

Sistema de localización global WiFi y su aplicación a un sistema de navegación basado en POMDP

M. Ocaña¹, L.M. Bergasa¹, M.A. Sotelo¹, R. Flores¹

¹ Departamento de Electrónica, Universidad de Alcalá,
Alcalá de Henares (Madrid), España
{mocana,bergasa,sotelo,flores}@depeca.uah.es

Resumen. En este trabajo se presenta un sistema de localización global basado en medida de señal WiFi (Wireless-Fidelity, “Fidelidad Inalámbrica”) con mapa patrón a priori y su aplicación como mejora de un sistema de navegación basado en un Proceso de Decisión de Markov Parcialmente Observable (POMDP, “Partially Observable Markov Decision Process”). El sistema de navegación global POMDP emplea las observaciones procedentes de la medida de señal WiFi y de los ultrasonidos de que dispone el robot de la aplicación consiguiendo un posicionamiento global del mismo desde el primer momento de funcionamiento sin utilizar sensores adicionales en el entorno, ya que la funcionalidad principal del sensor WiFi es la de establecer una red de comunicaciones WLAN (Wireless Local Area Network, “Red de Área Local Inalámbrica”). Se presenta un algoritmo denominado WSLAM (WiFi Simultaneous Localization And Mapping, “Localización y Mapeado Simultáneos”) para resolver el problema de la calibración inicial del sistema.

1 Introducción

El boom de las redes inalámbricas durante los últimos años está propiciando el crecimiento de numerosas herramientas para manejar los dispositivos y aplicaciones emergentes. Estas redes se están convirtiendo en elementos críticos dentro de la infraestructura de red disponibles en la mayoría de los edificios públicos (universidades, aeropuertos, estaciones de tren, tribunales, hospitales, etc.), edificios comerciales (cafés, restaurantes, cines, centros comerciales, etc.) e incluso en las casas particulares. Además en los hogares, el empleo de estas redes inalámbricas favorece la movilidad para ejecutar múltiples tareas en lo que se conoce como *Casas Inteligentes*. Existen diferentes proyectos WiFi en desarrollo en ciudades tales como Paris, Barcelona, etc.

El reciente interés en las aplicaciones de estimación de la posición dentro de una red inalámbrica y la demanda creciente de tales sistemas propician que los investigadores lo apliquen a uno de los problemas fundamentales que aparecen en el campo de la robótica como es el de la *localización*. La determinación de la *pose* (posición y orientación) de un robot mediante un sensor físico no es un problema trivial y a menudo se refiere a él como el principal problema a resolver dentro de los robots con

capacidades autónomas [1]. Existen diferentes propuestas de sistemas de localización en interiores, tales como basados en infrarrojos [2], visión [3], sensores de ultrasonidos [4], sensores de contacto [5] y sistemas de Radio-Frecuencia (RF) [6].

Muchas plataformas robóticas emplean redes inalámbricas para comunicarse con recursos de computación, interfaces hombre-máquina e incluso con otros robots. Debido a la disminución de los costes de dichas redes, muchos robots son equipados con interfaces WiFi 802.11b/g. En muchas aplicaciones de localización se emplean sensores láser de elevado coste frente al coste computacional que supone el procesamiento de imagen del sensor de visión. En otros casos, se emplea el sensor WiFi tanto para realizar la localización como para establecer las comunicaciones, con lo que se evita el empleo de dichos sensores además de la modificación del entorno.

Los sistemas de localización WiFi emplean la infraestructura de red 802.11b/g para determinar la posición de los dispositivos sin necesidad de emplear hardware adicional. Esta característica los convierte en sistemas idóneos para trabajar en entornos interiores donde técnicas tradicionales, como el Sistema de Posicionamiento Global GPS (Global Positioning System) [7], no son útiles. Para estimar la posición del robot se mide el nivel de señal recibido en el interfaz WiFi desde cada uno de los puntos de acceso (APs) que forman la estructura de la red WLAN. Esta medida es función de la distancia y de los obstáculos que se encuentran entre los APs y el robot. Desafortunadamente, en entornos interiores, el canal inalámbrico es muy ruidoso y la señal de RF se ve afectada por los fenómenos de la reflexión, refracción y difracción, en lo que se conoce como efecto del multicamino, lo que hace que el nivel de señal recibido sea una función compleja respecto de la distancia. Para resolver este problema, se proponen sistemas de localización WiFi basados en un mapa radiológico a priori [6], el cual almacena los niveles de señal recibidos de cada uno de los APs en ciertos puntos del área de interés. Estos sistemas trabajan en dos fases: entrenamiento y estimación. Durante la primera, se construye el mapa de radio con el robot de forma manual o teleoperada. En la fase de estimación se obtiene un vector con los niveles de señal recibida de cada uno de los APs y se comparan con el mapa de radio para obtener la posición estimada como aquella en la que los niveles de señal son más cercanos.

