], identifying sensor events with associations as well as expert knowledge to recognize multiple-resident activities.

A comparative study is conducted in [25] with multi-inhabitant activity datasets: ARAS dataset (HouseA and HouseB) [21], Tulum2 dataset and Cairo dataset. The best method was the tree ensemble with

random forests by means of multi-label learning. The methods compared in [23] were evaluated using the following four metrics: F-macro, F-micro, hamming loss and subset loss.

The multi-occupancy Aruba dataset was used [26-27] to propose a Long Short Term Memory model in order to perform annotations and identify characteristics. The authors proposed the use of multiple classical methods: logistic regression, SVM, multinomial naive Bayes and, finally, Gaussian naive Bayes to classify the activities in the new generated dataset. The accuracy achieved was 79.5%.

On the other hand, an example of feature extraction can be by sliding windows [28] is very agile (2.5 s). This has been shown to be suitable for evaluating inertia activity data and the delay in the response to estimating the classification is negligible. The set of features extracted from the inertial sensors included maximum and minimum values, averages and standard deviation, which had proven to be efficient and suitable to describe inertial sensors in Activity Recognition (AR) and allow the identification and recognition of actions or objectives of the inhabitant.

Most of these studies present datasets, some annotated others not, collected from binary sensors and proximity sensors. In our proposal, we present and evaluate an annotated dataset containing ADL collected in a multi-resident environment from four data sources (binary sensors in some objects in the space, proximity between the inhabitant and the BLE beacons in the space, acceleration of the inhabitant with the wearable device and intelligent floor for location). This paper introduces a novel dataset analysis that includes a new generation of sensors as a source of information call SaMO. Some of the advantages that can be highlighted with respect to our work are:

- The proposal includes the use of sensors together with the definition of a wide range of HAR in multiple occupancy conditions.
- Uses different technologies and sources of information,
- It integrates 30 sensors, 15 BLE beacons, wearable devices and Smart Lab Floor with 40 models which generate heterogeneous data.
- Two levels of class labeling are defined for the recognition of activities, which allowed the identification of 25 types of activities grouped into 7 categories.


According to the revised literature, none of them generate datasets from four data sources, in addition, most of them use binary sensors, accelerometer and gyroscope, none of them contain an intelligent floor for the location.

3. Methodology.

In this proposal, single and multi-occupation activities (SaMO – UJA dataset) are integrated in the labeled dataset by means of heterogeneous data sources generated in the UJAml Smart Lab of the University of Jaén [34]. Four data sources make up the sensor information:

- 1) Sensor data stream generated by 30 binary sensors that were located, categorized into three sensor types: wireless magnetic sensor that works with the Z-Wave protocol (detecting opening and closing of doors, and use of TV remote control, medicine box or bottle of water); wireless PIR motion sensor that works with the ZigBee protocol (detecting whether an inhabitant has moved inside or outside a range of 7 meters from the sensor with a sample rate of 5 seconds) and wireless pressure sensor that works with the Z-Wave protocol (detecting pressure when the inhabitants use the sofa, chairs or bed).
- 2) Location information generated by a set of 15 BLE beacons [29] as well as a wearable device worn by inhabitants. The BLE beacons model sticker was estimated [30] for proximity with a sample frequency of 0.25 Hz. The wearable device reads the Received Signal Strength Indicator (RSSI) from several BLE beacons, to identify the proximity between the inhabitant and, for example, a beacon located on the toothbrush or the medicine box.
- 3) Acceleration data generated from the same wearable device. The acceleration of the inhabitant data collected through an Android application installed on the wearable device [31] of the inhabitant with a sample frequency of 50 Hz (acceleration data of the inhabitant collected in three axes expressed by meter per second squared).
- 4) Location data generated by the smart lab floor with 40 modules that provides location data. SensFloor® [32] that consists of a suite of capacitive sensors (formed by 40 modules that are distributed into a matrix with 4 rows and 10 columns, each module composed of eight sensor fields).

Of the seven datasets mentioned above and detailed in [5], as the most widely used in the recognition of ADL, none are generated from four data sources. Most of them are generated from binary sensors, accelerometers and gyroscope. None contains an intelligent floor for location and although some of them mention the use of motion sensors [7-9], there is no evidence that they are BLE beacons. Our work features the use of these sensors together with the definition of a wide range of HAR under multi-occupancy conditions.

**Figure 1. Applied methodology.**

As indicated in Figure 1, the data were collected and debugged, reducing the time in which no relevant activities were carried out. For feature representation, a sliding window with a fixed size of 30 seconds was established. The resulting dataset was randomly distributed into two datasets: one for training, with 70% of the data instances and another for testing with 30%. In order to reduce the amount of data, different feature selection techniques were applied within each dataset.

4. Data preparation.

Single and multi-occupation datasets were collected in the UJAmI SmartLab, the dataset is publicly available in <https://cutt.ly/qf5MuZw> and contain data from four sources (acceleration of the inhabitant, intelligent floor for location, proximity and binary-sensors). The single-occupation dataset [13] contains 246 activity instances collected over 10 days. The dataset was divided into two sets: training and test. The subset used for training contains 169 instances recorded over seven days and the subset used for testing contains 77 instances recorded over three days. The multi-occupation dataset contains 451 activity instances collected over 9 days. Just like in the single-occupation dataset, data was collected for each day in the morning, afternoon and evening sessions. Table 1 contains a count of activities of the multi-occupation dataset and the single-occupation datasets by activity type.

Table 1. Integration of single/ multi-occupation dataset activities – Training set (7 days)

Activity	Multi-occupation	Single	Total
Shower	91	6	97
Brush teeth	43	21	64
Use toilet	33	10	43
Get dressed	17	15	32
Take medicine	6	7	13
Dinner	18	7	25
Lunch	18	6	24

Breakfast	16	7	23
Take snack	7	5	12
Prepare breakfast	15	7	22
Prepare dinner	12	7	19
Prepare lunch	14	6	20
Go home	9	12	21
Leave home	3	9	12
Visit in the SmartLab	0	1	1
Sleep	18	14	32
Relax on sofa	32	1	33
Play videogame	29	1	30
Read book	9	0	9
Watch TV	28	6	34
Work at table	8	2	10
Do dishes	10	2	12
Put washing machine on	7	6	13
Take out trash	8	0	8
Throw waste in bin	0	11	11
Total	451	169	620

After integrating and debugging the datasets, the data instances of the four information sources were grouped into sliding windows of 30 seconds. For the single-occupation dataset, 1529 instances were generated and 3249 for the multi-occupation dataset. The activities were grouped by categories, according to their affinity and the total activities were calculated by category, see Table 2.

