

# SafeWalks: aplicación móvil de supervisión de pacientes de Alzheimer

Pablo Pérez Lozano<sup>1</sup>, Alejandro Pérez Vereda<sup>2</sup>,  
Juan Manuel Murillo<sup>1</sup>, Carlos Canal<sup>2</sup>

<sup>1</sup> Universidad de Extremadura; <sup>2</sup> Universidad de Málaga

pperezlo@alumnos.unex.es; apvereda@uma.es;  
juanmamu@unex.es; canal@lcc.uma.es

**Abstract.** *El principal objetivo de Internet of Things (IoT) es integrar las tecnologías informáticas en el quehacer cotidiano de las personas, facilitando su interacción con un entorno de dispositivos interconectados, pero el estado actual del arte hace que dicha interacción esté aún lejos de resultar trivial, precisando de continua intervención del usuario. El modelo People as a Service (PeaaS) pretende facilitar estas tareas por medio del uso del teléfono móvil como interfaz del usuario con IoT. PeaaS permite elaborar un perfil sociológico del usuario, que puede ser explotado por el mismo y servido a terceros de forma controlada. En este trabajo presentamos una aplicación móvil para la supervisión de personas afectadas de Alzheimer como prueba de concepto del modelo PeaaS, teniendo como resultado una funcionalidad que va mucho más allá de la ofrecida por otros productos similares en este campo.*

## 1 Introducción

El principal objetivo de *Internet of Things* (IoT) es integrar las tecnologías informáticas en el quehacer cotidiano de las personas [1, 2], de forma que, por ejemplo, se encienda de forma automática la cafetera para tener el café preparado al levantarnos, incluso planificando esta tarea de acuerdo con nuestros hábitos diarios.

Sin embargo, la forma en que esta integración se lleva a cabo en la actualidad es notablemente susceptible de mejora, quedando aún un salto entre la red donde la información es tratada e intercambiada y la realidad de la vida física y su contexto [3]. En general, el usuario necesita configurar diversos parámetros del sistema en cuestión de forma manual, lo cual, lejos de hacer que la tecnología trabaje para las personas, las obliga a estar pendientes de introducir nuevas órdenes o modificar la planificación siempre que se produzca un cambio inesperado en sus hábitos.

En un escenario de IoT más adecuado, la tecnología debería tener en cuenta el contexto de las personas a las que debe servir, aprendiendo de dicho contexto y realizando acciones de forma proactiva de acuerdo con su situación y expectativas en cada momento. Así, cuando una persona pone el despertador más tarde de lo habitual, le gustaría que el café empezara a hacerse en el momento adecuado para tomárselo caliente al levantarse.

Esto es lo que plantea el modelo *People as a Service* (PeaaS) [4]. PeaaS se basa en el uso de *smartphones* como representantes e interfaces de los usuarios con IoT, debido a que este tipo de dispositivos son altamente personalizados, y acompañan a sus propietarios a lo largo de sus actividades diarias y, en particular, en la mayor parte de sus interacciones en Internet, acumulando una gran cantidad de información sobre ellos [5,6]. PeaaS es un modelo social que pone su énfasis en el usuario como proveedor de servicios y le permite controlar la información que ofrece su dispositivo móvil, dando especial importancia a aspectos de privacidad y de seguridad.

Con la intención de validar este modelo, y como prueba de concepto del mismo, este trabajo se centra en el desarrollo de una aplicación Android para el seguimiento de personas con capacidades intelectuales mermadas, pero con cierto grado de autonomía, como pueden ser las personas con Alzheimer. El objetivo es que el teléfono móvil aprenda los patrones habituales del usuario (horarios, rutinas de desplazamiento, etc.), de forma que pueda supervisar dichas actividades y realizar acciones (por ejemplo, alertas al paciente o a sus familiares) en caso de un cambio inesperado en dichos patrones. La propuesta entronca con el interés actual en el desarrollo de productos software relacionados con la salud de los usuarios. Es tal el crecimiento de este sector que incluso Google ofrece una API<sup>1</sup> para la creación de aplicaciones destinadas a fomentar hábitos saludables de una forma más fácil, rápida y eficiente.