Las técnicas de estimación de la posición se dividen en determinísticas y probabilísticas. En las primeras, el entorno se divide en celdas y durante la fase de estimación se obtiene la posición como aquella celda en la que las medidas almacenadas en el patrón son más parecidas [6]. Por otro lado las técnicas probabilísticas mantienen una distribución de probabilidad sobre todas las posibles ubicaciones del entorno. Estas técnicas consiguen una precisión superior a cambio de un mayor coste computacional. En [8] los autores emplean una red de conocimiento Bayesiana para obtener una distribución de probabilidad posterior sobre la posición estimada. En [9] se emplea una aproximación probabilística mediante un filtro Bayesiano recursivo basado en un muestreo de Monte Carlo secuencial.

La aproximación Bayesiana se suele aplicar en los casos en los que la representación del entorno es en forma de rejillas. Otra alternativa para modelar el entorno es mediante un mapa topológico. En este caso la localización se basa en el hecho de que el robot identifica automáticamente que ha alcanzado un nodo del mapa en base a alguna información geométrica del entorno.

La discretización topológica es útil para diseñar un sistema de navegación global en el que el objetivo es guiar al robot a un nodo de destino, como puede ser la puerta de una habitación, y en el que las tareas de navegación local son llevadas a cabo por un controlador de más bajo nivel. Los POMDPs son modelos que proporcionan soluciones para la localización, planificación y aprendizaje en el contexto robótico. Estos modelos emplean razonamientos probabilísticos, muy importantes en el caso de los sensores WiFi, sobre una representación topológica del entorno para reducir memoria y tiempo de proceso de los algoritmos.

En este trabajo se presenta un sistema de localización probabilístico basado en la medida de la señal WiFi y la lectura de los ultrasonidos, que sirve de ayuda al sistema de navegación global POMDP para navegar en entornos interiores. En primer lugar se realiza una introducción a los sistemas de navegación POMDP y a continuación se propone nuestro sistema de localización y navegación que se empleará para obtener resultados experimentales sobre un robot real. También se presenta un algoritmo basado en EM-SLAM que ha sido denominado WSLAM para realizar el aprendizaje automático de las matrices de observación y transición que serán empleadas por el POMDP. Por último se extraen conclusiones sobre el sistema propuesto.

2 Introducción a los sistemas de navegación global basados en POMDP

Para la comprensión del funcionamiento de los sistemas de navegación basados en POMDP resulta interesante hacer una revisión inicial de los Procesos de Decisión de Markov o MDP (Markov Decision Process).

Los MDP son unos de los modelos probabilísticos más utilizados en la Planificación basada en Teoría de Decisiones o DTP (Decision-Theoretic Planning), que es una extensión de la planificación clásica para resolver problemas de toma de decisiones en sistemas en los que el efecto de las acciones sobre el entorno es incierto.

Suponiendo un robot que se mueve por un entorno tomando decisiones y ejecutando acciones, como se puede observar en la Figura 1, el robot toma como entrada el estado actual del entorno y genera a su salida una acción, la cual conlleva la modificación o no del entorno en el que se encuentra el robot. En un MDP sólo existe incertidumbre en el efecto que tiene la acción sobre el entorno, sin embargo, no existe incertidumbre en el conocimiento del estado actual, ya que es completamente observable.

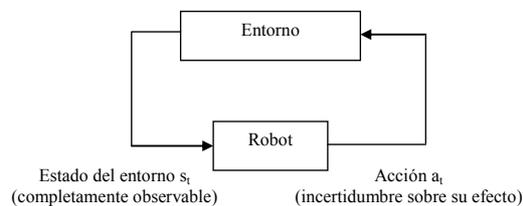


Fig. 1. Estructura de un MDP

Por lo tanto, un MDP es un modelo matemático de un problema de decisión secuencial en tiempo discreto, definido por los siguientes elementos: S es el conjunto finito de estados ($s \in S$) que puede tomar el entorno, A es el conjunto finito de acciones ($a \in A$) que puede ejecutar el robot, T es la función de transición de estados, que para cada estado final s' , estado inicial s y acción a , determina la probabilidad $p(s'|s,a)$ (probabilidad de que ejecutando la acción a en el estado s , el entorno pase al estado s') y R es la función de recompensa, que para cada estado s y acción a , determina la recompensa obtenida por el robot al ejecutar la acción a en dicho estado, $r(s,a)$. En un MDP que a lo largo de su ejecución va pasando por los estados $s_0, s_1, \dots, s_{t-1}, s_t$, y va ejecutando las acciones $a_0, a_1, \dots, a_{t-1}, a_t$, la probabilidad de que el estado en el instante $t+1$ sea s_{t+1} viene dada por la expresión (1).

$$p(s_{t+1} | s_0, a_0, s_0, a_0, \dots, s_t, a_t) = p(s_{t+1} | s_t, a_t) \quad (1)$$

Esta condición se conoce como *propiedad de Markov*, y significa que el estado y la acción actuales proporcionan toda la información necesaria para predecir el próximo estado.