Table 2. Description data using a 30 second sliding window

Category	Activities	Multi-occup.	Single-occupation	Total	
				Act.	N.
Personal care and cleaning	Shower	237	24	261	
	Brush teeth	151	100	251	8
	Use toilet	76	28	104	2
	Get dressed	67	84	151	7
	Take medicine	23	37	60	
Have food	Dinner	146	127	273	8
	Lunch	186	110	296	2
	Breakfast	115	97	212	0
	Take snack	26	13	39	
Food preparation	Prepare breakfast	94	66	160	6
	Prepare dinner	109	84	193	6
	Prepare lunch	168	145	313	6
	Go home	25	41	66	1
Out of home	Leave home	9	35	44	1
	Visit in the SmartLab	0	4	4	4

Rest	Sleep	100	92	2	192	7
	Relax on sofa	399	499	140	3	539
Entertainment	Play videogame	541	121	30	2	571
	Read book	141	8	0	0	141
	Watch TV	408	106	7	514	2
	Work at table	128	71	199	5	
Domestic cleaning	Do dishes	34	12	46		
	Put washing machine on	29	16	45		
	Take out trash	37	100	9	5	37
	Throw waste in bin	0	67	67		
Total		3249	1529	4778		

For each of the data sources of the dataset, the following description feature representation was generated in the sliding windows. First, the inhabitant acceleration data (see table 3) are structured into timestamp, device, X, Y and Z columns. The last three correspond to the acceleration measurements in the spatial axes. For each of the three axes a feature representation was generated from the following calculations [33]: arithmetic mean, range, standard deviation, skewness and kurtosis.

Table 3. Excerpt from an acceleration of the inhabitant

TIMESTAMP	DEV.ID	X	Y	Z
2018/01/16 11:13:01.766	d36b03135c9	-0.36474	-6.83032	10.0050
2018/01/16 11:13:01.767	d36b03135c9	-1.0990906	-4.79272	8.4983
2018/01/16 11:13:01.768	d36b03135c9	-0.73965	-3.5930	9.4552
2018/01/16 11:13:01.780	d36b03135c9	-0.52661	-4.0048	9.4111

Second, capacitance data (see Table 4) are obtained from the intelligent floor for location, by the individuals' interaction with it (see Fig 2). The data are structured into timestamp, device and capacitance value. As the feature representation for the intelligent floor for location data, we include the count of times that each tile was activated in the sliding window.

Table 4. Excerpt from an intelligent floor for location

TIMESTAMP	DEV	CAPACITANCE							
16/01/2018 11:14:44	3,04	4	4	5	1	7	0	2	1
16/01/2018 11:14:44	4,04	0	-2	-1	-1	0	0	4	-1
16/01/2018 11:14:44	1,07	-1	0	-1	-2	1	0	-	1
16/01/2018 11:14:44	3,04	-	4	1	1	1	1	3	7




Figure 2. Layout of the intelligent floor for location in the UJAmI SmartLab [24].

Third, user proximity to objects and rooms (see table 5) was obtained from the Received Signal Strength between the wearable device worn by the individual and BLE beacon objects. The location of BLE objects within the smart lab are shown in the indoor environment (see Fig 3). Proximity data is structured into timestamp, device ID, ID, object and RSSI columns. RSSI is used to generate the feature representation of proximity. The features computed from the RSSI of each smart object in the sliding window are: arithmetic mean, range and standard deviation.

Table 5. Excerpt from a proximity

TIMESTAMP	DEV.D	ID	OBJECT	RSSI
2018/01/16 11:13:01.929	.30586a1-e1f0-382f-	472c1	BED	-93
2018/01/16 11:13:07.314	.30586a1-e1f0-382f-	b141ab	FRIDGE	-99
2018/01/16 11:13:12.579	.30586a1-e1f0-382f-	472c18	BED	-71
2018/01/16 11:13:12.580	.30586a1-e1f0-382f-	b141ab	FRIDGE	-97




Figure 3. Layout of the BLE beacons in the UJAmI SmartLab.

Fourth, the data from binary sensors (see Table 6) collected in the smart lab identify the interactive events between individuals and sensors. 30 binary sensors were deployed in the indoor environment (see Fig 4).

The data from binary sensors is structured into timestamp, object and state columns. The possible values of the latter depend on sensor type: magnetic contact (open or closed), motion (movement or no movement) and pressure (pressure or no pressure).

In order to translate this information into feature representation, the count of activations (open, movement or pressure) for each object was computed in the respective sliding window.

Table 6. Excerpt from a binary-sensors

TIMESTAMP	OBJECT	STATE
2018/01/16 11:12:48.0	SM4	Movement
2018/01/16 11:13:04.0	SM4	No movement
2018/01/16 11:13:48.0	SM4	Movement
2018/01/16 11:13:58.0	SM4	No movement
2018/01/16 11:13:59.0	SM4	Movement
2018/01/16 11:14:53.0	C09	Open
2018/01/16 11:15:05.0	C09	Close




Figure 4. Layout of the binary sensors in the UJAmI SmartLab.

Following, we describe the id sensors with the objects that are illustrated in Figure 4: M01 Door, TV0 TV, SM1 Motion sensor–Kitchen, SM3 Motion sensor–bathroom, SM4 Motion sensor–bedroom, SM5 Motion sensor–sofa, D01 Refrigerator, D02 Microwave, D03 Wardrobe, D04 Cupboard cups, D05 Dishwasher, D07 Top WC, D08 Closet, D09 Washing machine, D10 Pantry, H01 Kettle, C01 Medication box, C02 Fruit platter, C03 Cutlery, C04 Pots, C05 Water bottle, C07 Remote XBOX, C08 Trash, C09 Tap, C10 Tank, C12 Laundry basket, C13 Pyjamas drawer, C14 Bed, C15 Kitchen faucet and, finally, S09 Pressure sofa

The integration of several data sources, through the timestamp field, allowed us to generate the fixed time windows and the feature representation generated from the raw features. The resulting SaMO – UJA dataset has 4778 data instances with 134 features, identifying the category as the class criterion (see Table 7).

Table 7. Dataset structure - feature representation of the SaMO – UJA dataset

Sources	Raw features	Generated features	Description
All	Timestamp	Time	Window set in 30 seconds (one feature)
Acceleration of the inhabitant	X, Y and Z	Xmean, Xrank, Xstd, Xskew, Xkur, Ymean, Yrank, Ystd, Yskew, Ykur, Zmean, Zrank, Zstd, Zskew and Zkur.	Arithmetic Mean, range, standard deviation, Skewness and kurtosis (15 features)
Intelligent floor for location	Device	F1_1, F1_2, F1_3, F1_4, F1_5, F1_6, F1_7, F1_8, F1_9, F1_10, F2_1, F2_2, F2_3, F2_4, F2_5, F2_6, F2_7, F2_8, F2_9, F2_10, F3_1, F3_2, F3_3, F3_4, F3_5, F3_6, F3_7, F3_8, F3_9, F4_1, F4_2, F4_3, F4_4, F4_5, F4_6, F4_7, F4_8, F4_9, F5_6 and F5_7.	Counting by contact with tile (40 features)
Proximity	Object, RSSI	1_Book_mean, 1_Book_rank, 1_Book_std, 2_TV_controller_mean, 2_TV_controller_rank, 2_TV_controller_std, 3_Entrance_door_mean, 3_Entrance_door_rank, 3_Entrance_door_std, 4_Medicine_box_mean, 4_Medicine_box_rank, 4_Medicine_box_std, 5_Food_cupboard_mean, 5_Food_cupboard_rank, 5_Food_cupboard_std, 6_Fridge_mean, 6_Fridge_rank, 6_Fridge_std, 7_Pot_drawer_mean, 7_Pot_drawer_rank, 7_Pot_drawer_std, 8_Water_bottle_mean, 8_Water_bottle_rank, 8_Water_bottle_std, 9_Garbage_can_mean, 9_Garbage_can_rank, 9_Garbage_can_std, 10_Wardrobe_door_mean, 10_Wardrobe_door_rank, 10_Wardrobe_door_std, 11_Pyjamass_drawer_mean, 11_Pyjamass_drawer_rank, 11_Pyjamass_drawer_std, 12_Bed_mean, 12_Bed_rank, 12_Bed_std, 13_Bathroom_tap_mean, 13_Bathroom_tap_rank, 13_Bathroom_tap_std, 14_Toothbrush_mean, 14_Toothbrush_rank, 14_Toothbrush_std, 15_Laundry_basquet_mean, 15_Laundry_basquet_rank and 15_Laundry_basquet_std.	Arithmetic Mean, range and standard deviation by object (45 features)
Binary sensors	Object, state	M01, TV0, SM1, SM3, SM4, SM5, D01, D02, D03, D04, D05, D07, D08, D09, D10, H01, C01, C02, C03, C04, C05, C07, C08, C09, C10, C12, C13, C14, C15 and S09.	Count by object (30 features)
	Inhabitant		One feature
	Activity	Category and activity	Two features
Total			134 features