La estructura de este artículo es la siguiente. La Sección 2 presenta y discute la motivación del trabajo y su campo de aplicación. La Sección 3 desarrolla los principales aspectos técnicos del mismo, incluyendo entre otros la descripción del caso de estudio, la arquitectura de la aplicación, el procedimiento de análisis de detección de rutinas y el estado actual del producto. La Sección 4 hace un repaso de los principales trabajos relacionados. Por último, la Sección 5 recoge las conclusiones de este trabajo.

## 2 Motivación

Este trabajo se enmarca en el desarrollo de una plataforma software que mejore cómo las personas se integran en IoT, para lo que se hace uso de la información contextual y perfil de usuario alojado en sus teléfonos móviles, paliando así las limitaciones actuales de este tipo de sistemas. Esto abre camino a la transición del actual modelo de IoT hacia el que podríamos llamar *Internet of People* (IoP) [7].

Esta línea de investigación parte de trabajos anteriores sobre los modelos y plataformas Social Devices [8,9] y PeaaS. Social Devices es una plataforma desarrollada en la Universidad de Tampere que tiene por objeto enriquecer, incrementar y facilitar las interacciones entre personas geográficamente próximas y entre ellas e IoT. Por otro lado, PeaaS, es un modelo y plataforma de computación móvil que permite la gestión de perfiles sociológicos de los usuarios, que son inferidos y almacenados en el propio dispositivo móvil y proporcionados a terceros como un servicio en la Nube, de manera segura y controlada por su propietario. La combinación de ambos modelos permite convertir el teléfono móvil en la interfaz

---

<sup>1</sup> Google Fit. <http://developers.google.com/fit/>

natural entre las personas e IoT, de forma que este almacena toda la información contextual necesaria e interactúa con IoT en consecuencia, minimizando la necesidad de intervención del usuario.

En la actualidad, con la aparición en el mercado de diversos dispositivos *wearable*, el sector de IoT está experimentando un gran crecimiento y difuminando las fronteras que había en cuanto a lo que es posible hacer con estas tecnologías. La mayoría de estos dispositivos salen al mercado en una línea claramente dirigida hacia sanidad y hábitos saludables. Esto es lo que nos ha llevado a elegir este sector como la prueba de concepto más adecuada.

Existen en la actualidad diversas aplicaciones móviles para la ayuda de personas con alzheimer, entre las que podemos citar Cerqana<sup>2</sup> y Tweri<sup>3</sup>. Sin embargo, ninguna de ellas considera el aprendizaje automático de rutinas y patrones de desplazamiento. Esto sin duda es una gran ventaja de nuestra aplicación sobre las ya existentes, ya que minimiza la necesidad de configuración de distintos parámetros que pueden ser complejos. De esta manera se facilita el uso de la aplicación tanto a los enfermos, que suelen tener edad avanzada y no tienen interiorizado el uso del teléfono, como a sus cuidadores, que simplemente recibirán notificaciones cuando sea oportuno. Para ello, nuestra propuesta sigue el modelo de la pirámide DIKW, que distingue entre los niveles de datos, información, conocimiento y sabiduría [10]. Así, partiendo de la recolección y agregación de datos de geolocalización temporal del teléfono móvil, se obtiene información sobre lugares y trayectorias habituales del usuario. A partir de esta información, es posible inferir conocimiento sobre sus rutinas de desplazamiento y frecuencia de las mismas, adquiriendo finalmente la sabiduría necesaria para poder predecir comportamientos y detectar desviaciones en los mismos, tomando decisiones de emisión de alertas en caso necesario.