Ya que en un MDP el estado actual es completamente observable, el problema a resolver es determinar la acción a ejecutar en cada estado. Cuando un robot no puede conocer con exactitud el estado actual del entorno en el que se encuentra se habla de un proceso de observabilidad parcial. En este caso las observaciones se modelan mediante una función de observación \mathcal{G} , que indica la probabilidad de realizar cada observación en cada estado del entorno $p(o|s)$.

En un POMDP, el robot no conoce de forma exacta el estado actual, en su lugar mantiene una distribución de probabilidad sobre todos los estados, esta distribución recibe el nombre de Distribución de Creencia ($Bel(S)$), que resume toda la historia pasada del sistema. El POMDP está definido por los mismos elementos de un MDP, es decir, S (el conjunto de estados), A (el conjunto de acciones), T (la función de transición de estados) y R (función de recompensa) que se definen de la misma forma que en un MDP, pero además añade otros dos elementos que son: O es el conjunto de observaciones ($o \in O$) que se pueden recibir del entorno y \mathcal{G} es la función de observación. La Figura 2 muestra la estructura del POMDP.

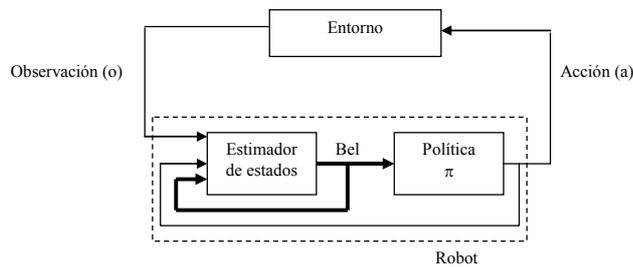


Fig. 2. Estructura de un POMDP

El bloque de estimación de estados representa la etapa de localización y es el encargado de actualizar la distribución de creencia cada vez que se ejecuta una nueva acción y cada vez que se realiza una nueva observación, utilizando para ello el método Bayesiano o localización de Markov.

3. Diseño de nuestro sistema de navegación POMDP

En esta sección se describe el diseño de nuestro sistema de navegación empleando un POMDP basado en observaciones de la señal WiFi y ultrasonidos, este diseño incluye: representación del entorno, conjunto de estados, selección del tipo de observaciones, acciones y las matrices de observación y transición.

3.1 Representación del entorno

En la representación topológica se debe elegir el grado de discretización suficiente para cumplir con los objetivos de la aplicación a la que se destina y que ayude a reducir el tiempo de cómputo del algoritmo.

La aplicación principal a la que se destina el robot en este trabajo es la de vigilancia, por lo que el robot debe ser capaz de alcanzar las puertas de cada despacho para poder realizar una inspección de las mismas de forma teleoperada. Se han seleccionado dos tipos de nodos: los nodos de puerta (son aquellos que quedan en los pasillos enfrente de cada puerta de despacho) y los nodos extremos (que son aquellos que quedan al principio y final de cada pasillo y son útiles para realizar el enlace entre los mismos). La Figura 3 muestra un ejemplo de la discretización de un entorno de ejemplo y su representación topológica. Los nodos de puerta se muestran mediante círculos y los nodos extremos se muestran como cuadrados.

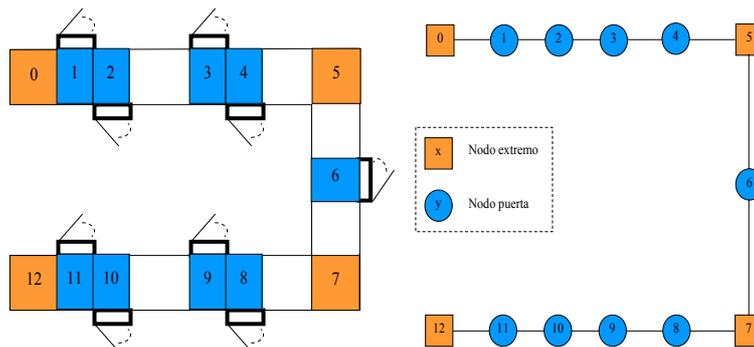


Fig. 3 Ejemplo de discretización de un entorno y su representación topológica

3.2 Conjunto de estados

Por cada nodo se definen dos estados, uno en el sentido de avance y otro en el sentido de retroceso, como se muestra en la Figura 4. Denotando el sentido de avance como aquél que va desde el nodo 0 hasta el último nodo del grafo y el de retroceso al que va en sentido contrario.