5. Conclusions.

This paper presented the SaMO – UJA dataset, which contains Single and Multi-Occupancy activities, collected in the UJAml Smart Lab of the University of Jaén (Spain) from different sensor technologies and information sources: binary sensors in some objects in the space, proximity between the inhabitant and the BLE beacons in the space, acceleration of the inhabitant with the wearable device and intelligent floor for location.

The SaMO - UJA dataset has two levels of class labelling for the identification of activities: a level with greater granularity called activity (shower, brush teeth, use toilet, get dressed and take medicine, among others), which allows us to represent a total of 25 different types of activities, and a more general level called category (personal care and cleaning, have food and food preparation, among others), which groups the aforementioned activities into seven major categories.

Our future works are focused on presenting different models for learning HAR based on the sensor information and features described in the previous section. In order to evaluate the impact of different configurations in machine learning methods, we developed several case studies with the SaMO – UJA dataset.

Acknowledgements.

This research has received funding under the REMIND project Marie Skłodowska-Curie EU Framework for Research and Innovation Horizon 2020, under Grant Agreement No. 734355. Furthermore, this contribution has been supported by the Spanish Government by RTI2018-098979-A-I00 and the University of Jaén by EI_TIC1_2019.

References.

- [1] R. Mohamed, T. Perumal, M. Sulaiman and N. Mustapha, "Multi-resident activity recognition using label combination approach in smart home environment," IEEE International Symposium on Consumer Electronics (ISCE), Kuala Lumpur, 2017, pp. 69-71, doi: 10.1109/ISCE.2017.8355551.
- [2] R. Mohamed, T. Perumal, M. Sulaiman, N. Mustapha and M. Razali, "Conflict resolution using enhanced label combination method for complex activity recognition in smart home environment," IEEE 6th Global Conference on Consumer Electronics (GCCE), Nagoya, 2017, pp. 1-3, doi: 10.1109/GCCE.2017.8229477.
- [3] J. Medina, S. Zhang, C. Nugent, M. Espinilla. "Ensemble classifier of Long Short-Term Memory with Fuzzy Temporal Windows on binary sensors for Activity Recognition" in Expert Systems with Applications, vol. 114, 2018 pp. 441-453, doi: 10.1016/j.eswa.2018.07.068.
- [4] A. Salguero, M. Espinilla, P. de la Torre, J. Medina "Using Ontologies for the Online Recognition of Activities of Daily Living" in Sensors, vol. 18, n.º 4., 2018. doi: 10.3390/s18041202.
- [5] E. De-La-Hoz-Franco, P. Ariza-Colpas, J. M. Quero and M. Espinilla, "Sensor-Based Datasets for Human Activity Recognition – A Systematic Review of Literature," in IEEE Access, vol. 6, 2018 pp. 59192-59210, doi: 10.1109/ACCESS.2018.2873502.
- [6] T. L. M. van Kasteren, G. Englebienne, and B. J. A. Kröse, "Activity recognition using semi-Markov models on real world smart home datasets," J. Ambient Intell. Smart Environ., vol. 2, no. 3, Aug. 2010, pp. 311–325 doi: 10.3233/AIS-2010-0070.
- [7] D. J. Cook, A. S. Crandall, B. L. Thomas and N. C. Krishnan, "CASAS: A Smart Home in a Box," in Computer, vol. 46, no. 7, July 2013, pp. 62-69, doi: 10.1109/MC.2012.328.
- [8] D. Cook, "Learning Setting-Generalized Activity Models for Smart Spaces," in IEEE Intelligent Systems, vol. 27, no. 1, Jan.-Feb. 2012, pp. 32-38, doi: 10.1109/MIS.2010.112.
- [9] G. Singla, D.J. Cook, and M. Schmitter-Edgecombe, "Recognizing independent and joint activities among multiple residents in smart environments," J. Ambient Intell. Humanized Comput., vol. 1, no. 1, 2010, pp. 57–63, doi: 10.1007/s12652-009-0007-1.
- [10] D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, "A public domain dataset for human activity recognition using smartphones," in Proc. 21th Eur. Symp. Artif. Neural Netw., Comput. Intell. Mach. Learn. (ESANN), Bruges, Belgium, Apr. 2013, pp. 437–442.
- [11] R. Chavarriaga et al., "The opportunity challenge: A benchmark database for on-body sensor-based activity recognition," Pattern Recognit. Lett., vol. 34, no. 15, Nov. 2013, pp. 2033–2042, doi: 10.1016/j.patrec.2012.12.014.
- [12] O. Banos et al., "mHealthDroid: A novel framework for agile development of mobile health applications," in Proc. 6th Int. Workshop Conf. Ambient Assist. Living (IWAAL), Belfast, U.K., Dec. 2014, pp. 91–98, doi: 10.1007/978-3-319-13105-4_14.
- [13] M. Espinilla, J. Medina, and C. Nugent, "UCAml Cup. Analyzing the UJA Human Activity Recognition Dataset of Activities of Daily Living," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1267, doi: 10.3390/proceedings2191267.
- [14] J. D. Cerón, D. M. López, and B. M. Eskofier, "Human Activity Recognition Using Binary Sensors, BLE Beacons, an Intelligent Floor and Acceleration Data: A Machine Learning Approach," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1265, doi: 10.3390/proceedings2191265.
- [15] N. Karvonen and D. Kleyko, "A Domain Knowledge-Based Solution for Human Activity Recognition: The UJA Dataset Analysis," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1261, doi: 10.3390/proceedings2191261.
- [16] M. Razzaq, I. Cleland, C. Nugent, and S. Lee, "Multimodal Sensor Data Fusion for Activity Recognition Using Filtered Classifier," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1262, doi: 10.3390/proceedings2191262.
- [17] S. Salomón and C. Tîrnăucă, "Human Activity Recognition through Weighted Finite Automata," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1263, doi: 10.3390/proceedings2191263.
- [18] A. Jiménez and F. Seco, "Multi-Event Naive Bayes Classifier for Activity Recognition in the UCAml Cup," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1264, doi: 10.3390/proceedings2191264.
- [19] P. Lago and S. Inoue, "A Hybrid Model Using Hidden Markov Chain and Logic Model for Daily Living Activity Recognition," Proceedings, vol. 2, no. 19, Oct. 2018, p. 1266, doi: 10.3390/proceedings2191266.
- [20] WSU CASAS Datasets. Accessed: Jul. 1, 2020. [Online]. Available: <http://casas.wsu.edu/datasets/>