### **3 Una aplicación para enfermos de alzheimer**

El escenario elegido como prueba de concepto del modelo PeaaS consiste en el desarrollo de SafeWalks, una aplicación para ayudar a personas con alzheimer en las fases iniciales de esta enfermedad. Con ella se quiere contribuir a mejorar su calidad de vida y la de sus cuidadores. El síndrome de Alzheimer, es una enfermedad degenerativa que produce un deterioro de las neuronas del cerebro. Esto afecta al enfermo con síntomas como pérdida de memoria, desorientación o pérdida de otras capacidades mentales que pueden resultar muy peligrosas para su seguridad. Estos síntomas pueden manifestarse con mayor fuerza en ciertos momentos, afectando a la persona de inmediato. Por ejemplo, el enfermo ha salido de casa a realizar alguna actividad y durante ella olvida el propósito de lo que estaba haciendo o cómo volver a casa.

Existen alrededor de 24 millones de personas afectadas por alzheimer en el mundo, y se estima que esta cifra alcanzará los 80 millones dentro de 20 años. Esta enfermedad no solo afecta a los pacientes, sino que también condiciona la vida de sus cuidadores, ya que les obliga a estar constantemente pendientes de ellos y

---

<sup>2</sup> Cerqana. <http://www.cerqana.es>

<sup>3</sup> Tweri. <http://www.tweri.com>

preocupados por su situación. Con objeto de contribuir a la mejora de esta situación, nos planteamos el desarrollo de una aplicación para dispositivos móviles basada en PeaaS y capaz de aprender las rutinas de desplazamiento del usuario. La motivación para ello fue doble. Por un lado la penetración cada vez mayor de los dispositivos móviles incluso entre la población mayor. Por otro, las ventajas que proporciona PeaaS para potenciar el uso del contexto de los usuarios de dispositivos móviles.

La aplicación diseñada incorpora dos componentes funcionales:

**Dispositivo Paciente:** Es el componente principal y se trata de una aplicación Android que reside en el dispositivo del paciente. Valiéndose de la información facilitada por el GPS del dispositivo, la aplicación registra los desplazamientos del usuario y los analiza para aprender y detectar sus rutinas. Comprueba continuamente si los desplazamientos realizados son acordes a dichas rutinas, sino emite avisos tanto al paciente como a su cuidador según diferentes niveles de alarma que pueden ser configurados. SafeWalks utiliza, analiza y pone al servicio de otros su contexto. La aplicación también permite indicar qué cuidadores tendrán acceso a este contexto.

**Dispositivo Cuidador:** De nuevo es una aplicación Android, que en este caso reside en el dispositivo del cuidador. A través de ella el cuidador puede realizar un seguimiento de la posición del paciente y configurar de forma remota la aplicación de este indicando los niveles de alarma deseados y las actuaciones a llevar a cabo en la detección de cada nivel. La aplicación se encarga de recibir y procesar las alarmas dándoles el tratamiento adecuado.

### 3.1 Arquitectura

En esta sección se describe la arquitectura adoptada para integrar PeaaS en el desarrollo de la aplicación. La Figura 2 muestra dicha arquitectura.