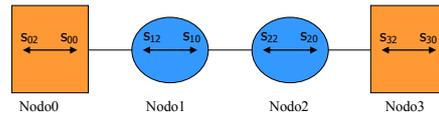


Fig. 4 Estados definidos por cada nodo

3.3 Conjunto de acciones

El conjunto de acciones se selecciona para realizar las transiciones entre cada uno de los estados del entorno, y son realizadas por el navegador de bajo nivel. La incertidumbre que existe sobre el efecto de cada una de las acciones se modela mediante su correspondiente matriz de transición T . La Tabla 1 muestra el conjunto de acciones seleccionadas.

Tabla 1. Conjunto de acciones.

Acción	Símbolo	Estados donde es posible ejecutarla
Avanzar por pasillo (follow corridor)	a_F	En todos aquellos estados en los que el robot tiene un pasillo delante
Dar la vuelta (turn around)	a_T	Sólo en aquellos estados en los que el robot tiene pared a ambos lados, por lo general coincidirán con los nodos extremos
Girar a derecha (turn to the right)	a_R	Aquellos estados de extremo en los que se conecta un pasillo a la derecha
Girar a izquierda (turn to the left)	a_L	Aquellos estados de extremo en los que se conecta un pasillo a la izquierda
No operación (no operation)	a_{NO}	En los estados seleccionados como destino

3.4 Conjunto de observaciones

Se emplean tres tipos de observaciones en el diseño del POMDP: una procedente de la medida de la señal WiFi ($obs_{wifi_{APu}}$), y dos procedentes de la medida de los ultrasonidos ($obs_{sus_{DD}}$ y $obs_{sus_{OZ}}$).

La observación $obs_{wifi_{APu}}$ representa el valor medio de 60 muestras de la señal recibida desde cada uno de los U puntos de acceso del entorno. Existiendo tantas observaciones de la señal WiFi como puntos de acceso en el entorno. Como se demuestra en trabajos anteriores de los autores [11][12], el valor medio de un número determinado de muestras de la señal WiFi resulta ser estable, filtrando el posible ruido del sensor, además de ser el valor ideal del número de muestras para conseguir un porcentaje de aciertos del 100% en la localización con medida de la señal WiFi.

El valor medio obtenido se redondea a un valor entero con el fin de obtener un espacio discreto de valores. El margen de valores posibles de esta observación va desde el valor 0 hasta 99, correspondiéndose con los valores medidos en el interfaz WiFi 0 y -99dBm.

La observación de ultrasonidos $obs_{sus_{DD}}$ se obtiene de la capacidad que tiene el navegador local para detectar las puertas en los laterales del robot. Estas puertas se detectan cuando se encuentran en una depresión mayor a 5cm respecto de la pared (condición que se cumple en la mayoría de edificios públicos, oficinas, etc.). Los posibles valores de la observación se muestran en la Figura 5.

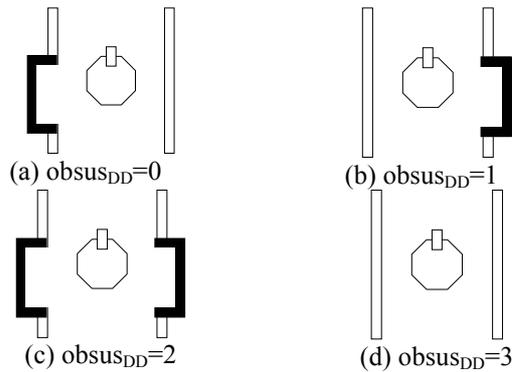


Fig. 5 Posibles valores de la observación $obs_{sus_{DD}}$: (a) detectada puerta en el lado izquierdo, (b) en el lado derecho, (c) en ambos lados, (d) ninguna puerta

La observación $obs_{sus_{OZ}}$ se obtiene por medio de la definición de tres zonas de ocupación en los laterales y el frontal del robot, indicando los ultrasonidos que zona se encuentra abierta y cual está ocupada. Las posibles combinaciones de las tres zonas dan ocho posibles valores, de los cuales cuatro coinciden con el valor de $obs_{sus_{DD}}$. Esta observación, a diferencia de la anterior, resulta útil para realizar la discriminación entre los estados de extremo.

3.5 Modelado de las incertidumbres de las acciones

La matriz de transición T modela la incertidumbre sobre la ejecución de las acciones. La matriz T representa la probabilidad de pasar de un estado s_t al estado s_{t+1} cuando se ha ejecutado la acción a_t . Las dimensiones de la matriz son $n_{est} \times n_{est}$, donde n_{est} representa el número máximo de estados del grafo.