- [21] H. Alemdar, H. Ertan, O. D. Incel and C. Ersoy, "ARAS human activity datasets in multiple homes with multiple residents," 2013 7th International Conference on Pervasive Computing Technologies for Healthcare and Workshops, Venice, 2013, pp. 232-235.
- [22] T. Tan, M. Gochoo, S. Huang, Y. Liu, S. Liu and Y. Huang, "Multi-Resident Activity Recognition in a Smart Home Using RGB Activity Image and DCNN," in IEEE Sensors Journal, vol. 18, no. 23, 1 Dec.1, 2018 pp. 9718-9727, doi: 10.1109/JSEN.2018.2866806.
- [23] F. A. Machot, A. H. Mosa, M. Ali and K. Kyamakya, "Activity Recognition in Sensor Data Streams for Active and Assisted Living Environments," in IEEE Transactions on Circuits and Systems for Video Technology, vol. 28, no. 10, Oct. 2018, pp. 2933-2945, doi: 10.1109/TCSVT.2017.2764868.
- [24] Y. Ting , K. Hsu, C. Lu, Li-Chen Fu and J. Yung-Jen, "Interaction models for multiple-resident activity recognition in a smart home," 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, Taipei, 2010, pp. 3753-3758, doi: 10.1109/IROS.2010.5650340.
- [25] R. Kumar, I. Qamar, J. S. Virdi and N. C. Krishnan, "Multi-label Learning for Activity Recognition," 2015 International Conference on Intelligent Environments, Prague, 2015, pp. 152-155, doi: 10.1109/IE.2015.32.
- [26] N. Sarma, S. Chakraborty and D. S. Banerjee, "Learning and Annotating Activities for Home Automation using LSTM," 2019 11th International Conference on Communication Systems & Networks (COMSNETS), Bengaluru, India, 2019, pp. 631-636, doi: 10.1109/COMSNETS.2019.8711433.
- [27] N. Sarma, S. Chakraborty and D. S. Banerjee, "Activity Recognition through Feature Learning and Annotations using LSTM," 2019 11th International Conference on Communication Systems & Networks (COMSNETS), Bengaluru, India, 2019, pp. 444-447, doi: 10.1109/COMSNETS.2019.8711147.
- [28] W. Wang and C. Miao, "Multi-Resident Activity Recognition with Unseen Classes in Smart Homes," 2018 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI), Guangzhou, 2018, pp. 780-787, doi: 10.1109/SmartWorld.2018.00147.
- [29] Everspring Website. Accessed: Jul. 1, 2020. [Online]. Available: <http://www.everspring.com/product/>
- [30] Estimote Website. Accessed: Jul. 1, 2020. [Online]. Available: <https://estimote.com/>
- [31] Android SDK. Accessed: Jul. 1, 2020. [Online]. Available: <https://developer.android.com/docs>
- [32] SensFloor®. Accessed: Jul. 1, 2020. [Online]. Available: <https://future-shape.com/en/system>
- [33] F. A. Machot and H. C. Mayr, "Improving human activity recognition by smart windowing and spatio-temporal feature analysis," in Proc. 9th ACM Int. Conf. Pervasive Technol. Rel. Assistive Environ., 2016, p. 56, doi: 10.1145/2910674.2910697.
- [34] M. Espinilla, L. Martínez, J. Medina and C. Nugent, "The Experience of Developing the UJAmI Smart Lab," in IEEE Access, vol. 6, 2018, pp. 34631-34642, doi: 10.1109/ACCESS.2018.2849226.
- [35] A.G. Salguero, J. Medina, P. Delatorre, et al. "Methodology for improving classification accuracy using ontologies: application in the recognition of activities of daily living" in J Ambient Intell Human Comput 10, (2019), p 2125–2142 <https://doi.org/10.1007/s12652-018-0769-4>
- [36] M.A. López, M. Espinilla, I. Cleland, C. Nugent, and J. Medina, "Fuzzy cloud-fog computing approach application for human activity recognition in smart homes" in Journal of Intelligent & Fuzzy Systems, vol. 38, no. 1, pp. 709-721 (2020). doi: 10.3233/JIFS-179443.
- [37] M.Á. López ; M Espinilla; C. Paggeti, J.Medina Activity Recognition for IoT Devices Using Fuzzy Spatio-Temporal Features as Environmental Sensor Fusion. Sensors 2019, 19, 3512.
- [38] M. Á. López, M. Espinilla, C. Nugent, & J. Quero, "Evaluation of convolutional neural networks for the classification of falls from heterogeneous thermal vision sensors" in International Journal of Distributed Sensor Networks (2020). <https://doi.org/10.1177/1550147720920485>
- [39] R. A. Hamad, A. S. Hidalgo, M. Bouguelia, M. E. Estevez and J. M. Quero, "Efficient Activity Recognition in Smart Homes Using Delayed Fuzzy Temporal Windows on Binary Sensors," in IEEE Journal of Biomedical and Health Informatics, vol. 24, no. 2, Feb. 2020, pp. 387-395, doi: 10.1109/JBHI.2019.2918412.
- [40] M. Espinilla, J. Medina, J. Hallberg,. et al. A new approach based on temporal sub-windows for online sensor-based activity recognition. J Ambient Intell Human Comput (2018). <https://doi.org/10.1007/s12652-018-0746-y>

A.6. Conclusions and Future Works

A.6.1. Conclusions

In this doctoral thesis, we have addressed the design and evaluation of new methodologies for the recognition of postural changes through sensors.

In the first of our proposals, we present a methodology for the classification of postural changes with inertial sensors, in which the system detects the position of patients with reduced mobility while they are in bed, walking or standing, and provides medical personnel with already useful information for caregivers through notifications. This methodology consists of a historical record of body activity and notifications when a position persists for a long period, to remotely monitor the positions and times of patients, becoming a support tool for medical personnel.

The data from the sensors has been processed in real-time to calculate the following postures: supine, leaning, left side, right side, sitting, straight legs, elevated torso, and walking. The previously defined characteristics and labels are used to train a classifier. In this methodology, the following classifiers are evaluated: K Nearest Neighbor (KNN), Naïve Bayes (NB), Support Vector Machines (SVM), and Decision Trees (C4.5), using the Java and C programming languages ++, allowing deployment on miniature boards or mobile devices. The evaluation of different classification approaches shows that SVM and KNN provide better results in determining the position

of the patient, according to the collected data, the high competence, and the inherent design to work with numerical attributes.