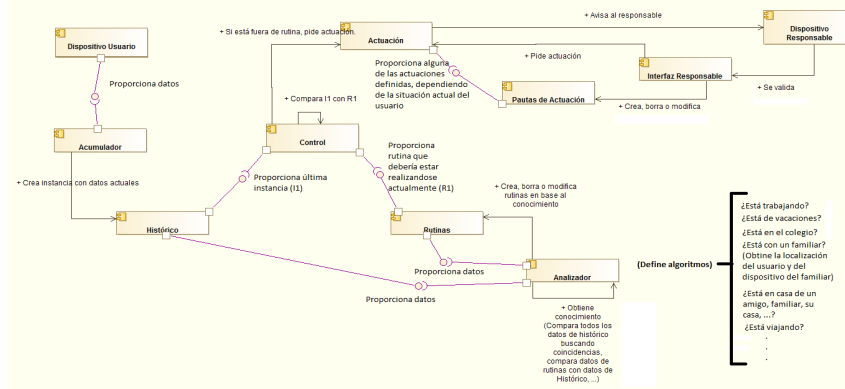


Fig. 1. Arquitectura de componentes

El componente *Acumulador* se encarga de registrar los datos de desplazamiento del paciente. Para ello detecta cuándo el paciente se pone en movimiento y, a partir de ese momento y hasta que de nuevo entre en reposo, va registrando sus coordenadas GPS, velocidad y dirección, con una cadencia variable. Toda esta información es

facilitada al *Histórico* que se encarga de almacenarla. No obstante, el componente principal de la arquitectura es el *Analizador* que se encarga de analizar los datos de desplazamiento almacenados por el *Histórico* para detectar las rutinas del paciente. El algoritmo seguido para ello se detalla en la Sección 3.3. Las rutinas son almacenadas como hitos en una línea de tiempo que coincide con un día de actividad.

Una vez establecidas las rutinas del paciente, el componente *Controlador* se encarga de analizar si su actividad actual corresponde a una rutina registrada o no. Para ello, simplemente toma la siguiente rutina en la línea de tiempo y, una vez alcanzado el momento del tiempo indicado por la rutina analiza la última información almacenada en *Histórico* y comprueba si son similares según unos márgenes de tiempo y espacio configurables. En caso de detección de una actividad fuera de rutina se notifica el hecho al componente *Actuador*. Este componente tiene configurados diferentes *Tipos* de desviación de rutinas. Por ejemplo, el cuidador puede establecer que encontrarse lejos del lugar habitual a las 12:00 del mediodía es una desviación de rutina de índole distinta a si el mismo hecho se produce a las 2:00 de la madrugada. Para cada *Tipo* de violación se pueden configurar diferentes *Niveles* de alarma. Cada nivel puede llevar asociadas acciones que van desde el lanzamiento de eventos en el propio dispositivo móvil del paciente hasta el lanzamiento de llamadas telefónicas automáticas al cuidador o incluso el lanzamiento de mensajes sonoros desde el móvil del paciente para captar la atención de las personas que puedan encontrarse cerca. Toda esta información es gestionada por el componente *Pautas de Actuación*. El cuidador puede tomar control de las alarmas en el momento que lo desee gracias a los servicios ofrecidos por el componente *Interfaz Cuidador*.

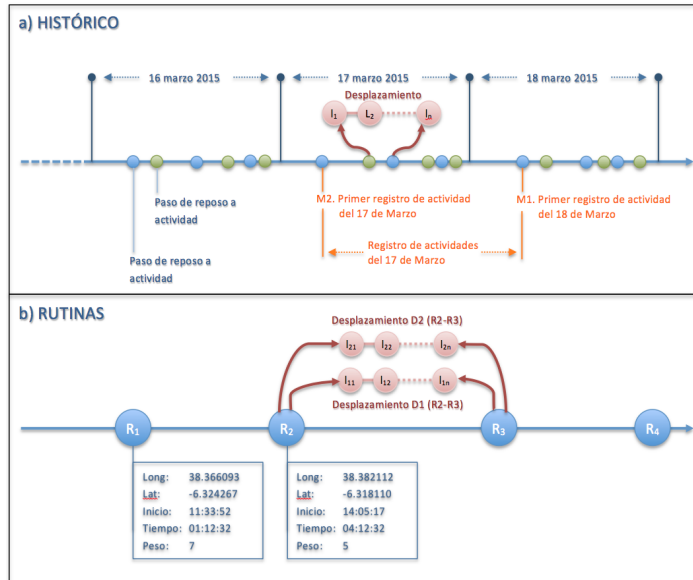
## 3.2 Procedimiento de análisis

Como mencionamos anteriormente, el componente principal de la arquitectura es el *Analizador*, que revisa los desplazamientos que realiza el paciente y trata de descubrir y aprender cuáles son sus rutinas. Para ello, este componente lanza su análisis una vez al día a una hora preestablecida. Inicialmente, para el diseño y construcción de este componente se valoró la posibilidad de utilizar motores de inferencia existentes disponibles incluso para dispositivos móviles, en particular AndroJena<sup>4</sup>. Sin embargo, tras valorar su potencial se optó diseñar y construir un procedimiento de análisis y aprendizaje *ad hoc*.