3.6 Modelado de las incertidumbres de las observaciones

La función de observación \mathcal{G} aporta la información sobre la incertidumbre de las observaciones al POMDP. En este trabajo \mathcal{G} se representa con una matriz para cada una de las observaciones. Donde las dimensiones de las matrices se corresponden con el número de estados totales del entorno por los posibles valores de cada observación ($n_{est} \times \text{valores}_{obs}$).

La matriz de la observación de $obs_{wifi_{APu}}$ representa la probabilidad de obtener ruido en la medida de la señal WiFi en el interfaz del robot. Este ruido puede estar provocado por la interferencia de un dispositivo que trabaje en la misma frecuencia que la señal WiFi (2.4GHz), por una modificación esporádica del entorno o incluso por la presencia de personas en el entorno, ya que es la frecuencia de resonancia del agua.

Las matrices de observación correspondientes a las observaciones de ultrasonidos ($obs_{us_{DD}}$ y $obs_{us_{OZ}}$) modelan la probabilidad de obtener un error en la obtención de las mismas. Las posibilidades de fallos en este sensor se deben principalmente al paso de personas o a la obstrucción esporádica de personas u objetos en el entorno.

3.7 Política

Existen diferentes algoritmos para resolver la selección de la acción ideal a ejecutar en cada estado para que el robot alcance el objetivo. En un POMDP el problema es mayor que en un MDP ya que no se conoce con certeza el estado actual, sino que se mantiene una distribución de creencia sobre todos los estados.

En [12] y [13] se resuelve el MDP subyacente y a continuación emplean diferentes métodos para conseguir la acción óptima.

En este trabajo se emplea el método del estado más parecido o MLS (Most Likely State), ya que el empleo de una observación global como es la de la señal WiFi consigue unos estados estimados con una gran probabilidad de acierto.

3.8 Aprendizaje de los parámetros del POMDP

En algunos trabajos sobre POMDPs [12][13][14], introducen los valores de las matrices de transición y observaciones de forma manual en base al conocimiento de un experto. En este trabajo se realiza un aprendizaje automático de los parámetros del POMDP mediante un algoritmo de SLAM (Simultaneous Localization And Mapping,

“Localización y Mapeado Simultáneos”), basado en el conocido algoritmo Baum-Welch y que ha sido denominado WSLAM (Wifi-SLAM).

El algoritmo WSLAM se define como aquel que es capaz de obtener la posición estimada s_t del robot y el mapa de marcas del entorno Θ a partir de un conjunto de tramas de entrenamiento. Suponiendo que dichas tramas están formadas por las acciones a_T ejecutadas por el robot en cada estado y la observación WiFi de un único punto de acceso obs_{wifi}_T (trama= $\{obs_{wifi}_1, a_1, \dots, obs_{wifi}_T, a_T\} = \{obs_{wifi}^T, a^T\}$) el algoritmo WSLAM se definirá como se muestra en la expresión (2).

$$p(s_t, \Theta | obs_{wifi}^T, a^T) \quad (2)$$

En este trabajo se emplea la capacidad del navegador de bajo nivel para guiar al robot de forma autónoma por los pasillos para generar las tramas de entrenamiento. Una vez que se dispone de las mismas se ejecuta el algoritmo WSLAM para realizar el aprendizaje y generar tanto el mapa de marcas como la matriz de transición mediante una cuenta de frecuencias. El mapa de marcas en el caso de la señal WiFi se corresponde con las matrices de observación para cada una de las observaciones. Dichas matrices son inicializadas mediante un modelo de propagación con el objetivo de acelerar el proceso de convergencia del algoritmo. Este proceso constituye una fase de aprendizaje previa, de forma que cuando el robot aprende las matrices de observación y transición se pasa a la fase de seguimiento en la que el robot estará navegando y localizándose de forma local en el entorno.

4 Sistema de Localización

El sistema de localización actualiza la distribución de creencia bien tras la ejecución de una acción mediante la etapa de *predicción*, o bien tras obtener una nueva observación, o fase de *estimación*. La primera utiliza la función de transición de estados para calcular la nueva creencia Bel_t tras la ejecución de una acción a y en base a la creencia anterior Bel_{t-1} . En la segunda se emplea la función de observación para calcular la nueva creencia $Bel_{posterior}$ a partir de una nueva observación y con la creencia anterior $Bel_{anterior}$ aplicando a cada estado la regla de Bayes. La Figura 6 muestra el proceso de sistema de localización.

Las observaciones de la WiFi (obs_{WiFi}), de ultrasonidos de puerta detectada (obs_{USDD}) y de ultrasonidos de zona abierta (obs_{USOZ}) se incorporan a la observación del POMDP mediante un proceso de fusión multisensorial. Uno de los métodos más extendidos es la *Fusión Bayesiana*.