Thus, the main novelty of this proposal has been the use of inertial sensors to monitor patients through a methodology that automatically determines the position in real-time. This innovation offers multiple advantages, such as providing caregivers with continuous real-time monitoring of the body position, thus reducing the effort required thanks to automatic control. In addition, personalization was implemented, including some data of the patient under study. This markedly increased the accuracy and recovery performance. The presented proposal has been validated in the Smart Lab of the University of Jaén, to evaluate the proposed methodology and empirically verify the recognition of positions with the support of an external observer, who tagged the position in real-time during the collection of data, for a total collection of 100 422 samples.

In the second part of our proposals in this doctoral thesis, we have also focused on the recognition of postural changes. In this case, we have proposed a methodology for the classification of postures in bed, in addition to an approach based on fuzzy logic to calculate the priority of postural changes.

For this, in this second methodology we have used inertial sensors attached to clothing, which describe the orientation of patients and are installed in body areas in a non-invasive way, in addition to a data-based model for posture recognition, which segments the inertial data and the classification of the positions, and, finally, an approach

based on fuzzy logic, which calculates the priority of the postural changes for each body area according to a defined protocol and with the time elapsed since the previous position in bed.

To show the potential of the proposed methodology, we have selected the Tactigon One device, due to its specifications in terms of size, weight, and cost. For this research, three devices are adhered to the outer fabric of two socks and a patient's shirt, to identify the different postures adopted by the patient during a specific time. The acceleration and gyroscope data from the plates are sent via Bluetooth Low Energy (BLE), with a frequency of twenty samples per second.

The defined characteristics and labels were used to train the data-based classifiers. The lightweight and efficient classifiers were mainly studied, which allowed training and evaluation on microplates, in real time and in fog computing environments. Specifically, three classifiers were evaluated: closest neighbors to K (KNN), support vector machine (SVM) and decision tree (C4.5), given the best performance provided in the classification of postures from inertial sensors.

The main contribution of this proposal consists in the use of inertial microsensors, adhered to the patients' clothing in a non-invasive way, to detect the different bed postures. Among its many advantages, it should be noted that the algorithm performed light and optimized processing that could be integrated into low-cost devices since it did not require deep learning models. Also, as already noted, the system does not require customization to obtain high performance, although

this is sensitive to classifiers based on the decision tree, thus obtaining the best classification.

The second of our proposals has been validated through experimentation in the Smart Lab of the University of Jaén, which shows its usefulness and benefits. In addition, three protocols of heterogeneous postural changes were implemented, under the fuzzy logic approach proposed in this work, which allows notifying the medical staff, being flexible, and adjusting to the needs of each patient.

Finally, we discuss the results of the evaluations carried out. First, the recognition of bed postures was evaluated using inertial sensors connected to the participants' clothing to identify six different bed postures: supine, left, right, semi-sitting, supine with the right leg bent, and supine with the right leg. left leg bent. To do this, the three Tactigon ONE devices were integrated into the socks and t-shirts of the seven participants in the research project. During the experiment, two Neurobase professionals participated in the data collection and instructed the people on the postural change protocol for pressure ulcer prevention. More than 500,000 inertial sensor samples were collected for this analysis.

A.6.2. Future work

Given that the use of inertial devices and the recognition of activities constitute an area in evolution and of great utility in multiple sectors, our future works are oriented in the following research areas.

The methodologies proposed in this doctoral thesis have been validated in simulated scenarios, mainly in the Smart Lab of the University of Jaén. As future work, we plan to carry out tests on real patients with little mobility, developing an embedded system for real-time monitoring of postural changes integrated into the medical center, for which an alliance will be made with the Hospital Universitario de Jaén and with the Centro of Neurobase Rehabilitation, who have supported us with the verification of postures and times in the validated tests in the laboratory. The tests were scheduled for 2021, but due to the current health crisis, they have been affected.

In addition, one of the challenges of our proposal is the technology transfer to Colombia, intending to be able to carry out a pilot. For this, visits were made to different medical centers, to identify specific needs, obtaining as a result that the methodologies developed in this doctoral thesis could be of significant support to this problem in the country. The idea then in this sense is to manage financing from the Colombian government, through national calls, that allow us to carry out such piloting, with the support of researchers from the ASIA Research Group of the University of Jaén.

Bibliografía

- [1] Niels Aakvaag y Jan-Erik Frey. «Redes de sensores inalámbricos». En: *Revista ABB* 2.2006 (2006), págs. 39-42.
- [2] José Enrique Aceituno Pérez. «Prevención y tratamiento de las úlceras por presión. Revisión bibliográfica.» En: (2017).
- [3] José Javier Soldevilla Agreda, Joan Enric Torra i Bou y José Verdú Soriano. *Epidemiología, coste y repercusiones legales de las úlceras por presión en España, años 2005-2006*. 2007.
- [4] Hugo Daniel Aguagüña Pilataxi. «Sistema electrónico para asistir a pacientes en proceso de rehabilitación de úlceras por presión». B.S. thesis. Universidad Técnica de Ambato. Facultad de Ingeniería en Sistemas ..., 2018.
- [5] Hande Alemdar y Cem Ersoy. «Wireless sensor networks for healthcare: A survey». En: *Computer networks* 54.15 (2010).
- [6] Alberto Álvarez Pastor. «Implementación de unas gafas inteligentes en un almacén del sector textil». Tesis de mtría. 2015.
- [7] Mohsen Amiribesheli, Asma Benmansour y Abdelhamid Bouchachia. «A review of smart homes in healthcare». En: *Journal of Ambient Intelligence and Humanized Computing* 6.4 (2015), págs. 495-517.

- [8] Ortiz Arjona y col. «Úlceras por presión y heridas crónicas: revisión de las evidencias científicas sobre su tratamiento». En: *Rev. esp. investig. quir* (2011), págs. 229-235.
- [9] Miren Bagüés Bafaluy, Juan José Calvo Aguirre y col. «Evaluation and impact on the use of information and communication technology in the clinical management and agreed shared monitoring of pressure ulcers». En: *Revista espanola de geriatria y gerontologia* 50.4 (2014), págs. 179-184.
- [10] Oresti Banos y col. «Window size impact in human activity recognition». En: *Sensors* 14.4 (2014), págs. 6474-6499.
- [11] Ling Bao y Stephen S Intille. «Activity recognition from user-annotated acceleration data». En: *International conference on pervasive computing*. Springer. 2004, págs. 1-17.
- [12] Jason Beck y col. «A Backward Adjusting Strategy and Optimization of the C4. 5 Parameters to Improve C4. 5's Performance.» En: *FLAIRS Conference*. 2008, págs. 35-40.
- [13] Gustavo Adolfo Meneses Benavides. «Modelo de plataforma para el desarrollo de redes de sensores portables en monitoreo fisiológico ambulatorio». En: *Grupo de Investigación en Bioinstrumentación e Ingeniería Clínica, Universidad de Antioquia* (2013).
- [14] John Bongaarts. *World Economic and Social Survey 2007: Development in an Ageing World*. 2008.
- [15] Gerrie Bours y col. «A pressure ulcer audit and feedback project across multi-hospital settings in the Netherlands».