El primer paso en el análisis es aislar en el *Histórico* los desplazamientos correspondientes al último día tal y como esquematiza la Figura 2.a. Para ello, se recorre el histórico hacia atrás, tratando de localizar el primer desplazamiento de la mañana (M1 - primer desplazamiento tras un período de inactividad coincidente con la fase nocturna). A partir de este hito se sigue recorriendo el *Histórico* para localizar el siguiente primer movimiento de la mañana (M2). La actividad del último día queda descrita por los desplazamientos registrados entre M2 y M1.

---

<sup>4</sup> AndroJena: <http://code.google.com/p/androjena/>



**Fig. 2.a** Almacenaje y procesamiento de *Histórico* y *Rutinas*

El siguiente paso es llevar la información contenida entre M2 y M1 a *Rutinas*, la línea de tiempo que recoge la actividad del paciente durante una jornada, y que sirve para chequear si el paciente está realizando sus rutinas o se encuentra fuera de ellas. El algoritmo para ello se basa en el siguiente pseudocódigo:

```

1  Recorrer HISTÓRICO desde M2 hacia M1
2  Para cada periodo P de inactividad detectado
3  RUT <- Recorrer RUTINAS buscando periodo de
   inactividad similar a P atendiendo en cuenta
   los márgenes de espacio y tiempo configurados
4  Si RUT <> Null entonces
5  RUTINAS.RUT.PESO <- RUTINAS.RUT.PESO + 1
6  Sino
7  RUTINAS.NUEVA_RUTINA (P)

```

**Fig. 2.b** Almacenaje y procesamiento de *Histórico* y *Rutinas*

El algoritmo localiza en primer lugar los periodos P de inactividad del paciente y, para cada uno de ellos, se determina sus coordenadas y la duración de la inactividad. A continuación, para cada P encontrado se recorren las *Rutinas* del paciente tratando de encontrar un periodo de inactividad similar. En *Rutinas* cada periodo de inactividad se recoge como un hito registrando su longitud, latitud, hora de comienzo, duración y peso tal y como ilustra la Figura 2.b. El peso indica el número de días que se ha repetido dicha rutina. Para realizar las comparaciones se utilizan unos márgenes de tolerancia de espacio y tiempo configurables. Si se encuentra un hito similar en la línea de tiempo se suma una unidad a su peso. En caso contrario se ha encontrado una nueva rutina y se añade un nuevo hito a la línea de tiempo con peso 1. Con ello, y a medida que la aplicación lleva más días de funcionamiento, se consigue reforzar los

hitos que corresponden a rutinas más asiduas con mayores pesos. Esto también permite establecer distintos niveles de alarma dependiendo del peso de la rutina.