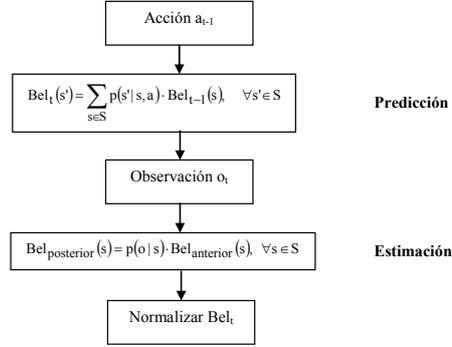


Fig. 6 Proceso de localización dentro del sistema de navegación POMDP

El modelo de observación de un POMDP permite fusionar información procedente de diferentes sensores utilizando el marco Bayesiano. Si se supone independencia entre todas las observaciones, la función de observación se calculará multiplicando las probabilidades individuales de cada una de las observaciones como se muestra en la expresión (3).

$$\begin{aligned}
 p(\bar{o} | s) &= p(\text{obswifi}_{AP1}, \dots, \text{obswifi}_{AP_u}, \text{obsus}_{DD} | s, \text{obsus}_{OZ} | s) = \\
 &\underset{\text{ind.}}{=} p(\text{obswifi}_{AP1} | s) \cdot \dots \cdot p(\text{obswifi}_{AP_u} | s) \cdot p(\text{obsus}_{DD} | s) \cdot p(\text{obsus}_{OZ} | s)
 \end{aligned} \tag{3}$$

Donde $p(\bar{o} | s)$ representa la probabilidad de obtener el vector de observación \bar{o} en el estado s , $p(\text{obswifi}_{AP_u} | s)$ representa la probabilidad de obtener la observación de WiFi del AP_u en el estado s , el término $p(\text{obsus}_{DD} | s)$ indica la probabilidad de obtener la observación de ultrasonidos de puerta detectada en el estado s y $p(\text{obsus}_{OZ} | s)$ expresa la probabilidad de obtener la observación de ultrasonidos de zona abierta en el estado s .

5 Resultados experimentales

En primer lugar se describe el entorno de trabajo en el que ha sido llevada a cabo la implementación del sistema y sobre la que han sido validados los sistemas de localización y navegación propuestos con un robot real para a continuación mostrar los resultados de las pruebas reales.

5.1 Entorno de pruebas

El entorno de pruebas se ha situado en la tercera planta de la Escuela Politécnica de la Universidad de Alcalá, concretamente en la parte asignada al Departamento de Electrónica. La configuración de dicho departamento se muestra en la Figura 7(a).

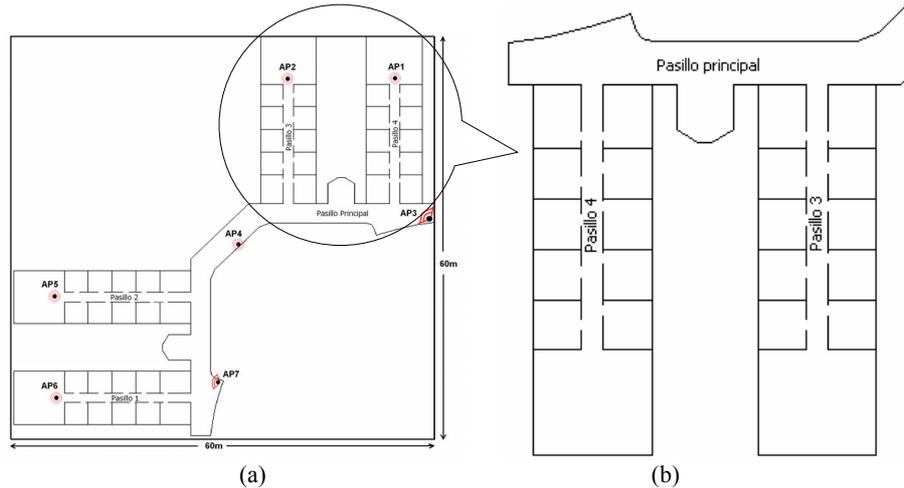


Fig. 7 (a) Planta 3ª del Departamento de Electrónica y (b) Detalle de la zona bajo estudio

Como se puede ver en dicha figura el entorno es simétrico respecto de la diagonal principal, lo que ha permitido realizar las medidas únicamente para la zona señalada, y que engloba los Pasillos 3, Pasillo 4 y Pasillo Principal, sin perder generalidad, como se muestra en la Figura 7(b).

Se han instalado 7 APs (WBRE-54G) con el objetivo de disponer de la cobertura de al menos 3 puntos de acceso en cada nodo del entorno. Como robot real se ha empleado un Pioneer 2AT de Activmedia Robotics (Figura 8).