- En: *International journal for quality in health care* 16.3 (2004), págs. 211-218.
- [16] Gerrie Bours y col. «Prevalence, prevention, and treatment of pressure ulcers: descriptive study in 89 institutions in the Netherlands». En: *Research in nursing & health* 25.2 (2002), págs. 99-110.
- [17] Barry Brumitt y col. «Easyliving: Technologies for intelligent environments». En: *International Symposium on Handheld and Ubiquitous Computing*. Springer. 2000, págs. 12-29.
- [18] Nancy Butte, Ulf Ekelund y Klaas R Westerterp. «Assessing physical activity using wearable monitors: measures of physical activity». En: *Medicine & Science in Sports & Exercise* 44.1S (2012), S5-S12.
- [19] Francisco Carrero Fernández y col. «Desarrollo de una aplicación móvil para reconocimiento de actividades». En: (2015).
- [20] Pablo Casado Gallardo y col. «Clasificación de imágenes de úlceras por presión mediante el uso de técnicas de aprendizaje profundo.» En: (2019).
- [21] Rosa Maria Chachipanta Lozano y Marcia Vanessa Lazaro Leon. «Factores que influyen en la aparición de las lesiones por presión en los pacientes hospitalizados del área de especialidades clínicas en el hospital Guayaquil Abel Gilbert Ponton desde octubre a diciembre del 2017.» Tesis doct. Universidad de Guayaquil-Ciencias Médicas-Carrera de Enfermería, 2018.

- [22] Chih-Chung Chang y Chih-Jen Lin. «LIBSVM: A library for support vector machines». En: *ACM transactions on intelligent systems and technology (TIST)* 2.3 (2011), págs. 1-27.
- [23] Hugo Charte Garcia. «Monitorización de la actividad diaria mediante el uso de una unidad de medición inercial». En: (2014).
- [24] Giovanni Cicceri y col. «A deep learning approach for pressure ulcer prevention using wearable computing». En: *Human-centric Computing and Information Sciences* 10.1 (2020), pág. 5.
- [25] Fiona Collins. «Sitting: pressure ulcer development». En: *Nursing Standard (through 2013)* 15.22 (2001), pág. 54.
- [26] Luisa Fernanda Cortés Torres y col. «Validación de un dispositivo que establece y notifica la frecuencia de movimiento para prevenir úlceras por presión y caídas». Tesis doct. Universidad del Rosario, 2020.
- [27] Kim Curry y col. «A prospective, descriptive study of characteristics associated with skin failure in critically ill adults». En: *Ostomy Wound Manage* 58.5 (2012), págs. 36-43.
- [28] Dare, Moorer y Flynn. «Peer-to-Peer Nursing Rounds and Hospital-Acquired Pressure Ulcer Prevalence in a Surgical Intensive Care Unit». En: *J Wound Ostomy Continence Nurs* 39 (2012).
- [29] Haikang Diao y col. «Deep Residual Networks for Sleep Posture Recognition With Unobtrusive Miniature Scale Smart

- Mat System». En: *IEEE Transactions on Biomedical Circuits and Systems* 15.1 (2021), págs. 111-121.
- [30] Julián Edilberto Rincón Díaz. «Aproximación al costo del manejo por Enfermería de UPP Sacro-coxigea en adulto mayor hospitalizado en el HFLLA sede Francia de Ibagué durante el periodo de febrero a abril de 2011». En: *Revista Manos al Cuidado* 3 (2011).
- [31] Dan Ding y col. «Sensor technology for smart homes». En: *Maturitas* 69.2 (2011), págs. 131-136.
- [32] Warner Dong y Wong. «Fuzzy weighted averages and implementation of the extension principle». En: *Fuzzy sets and systems* 21.2 (1987), págs. 183-199.
- [33] Kathy Duncan. «Preventing pressure ulcers: the goal is zero». En: *The Joint Commission Journal on Quality and Patient Safety* 33.10 (2007), págs. 605-610.
- [34] Macarena Espinilla y col. «Human Activity Recognition from the Acceleration Data of a Wearable Device. Which Features Are More Relevant by Activities?» En: *Multidisciplinary Digital Publishing Institute Proceedings*. Vol. 2. 19. 2018, pág. 1242.
- [35] Dave Evans. «Internet de las cosas». En: *Cómo la próxima evolución de Internet lo cambia todo*. Cisco Internet Business Solutions Group-IBSG 11.1 (2011), págs. 4-11.
- [36] Joaquin Facal, Nicolás Gammarano y Alex Gurevich. «Dispositivo de medida de posición y movimiento de una persona». En: (2018).

- [37] Jingjin Fan y col. «Sensor Fusion Basketball Shooting Posture Recognition System Based on CNN». En: *Journal of Sensors* 2021 (2021).
- [38] Imelda Flores Montes y col. «Prevalencia de úlceras por presión en pacientes atendidos en el Instituto Nacional de Cardiología Ignacio Chávez». En: *Rev. mex. enferm. cardiol* (2010), págs. 13-17.
- [39] Renata Virginia González-Consuegra y col. «Plan de atención integral de enfermería para el cuidado de personas con úlceras por presión». En: *Revista de la Facultad de Medicina* 63.1 (2015), págs. 69-80.
- [40] Renata Virginia González-Consuegra y col. «Prevalencia de úlceras por presión en Colombia: informe preliminar». En: *Revista de la Facultad de Medicina* 62.3 (2014), págs. 369-377.
- [41] Aldemar Guauque Barrera, Jenniffer Ramirez Acuña y Fredy Alejandro Rincón Ortiz. «Validez de las escalas de valoración del riesgo de desarrollar úlceras por presión. Revisión de la literatura.(2009-2014)». En: ().
- [42] Julian Alfredo Gutierrez Azabache. «Riesgo a Úlceras por presión según Escala de Norton en una población adulto mayor de un programa de atención domiciliaria del Callao». En: (2015).
- [43] Mark Hall y col. «The WEKA data mining software: an update». En: *ACM SIGKDD explorations newsletter* 11.1 (2009).

- [44] Laura Herrero Boil. «Las superficies especiales de manejo de presión en la prevención y tratamiento las úlceras por presión. Revisión de la literatura». En: (2015).
- [45] Dolores Hinojosa-Caballero. «Conocimiento de los profesionales de urgencias sobre la prevención y tratamiento de las úlceras por presión». En: *Gerokomos* 23.4 (2012), págs. 178-184.
- [46] Philippe Kaikenger y col. *Pressure ulcer prevention with wearable monitoring*. US Patent App. 15/822,532. Mayo de 2018.
- [47] Alyson Dare Kelleher, Amanda Moorer y MaryBeth Flynn Makic. «Peer-to-peer nursing rounds and hospital-acquired pressure ulcer prevalence in a surgical intensive care unit: a quality improvement project». En: *Journal of Wound Ostomy & Continence Nursing* 39.2 (2012), págs. 152-157.
- [48] Arshia Khan y col. «Wireless solution to prevent decubitus ulcers: Preventive weight shifting guide, monitor, and tracker app for wheel chair users with spinal cord injuries (phase II)». En: *2016 IEEE 18th International Conference on e-Health Networking, Applications and Services (Healthcom)*. IEEE. 2016, págs. 1-6.
- [49] Jan Kottner y Theo Dassen. «An interrater reliability study of the Braden scale in two nursing homes». En: *International Journal of Nursing Studies* 45.10 (2008), págs. 1501-1511.
- [50] Debian Kress. En: (1985). US Patent 4,554,930 Washington, DC: U.S. Patent and Trademark Office.