Las rutas de desplazamiento entre puntos de inactividad reciben un tratamiento similar. Tal y como ilustra la Figura 2.a, cuando el paciente está en movimiento el dispositivo móvil registra en el *Histórico* su desplazamiento almacenando la latitud, longitud, dirección y velocidad con una cadencia que de nuevo es configurable en la aplicación. Cadencias de un registro cada 3-5 minutos son aceptables. *Rutinas* no solo almacena los puntos de inactividad sino también todas las rutas que el *Paciente* recorre entre ellos. Entre dos rutinas puede haber más de una rutas, como muestran D1 y D2 en la figura 2.b. Para cada Desplazamiento registrado en *Histórico* durante el último día se trata de localizar su existencia en *Rutinas*. La búsqueda ahora es mucho más dirigida dado que se conocen las rutinas R de origen y destino. Sólo hay que comparar la nueva ruta entre el origen y destino con cada una de las rutas almacenadas en *Rutinas* para ese origen y destino. De nuevo la comparación se realiza atendiendo a unos márgenes de tolerancia de espacio configurables. Más concretamente la comparación se realiza analizando si los puntos de la de la nueva ruta ( $l_1, l_2, \dots, l_n$ ) se encuentran en la ruta almacenada en *Rutinas* (por ejemplo  $l_{11}, l_{12}, \dots, l_{1n}$ ) o en sus puntos intermedios (por ejemplo entre  $l_{11}$  y  $l_{12}$ ).

### 3.3 Optimización del consumo de recursos

En el diseño de aplicaciones destinada a dispositivos móviles, la optimización del consumo de recursos del dispositivo debe ser un factor director en su diseño.

En primer lugar, teniendo en cuenta el tamaño limitado de la memoria de los dispositivos, se ha optado por no guardar el historial de desplazamientos del paciente por un plazo indefinido. Como ya se ha mencionado anteriormente, una vez que los datos correspondientes al último día de actividad han sido procesados e integrados a la línea de tiempo del paciente podrían eliminarse. Aún así se permite la opción de almacenar un número de días de historia. Esto se hace con el objetivo de permitir regenerar la línea de tiempo del paciente a partir de esos días de historia. Esto resulta beneficioso cuando el paciente introduce un cambio en sus rutinas de comportamiento y desea regenerar su línea de tiempo a partir de las actividades realizadas en los últimos días. Por ejemplo, imagínese que el paciente cambia su domicilio habitual por una residencia con el objeto de conseguir asistencia durante todo el día.

El procesamiento de la actividad de la jornada, el reconocimiento de rutinas y su integración en la línea de tiempo es una tarea que consume muchos ciclos de reloj y en consecuencia batería. Por ello esta actividad se lleva a cabo sólo cuando se detecta que el teléfono está en carga conectado a la red eléctrica.

Por último, todas las actividades de registro de localización física también consumen batería y memoria. Sin embargo en este caso resulta difícilmente evitable. Si se desea mucha precisión en los registros de información y en los cálculos de cercanía se requieren cadencias de registro muy elevadas. No obstante, como ha podido comprobarse, existen gran número de parámetros configurables en la aplicación con el objeto de poder adecuar estas cadencias a las características de cada paciente.

Actualmente se dispone de un prototipo funcional de la aplicación. Dicho prototipo monitoriza la actividad del paciente, aprende sus rutinas en base a puntos de inactividad y rutas entre ellos y realiza detecciones básicas de si el paciente se encuentra en rutina o no. Sin embargo, todavía no se ha implementado todo el tratamiento para las alertas, que se encuentra actualmente en construcción. Tras completar dicha construcción se procederá a una evaluación sistemática de la aplicación y a estudiar cuáles son los parámetros de configuración más adecuados en función del tipo de paciente con el objeto de optimizar las detecciones de alertas eliminando falsos positivos y negativos así como el consumo de recursos.

#### 4 Trabajos relacionados

PeaaS es un modelo que persigue poner en valor el contexto de las personas proporcionándolo como un servicio desde el teléfono móvil. Tecnologías como Siri<sup>5</sup> para iOS o Sherpa<sup>6</sup> para Android contribuyen en el mismo sentido proporcionando a los dispositivos móviles capacidades atribuibles a las personas. PeaaS contribuye a iniciar el siguiente paso en el que dichas capacidades se adaptarán a la personalidad y preferencias de cada usuario.