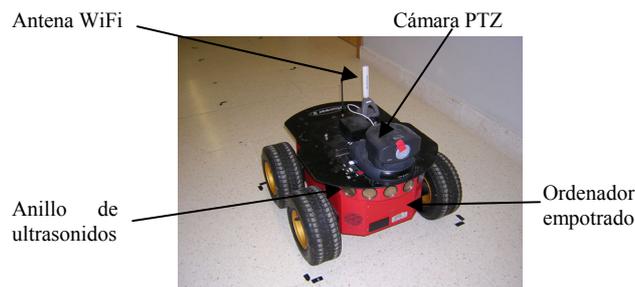


Fig. 8 Robot empleado durante las pruebas del sistema

5.2 Resultados del entrenamiento

En la siguiente figura se muestra el resultado del entrenamiento empleando las observaciones de la señal WiFi y los ultrasonidos. Para realizar el aprendizaje de las observaciones WiFi se ha empleado el algoritmo WSLAM mientras que para las observaciones de los ultrasonidos se ha empleado el algoritmo Baum-Welch.

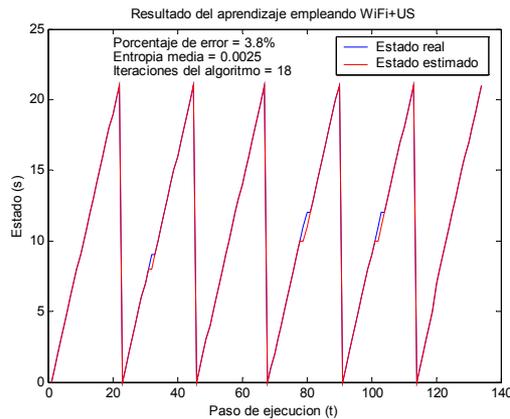


Fig. 9 Resultados del aprendizaje empleando WiFi y ultrasonidos

El porcentaje de error que obtiene es tan sólo de un 3.8% y realiza el aprendizaje en tan sólo 18 iteraciones del algoritmo.

5.3 Resultados de la localización

En la Figura 10 se muestra el porcentaje de fallos en la localización a lo largo del tiempo y en función de las condiciones del entorno. Los experimentos han sido llevados a cabo a lo largo de una hora en la que el robot ha estado navegando de forma autónoma por el entorno para diferentes condiciones, como son: con gran volumen de tráfico de personas y con dispositivos inalámbricos en las cercanías, medio volumen de tráfico y bajo volumen.

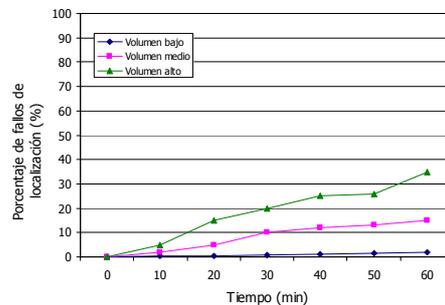


Fig. 10 Fallos de localización en función del tiempo

Se demuestra como la evolución del porcentaje de error es creciente en función del tiempo durante el cual se está ejecutando el algoritmo de localización y es mayor cuanto mayor volumen de personas y dispositivos inalámbricos se encuentran en el entorno, ya que introducen mayor ruido en la medida de la señal WiFi.

5.4 Resultados de la navegación

El sistema de navegación global POMDP permite recuperarse ante los errores del sistema de localización mediante la distribución de creencia, ya que ésta mantiene la probabilidad de acierto sobre todos los estados posibles.

En la siguiente tabla se muestran los resultados generales del sistema de navegación global obtenidos para 50 destinos diferentes encadenados usando la plataforma real.

Tabla 2. Resultados de la navegación global.

		NÚMERO DE CASOS	PORCENTAJE
Aciertos en la consecución del destino	De forma directa	45	90%
	Con correcciones	4	8%
Fallos de consecución del destino	Globales	1	2%
	Bucles	0	0%

Cuando se habla de consecución del destino de forma directa se está diciendo que el robot alcanzó el destino en una trayectoria directa sin tener que realizar correcciones en el sentido de la marcha, a diferencia de las consecuciones del destino mediante correcciones realizadas después de alguna maniobra de recuperación del sistema de localización.

Por fallos globales en la consecución del destino se entienden aquellos fallos en los que el robot no ha alcanzado el destino y además ha quedado en una situación imposible de recuperarse, mientras que los fallos de bucles son aquellos en los que entra el robot sin posibilidad de alcanzar el destino.

6 Conclusiones y trabajos futuros

Se ha propuesto un sistema de localización probabilístico basado en medida de la señal WiFi siendo el primero en emplear una fusión de ésta con la observación procedente de los ultrasonidos.