- [51] James Lenz y S Edelstein. «Magnetic sensors and their applications». En: *IEEE Sensors journal* 6.3 (2006), págs. 631-649.
- [52] Qiang Li y col. «Accurate, fast fall detection using gyroscopes and accelerometer-derived posture information». En: *2009 Sixth International Workshop on Wearable and Implantable Body Sensor Networks*. IEEE. 2009, págs. 138-143.
- [53] Gonzalo Rivera Lillo y Claudio Tapia Malebrán. «Informe Final Proyecto: “Desarrollo de soluciones para la prevención de úlceras por presión en pacientes con hospitalización domiciliaria o en clínica”». En: ().
- [54] Andreas Lmberis y Andre Dittmar. «Advanced wearable health systems and applications-research and development efforts in the European union». En: *IEEE Engineering in Medicine and Biology Magazine* 26.3 (2007), págs. 29-33.
- [55] José Félix Martínez López. *Prevención y tratamiento de úlceras y escaras*. Editorial Vértice, 2008.
- [56] Miguel Ángel López Medina y col. «Activity Recognition for IoT Devices Using Fuzzy Spatio-Temporal Features as Environmental Sensor Fusion». En: *Sensors* 19.16 (2019), pág. 3512.
- [57] Andreas Lymberis. «Wearable smart systems: from technologies to integrated systems». En: *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. IEEE. 2011, págs. 3503-3506.
- [58] Francisco MartÃ±ez Rus, Guillermo PradÃ±es Ramiro, BegoÃ±a Rivera GÃ³mez y col. «2021 Venta caliente de la banda reloj

- deportivo Pulsera inteligente para Apple Watch Band». En: RCOE 12.4 (2007), págs. 253-263.
- [59] Josefina Martinez y col. «Guia para la prevención, diagnóstico y tratamiento de las úlceras por presión». En: *Logroño, España: Consejería de Salud de La Rioja* (2009).
- [60] Merryn Mathie y col. «Accelerometry: providing an integrated, practical method for long-term, ambulatory monitoring of human movement». En: *Physiological measurement* 25.2 (2004).
- [61] Javier Medina, Luis Martinez y Macarena Espinilla. «Subscribing to fuzzy temporal aggregation of heterogeneous sensor streams in real-time distributed environments». En: *International Journal of Communication Systems* 30.5 (2017), e3238.
- [62] Javier Medina y col. «A Fuzzy Temporal Rule-based System for handling the Nursing Process on mobile devices». En: *Expert Systems with Applications* 39.12 (2012), págs. 10479-10488.
- [63] Javier Medina y col. «Fuzzy fog computing: A linguistic approach for knowledge inference in wearable devices». En: *International conference on ubiquitous computing and ambient intelligence*. Springer. 2017, págs. 473-485.
- [64] Javier Medina y col. «Intelligent multi-dose medication controller for fever: From wearable devices to remote dispensers». En: *Computers & Electrical Engineering* 65 (2018), págs. 400-412.
- [65] Iván Molina Carmona y col. «Validez del dispositivo inercial WIMU PRO para el registro de la frecuencia cardiaca en un test

- de campo». En: *SPORT TK-Revista EuroAmericana de Ciencias del Deporte* 7.1 (2018), págs. 81-86.
- [66] Edna Bernal Monroy y col. «Intelligent System for the Prevention of Pressure Ulcers by Monitoring Postural Changes with Wearable Inertial Sensors». En: *Multidisciplinary Digital Institute Proceedings*. Vol. 31. 1. 2019, pág. 79.
- [67] Imelda Flores Montes y col. «Prevalencia de úlceras por presión en pacientes atendidos en el Instituto Nacional de Cardiología Ignacio Chávez». En: *Revista mexicana de enfermería cardiológica* 18.1-2 (2010), págs. 13-17.
- [68] Zena Moore y Seamus Cowman. «Pressure ulcer prevalence and prevention practices in care of the older person in the Republic of Ireland». En: *Journal of Clinical Nursing* 21.3-4 (2012), págs. 362-371.
- [69] Bijan Najafi y col. «Measurement of stand-sit and sit-stand using a miniature gyroscope and its application in fall risk evaluation in the elderly». En: *IEEE Transactions on biomedical Engineering* 49.8 (2002), págs. 843-851.
- [70] Danny Manuel Nicolalde Rodriguez. «Influencia de la curación tradicional de las heridas crónicas en los costos de la estancia hospitalaria en los usuarios externos del Hospital General HOSNAG. Creación del servicio de clínica de heridas.» En: (2018).
- [71] Francisco Javier Ordóñez y Daniel Roggen. «Deep convolutional and lstm recurrent neural networks for

- multimodal wearable activity recognition». En: *Sensors* 16.1 (2016), pág. 115.
- [72] Omar Oreifej y Zicheng Liu. «Hon4d: Histogram of oriented 4d normals for activity recognition from depth sequences». En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2013, págs. 716-723.
- [73] Pedro Pancorbo Hidalgo y col. «Epidemiología de las úlceras por presión en España en 2013: 4. ° Estudio Nacional de Prevalencia». En: *Gerokomos* 25.4 (2014), págs. 162-170.
- [74] Pedro Pancorbo Hidalgo y col. «Epidemiología de las úlceras por presión en España en 2013: 4. ° Estudio Nacional de Prevalencia». En: *Gerokomos* 25.4 (2014), págs. 162-170.
- [75] Alexandros Pantelopoulos y Nikolaos G Bourbakis. «A survey on wearable sensor-based systems for health monitoring and prognosis». En: *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 40.1 (2009), págs. 1-12.
- [76] Donald Patterson y col. «Inferring high-level behavior from low-level sensors». En: *International Conference on Ubiquitous Computing*. Springer. 2003, págs. 73-89.
- [77] Maria Dolores Peláez y col. «Key factors for innovative developments on health sensor-based system». En: *International Conference on Bioinformatics and Biomedical Engineering*. Springer. 2017, págs. 665-675.
- [78] Paola Pierleoni y col. «A versatile ankle-mounted fall detection device based on attitude heading systems». En: *2014 IEEE*

- Biomedical Circuits and Systems Conference (BioCAS) Proceedings*. IEEE. 2014, págs. 153-156.
- [79] Maria Baran Pouyan y col. «A pressure map dataset for posture and subject analytics». En: *2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*. IEEE. 2017.
- [80] Robert Puers. «Capacitive sensors: when and how to use them». En: *Sensors and Actuators A: Physical* 37 (1993), págs. 93-105.
- [81] JM Quero y col. «CardioSmart: sistema inteligente de monitorización cardiológica empleando GPRS». En: *Revista IEEE américa latina* 3.2 (2005).
- [82] Madhuri Reddy, Sudeep S Gill y Paula A Rochon. «Preventing pressure ulcers: a systematic review». En: *Jama* 296.8 (2006), págs. 974-984.
- [83] Aurora Polo Rodriguez y col. «In-Bed Posture Classification from Pressure Mat Sensors for the Prevention of Pressure Ulcers Using Convolutional Neural Networks». En: *International Work-Conference on Bioinformatics and Biomedical Engineering*.
- [84] Noemi Marisa Brunet Rogenski y Paulina Kurcgant. «The incidence of pressure ulcers after the implementation of a prevention protocol». En: *Revista latino-americana de enfermagem* 20.2 (2012), págs. 333-339.
- [85] Lissette Estefania Salinas Salinas y col. «PUSAHQ, un robot inteligente para la enseñanza a niños de etapa inicial». En: *Ciencia Digital* 3.3.4. (2019), págs. 135-151.