La aplicación de PeaaS en este trabajo consiste en poner el contexto del *Paciente* al servicio del *Cuidador*. Ya existen otras aplicaciones móviles basadas en una arquitectura convencional que asisten a pacientes de alzheimer con el mismo objetivo que SafeWalks. Una de las pioneras en este género es la ya mencionada Tweri. Esta aplicación proporciona funcionalidades básicas para identificar las zonas donde el paciente está seguro de forma que se lancen alertas al cuidador si las abandona. El cuidador puede seguir al paciente a través de una interfaz. Además, si el paciente se encuentra inseguro puede lanzar una alerta al cuidador mediante una pulsación en la interfaz. Con funciones mejoradas y el mismo objetivo, Cerqana permite la fijación manual de zonas seguras y peligrosas en un mapa, aviso vía notificación si entra en alguna zona marcada como insegura, fijación manual de rutas habituales del usuario o detección de caídas o desvanecimientos. En comparación con SafeWalks, ambas aplicaciones adoptan una estrategia en la que el dispositivo móvil del paciente se encarga de subir su localización a un servidor con una cadencia determinada. En el servidor se realizan todos los análisis de datos y el tratamiento de alertas. Ninguna de ellas aborda la detección y aprendizaje de las rutinas del paciente, ni la actuación en tiempo real ante alertas. Simplemente está basada en los datos que se encuentran en el servidor y que normalmente tienen minutos de retraso que, en algunos casos, pueden resultar decisivos. Esta característica es difícilmente solventable mediante el uso de arquitecturas convencionales ya que implicaría cadencias muy altas en la subida de datos al servidor con el consiguiente consumo de batería. Plataformas como UrbanAirship<sup>7</sup> advierten

---

<sup>5</sup> Siri. <https://www.apple.com/es/ios/siri/>

<sup>6</sup> Sherpa. <http://sher.pa/>

<sup>7</sup> UrbanAirship: <http://urbanairship.com/>



que cadencias de registro y subida de datos cercanas a los 30 segundos implican el consumo de la batería del dispositivo en un periodo de 30 a 40 minutos.

Finalmente, se ha optado por emplear un algoritmo propio y muy básico para el análisis y aprendizaje de rutinas. Sin duda, el uso de herramientas como RDFQuery<sup>8</sup>, RDFStoreJS<sup>9</sup>, Nools<sup>10</sup> o la ya mencionada AndroJena podrían contribuir a mejorar nuestra propuesta. Su uso está contemplado en un siguiente paso cuando se proceda a incorporar datos al análisis más allá de la localización.

## 5 Conclusiones

El progresivo desarrollo de IoT y la salida al mercado de nuevos dispositivos *wearable* están haciendo cambiar la forma en que interactuamos con nuestro entorno, favoreciendo el surgimiento de escenarios cada vez más interconectados y de complejidad creciente. Sin embargo, el estado actual de la tecnología, obliga a una continua intervención del usuario. Modelos como PeaaS abogan por el uso del teléfono móvil como interfaz del usuario con su entorno, y permiten el desarrollo de perfiles sociológicos que pueden ser ofrecidos como servicios a terceros de forma controlada, favoreciendo la transición de IoT a IoP.

En este trabajo presentamos el desarrollo de una aplicación para la supervisión y seguimiento de enfermos de alzheimer, como prueba de concepto del modelo PeaaS. A partir de la monitorización de la señal GPS del teléfono, la aplicación desarrollada es capaz de aprender las rutinas de desplazamiento del usuario y de tomar decisiones en caso de desviaciones de las mismas que puedan implicar un peligro para el enfermo. SafeWalks ofrece una funcionalidad significativamente superior a otras similares actualmente en el mercado, y muestra cómo los conceptos inherentes al modelo PeaaS pueden ser puestos en práctica en un escenario de uso real, más allá del caso de estudio elegido como prueba de concepto. Actualmente estamos culminando el desarrollo de la funcionalidad básica de la aplicación y estudiando las posibilidades de su comercialización.