La fusión con un observador local consigue mejorar la robustez del sistema a nivel global, ya que las observaciones de ultrasonidos permiten discriminar fácilmente entre estados consecutivos. Se demuestra que la fusión entre un sensor global (WiFi) y otro local (US) ayuda a la convergencia y robustez del algoritmo desde la primera iteración del mismo.

El sistema de navegación propuesto en esta tesis, según nuestro conocimiento actual, es el primero en emplear observaciones de la señal WiFi, demostrando que con un sistema de localización basado en medida de la señal WiFi se puede navegar de forma global en interiores.

Se aporta un método de aprendizaje automático del mapa WiFi basado en la capacidad del navegador local para guiar al robot por los pasillos de forma totalmente autónoma al cual se le ha denominado WSLAM. Éste utiliza una particularización del algoritmo Baum-Welch para observaciones de tipo WiFi.

Como línea futura a seguir se pretende emplear un modelo de acción basado en un sensor láser en lugar de ultrasonidos. El empleo de un modelo de acción basado en láser mejoraría los resultados obtenidos respecto de los ultrasonidos o la odometría como se demuestra en el trabajo [9].

6 Agradecimientos

Este trabajo ha sido financiado con el proyecto ADVOCATE II (IST-2001-34508) de la Comisión Europea y el Proyecto de Acción Especial de ADVOCATE II (TIC2002-10744-E) del Ministerio de Ciencia y Tecnología (MCyT). Queremos agradecer especialmente a los participantes de ADVOCATE II: Universidad de Alcalá, GETRONICS DECAN, Universidad Politécnica de Madrid, ATLAS Elektronik GmbH, Ifremer, HUGIN Expert A/S, INNOVA S.p.A y E-MOTIVE.

Referencias

1. I. Cox, "Blanche-an experiment in guidance and navigation of an autonomous robot vehicle". IEEE Transactions on Robotics and Automation, 7(2), pp. 193-204, 1991.
2. R. Want, A. Hopper, V. Falco and J. Gibbons, "The Active Badge location system". ACM Transactions on Information Systems, 10, pp. 91-102, January 1992.
3. J. Krumm, S. Harris, B. Meyers, B. Brumitt, M. Hale, and S. Shafer, "Multi-camera, Multi-Person Tracking for Easy Living". 3rd IEEE International Workshop on Visual Surveillance, pp. 3-10, Piscataway, NJ, 2002.
4. N. B. Priyantha, A. Chakraborty, and H. Balakrishnan, "The Cricket Location Support System". Proceeding of the 6th ACM MobiCom, pp. 155-164, July 2002.
5. Abowd, "The Smart floor: A Mechanism for Natural User Identification and Tracking". Proceedings of the Conference on Human Factors in Computing Systems, pp. 1-6, Hague, Netherlands, April 2000.
6. P. Bahl, and V. N. Padmanabhan, "RADAR: A, In-building RF-based User Location and Tracking System". Proceedings of the IEEE Infocom 2000, vol.2, pp. 775-784, Tel Aviv, Israel, March 2000.
7. P. Enge and P. Misra, "Special issue on GPS: The Global Positioning System". Proceeding of the IEEE, pp. 3-172, January 1999.
8. P. Castro, P. Chiu, T. Kremenek, T. Muntz, "A Probabilistic Room Location Service for Wireless Networked Environments", Ubiquitous Computing 2001. 2001.
9. A. Howard, S. Siddiqi, G. Sukhatme, "An Experimental Study of Localization Using Wireless Ethernet", Proceeding of 4th International Conference on Field and Service Robotics. 2003.
10. M. Ocaña, L.M. Bergasa, M.A. Sotelo, "Robust Navigation Indoor Using WiFi Localization", Proceedings of the 10th IEEE International Conference on Methods and Models in Automation and Robotics, pp. 851-856, Miedzyzdroje, Poland, 30 August-2 September 2004.

11. M. Ocaña, L.M. Bergasa, M.A. Sotelo, J. Nuevo, R. Flores, "Indoor Robot Localization System using WiFi signal measure and minimizing calibration effort", Proceedings of the IEEE International Symposium on Industrial Electronics, Dubrovnik, Croatia, June 2005. 2005.
12. A.R. Cassandra, L.P. Kaelbling, J.A. Kurien, "Acting under uncertainty: Discrete Bayesian models for mobile robot navigation", Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems. 1996.
13. S. Koenig, R. Simmons, "Xavier: a robot navigation architecture based on partially observable Markov decision process models", Artificial intelligence and mobile robots, pp. 91-122. 1998.
14. I. Nourbakhsh, R. Powers, S. Birchfield, "Dervish: and office navigating robot", AI Magazine, vol. 16, n°2, pp. 53-60. 1995.