- [86] Manuel Joaquin Sánchez Chamocho. «Prevención y cuidados de las úlceras por presión en pacientes adultos». En: (2014).
- [87] Christina Searle y Fran McInerney. «Nurses' decision-making in pressure area management in the last 48 hours of life». En: *International journal of palliative nursing* 14.9 (2008), págs. 432-438.
- [88] Teresa Segovia Gómez y col. «Costes asociados a una úlcera por presión: no hay dudas en que lo mejor es prevenir. A propósito de un caso». En: *VIII Simposio Nacional GNEAUPP. Madrid: Hospital Universitario Puerta de Hierro Majadahonda*. 2010.
- [89] Eman Shahin y col. «The relationship between malnutrition parameters and pressure ulcers in hospitals and nursing homes». En: *Nutrition* 26.9 (2010), págs. 886-889.
- [90] José Javier Soldevilla Agreda. «Torra i Bou JE, Verdú Soriano J». En: *Epidemiologia, coste y repercusiones legales de las úlceras por presión en España, años 2006* (2005).
- [91] José Javier Soldevilla Agreda y col. «2º Estudio Nacional de Prevalencia de Úlceras por Presión en España, 2005: Epidemiología y variables definitorias de las lesiones y pacientes». En: *Gerokomos* 17.3 (2006), págs. 154-172.
- [92] José Javier Soldevilla Agreda y col. «Una aproximación al impacto del coste económico del tratamiento de las úlceras por presión en España». En: *Gerokomos* 18.4 (2007), págs. 43-52.
- [93] Tactigon. *The Tactigon ONE*. www.thetactigon.com/. [Online; accessed 1-02-2020]. 2020.

- [94] Ning Tan, Rajesh Elara Mohan y Akiko Watanabe. «Toward a framework for robot-inclusive environments». En: *Automation in Construction* 69 (2016), págs. 68-78.
- [95] Nefi Jafid Tola Vargas. «Prototipo de sistemas de control de acceso mediante módulos Bluetooth y RFID a través de la plataforma arduino en la editorial Abya Yala Patuju». Tesis doct.
- [96] GABRIELA NAVARRO TOVAR y col. «La ropa inteligente». En: ().
- [97] Katrien Vanderwee y col. «The reliability of two observation methods of nonblanchable erythema, Grade 1 pressure ulcer». En: *Applied Nursing Research* 19.3 (2006), págs. 156-162.
- [98] Sergio Alejandro Velastin Carroza, Saima Nazir y Haroon Yousaf. «Evaluating a bag-of-visual features approach using spatio-temporal features for action recognition». En: (2018).
- [99] José Verdú Soriano y col. «HELCOS. Sistema integrado para el manejo de heridas: A propósito de un caso». En: *Rev. Rol enferm* (2018), págs. 778-783.
- [100] Benedetto Vigna. «More than Moore: micro-machined products enable new applications and open new markets». En: *IEEE International Electron Devices Meeting, 2005. IEDM Technical Digest*. IEEE. 2005, 8-pp.
- [101] Dinesh Kumar Vishwakarma y Rajiv Kapoor. «Hybrid classifier based human activity recognition using the silhouette and cells». En: *Expert Systems with Applications* 42.20 (2015).

- [102] Jindong Wang y col. «Deep learning for sensor-based activity recognition: A survey». En: *Pattern Recognition Letters* 119 (2019), págs. 3-11.
- [103] Mark Weiser. «The Computer for the 21 st Century». En: *Scientific american* 265.3 (1991), págs. 94-105.
- [104] Gail Woodbury y Pamela Houghton. «Prevalence of pressure ulcers in Canadian healthcare settings». En: *Ostomy Wound Management* 50 (2004), págs. 22-39.
- [105] Jiawei Yan, Federico Angelini y Syed Mohsen Naqvi. «Image Segmentation Based Privacy-Preserving Human Action Recognition for Anomaly Detection». En: *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE. 2020, págs. 8931-8935.
- [106] Henry Yang y col. «Ferromagnetic micromechanical magnetometer». En: *Sensors and Actuators A: Physical* 97 (2002).
- [107] Jaeyoung Yang, Joonwhan Lee y Joongmin Choi. «Activity recognition based on RFID object usage for smart mobile devices». En: *Journal of Computer Science and Technology* 26.2 (2011), págs. 239-246.
- [108] Ran Yang y col. «A review on chitosan-based flocculants and their applications in water treatment». En: *Water research* 95 (2016), págs. 59-89.
- [109] Olga-Bueno Yáñez y col. «Evaluación e impacto del uso de las tecnologías de la información y comunicación para la gestión clínica y seguimiento compartido y consensuado de las úlceras

- por presión». En: *Revista Española de Geriatria y Gerontologia* 50.4 (2015), págs. 179-184.
- [110] Navid Yazdi, Farrokh Ayazi y Khalil Najafi. «Micromachined inertial sensors». En: *Proceedings of the IEEE* 86.8 (1998).
- [111] Ali K Yetisen y col. «Wearables in medicine». En: *Advanced Materials* 30.33 (2018), pág. 1706910.
- [112] Lotfi Zadeh. «A computational approach to fuzzy quantifiers in natural languages». En: *Computational linguistics*. Elsevier, 1983, págs. 149-184.
- [113] Tahmina Zebin y col. «Implementation of a batch normalized deep LSTM recurrent network on a smartphone for human activity recognition». En: *2019 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*. IEEE. 2019, págs. 1-4.
- [114] Zelkha y col. «From Devices to». En: *Ambient Intelligence""*, *Digital Living Room Conference (June 1998)*. 1998.
- [115] Shumei Zhang y col. «Activity monitoring using a smart phone's accelerometer with hierarchical classification». En: *2010 sixth international conference on intelligent environments*. IEEE.
- [116] Yuan Zhuang y col. «A survey of positioning systems using visible LED lights». En: *IEEE Communications Surveys & Tutorials* 20.3 (2018), págs. 1963-1988.
- [117] Xiao Lin Zuo y Fan-Jie Meng. «A care bundle for pressure ulcer treatment in intensive care units». En: *International Journal of Nursing Sciences* 2.4 (2015), págs. 340-347.