En cuanto a trabajos futuros, cabe señalar la incorporación progresiva de nuevos algoritmos de aprendizaje, para lograr una mayor precisión tanto en la detección de rutinas de desplazamiento, como en la predicción de las mismas y en la detección de desviaciones respecto al comportamiento habitual. La integración con servicios como Google Maps permitiría obtener información de interés sobre el entorno de las coordenadas del usuario, afinar la detección de situaciones peligrosas y proporcionar ayuda al usuario para retomar su rutina de desplazamiento en caso de que se haya extraviado. Por otro lado, el uso de la señal *wifi*, y *bluetooth* del teléfono permitiría un mejor seguimiento de la actividad del usuario en interiores, por ejemplo mediante iBeacons<sup>11</sup>, y la detección de si está acompañado por sus cuidadores o no.

---

<sup>8</sup> RDFQuery: <https://code.google.com/p/rdfquery/>

<sup>9</sup> RDFStoreJS: <https://github.com/antoniogarrote/rdfstore-js>

<sup>10</sup> Nools: <https://github.com/C2FO/nools>

<sup>11</sup> iBeacon. <http://developer.apple.com/ibeacon/>

## Agradecimientos

Este trabajo ha sido parcialmente subvencionado por el Gobierno de España, mediante el proyecto TIN2012-35669, mediante la Red de Excelencia en Ciencia e Ingeniería de Servicios TIN2014-53986-REDT, mediante la Red de Excelencia en Ingeniería del Software Dirigida por Modelos TIN2014-53555-REDT y por la Universidad de Málaga, Campus de Excelencia Internacional, Andalucía Tech.

## Referencias

- [1] M. Bakardjieva, R. Smith. "The Internet in everyday life computer networking from the standpoint of the domestic user": *New Media & Society*, 3(1):67-83, 2001.
- [2] Dohr, R. Modre-Oprian, M. Drobits, D. Hayn, G. Schreier. "The Internet of Things for ambient assisted living": *Information Technology - New Generations (ITNG)*, Seventh International Conference on, pp. 804-809, IEEE Computer Society, 2010.
- [3] L. Sha, S. Gopalakrishnan, X. Liu, Q. Wang. "Cyber-physical systems: A new frontier": *Machine Learning in Cyber Trust*, pp. 3-13, Springer, 2009.
- [4] J. Guillén, J. Miranda, J. Berrocal, J.A. García-Alonso, J.M., Murillo, C. Canal. "People as a Service: A Mobile-centric Model for Providing Collective Sociological Profiles": *Software, IEEE Software*, 31(2):48-53, IEEE Computer Society, 2014.
- [5] L. Srivastava "Mobile phones and the evolution of social behavior": *Behaviour & Information Technology*, 24(2), 2005.
- [6] Oulasvirta, T. Rattenbury, L. Ma, E. Raita "Habits make smartphone use more pervasive": *Personal and Ubiquitous Computing*, 16(1):105-114, 2012.
- [7] J. Miranda, N. Mäkitalo, J. García-Alonso, J. Berrocal, T. Mikkonen, C. Canal, J.M. Murillo. "From the Internet of Things to the Internet of People", *IEEE Internet Computing*, 19(2):40-47, IEEE Computer Society, 2015.
- [8] N. Mäkitalo, J. Pääkkö, M. Raatikainen, V. Myllärniemi, T. Aaltonen, T. Leppänen, T. Mänistö, T. Mikkonen, "Social Devices: Collaborative Co-located Interactions in a Mobile Cloud": *Proceedings of the 11<sup>th</sup> International Conference on Mobile and Ubiquitous Multimedia, MUM*, 2012.
- [9] N. Mäkitalo. "Building and programming ubiquitous social devices": *Proceedings of the 12<sup>th</sup> ACM international symposium on mobility management and wireless access (MobiWac'14)*, pp. 99-108, ACM 2014.
- [10] T.H. Davenport, L. Prusak. *Working Knowledge : How Organizations Manage What They Know*. Harvard Business School Press, 1998.