

Influencia de la variabilidad del canal en un sistema de localización para interiores

Alejandro Martínez Sala, Raúl Guzman Quirós, Esteban Egea López
Departamento de Tecnologías de la Información y las Comunicaciones
Universidad Politécnica de Cartagena (UPCT)
Antiguo Cuartel de Antigüones (Campus Muralla del Mar), 30202 Cartagena
AlejandroS.Martinez@upct.es, Raul.Guzman.Quiros@gmail.com, Esteban.Egea@upct.es

Resumen- Los sistemas de localización en interiores son la base de prometedores servicios telemáticos conscientes del contexto y entorno y se requiere un control de la posición con un error acotado. La medida de potencia de la señal recibida se puede usar como métrica para determinar la posición a partir de un algoritmo de localización. Se requiere hacer medidas para caracterizar los patrones de la señal recibida en un conjunto de puntos de interés (técnica de *fingerprint*). El canal en un interior es difícil de modelar y presenta un comportamiento aleatorio. En este trabajo de investigación se usan redes neuronales como herramienta matemática que aprende los patrones del *fingerprint* y su posición (x,y) asociada y son capaces de estimar una posición. Se evalúan varias arquitecturas del perceptron multicapa y se analiza el error de la estimación de la posición y su influencia con la variabilidad del canal para un escenario de una red WiFi.

Palabras Clave- localización, entorno interior, canal estocástico, WLAN, red neuronal.

I. INTRODUCCIÓN

Los sistemas de localización son claves para el desarrollo e implantación de servicios telemáticos contextuales y conscientes del entorno [1]. De especial relevancia son los servicios que se pueden ofrecer en entornos de interior; sistemas de ayuda y navegación para discapacitados, control y seguimiento de pacientes o equipos en hospitales, servicios contextuales en museos, aeropuertos, galerías comerciales, etc. Estos sistemas requieren de un sistema de posicionamiento que permita saber con un reducido y acotado margen de error su ubicación. La tecnología GPS no es adecuada para entornos de interior debido a la escasa o nula cobertura de los satélites de la red de posicionamiento por lo que hay que recurrir a otras tecnologías inalámbricas para la localización.

Cada vez es más frecuente que en un entorno objetivo haya desplegada una infraestructura de puntos de acceso (*Access Point*, AP) WiFi interconectados a una red Ethernet cableada. A su vez, los terminales móviles (*Mobile Stations*, MS) que portan los usuarios se van abaratando, aumentado su capacidad de proceso y una gran mayoría están dotados de una interfaz WiFi. Por tanto, el amplio despliegue y adopción de las redes WiFi supone que esta tecnología de comunicaciones sea un soporte idóneo para el desarrollo de servicios de localización en interiores.

Un sistema de posicionamiento calcula la posición a partir de parámetros de la señal generada entre un MS y varios AP, después procesa la señal medida mediante un algoritmo de localización que estima la posición del MS.

Existen varias medidas que se pueden hacer de una señal de radiofrecuencia para determinar la posición de su emisor: *Angle of Arrival* (AoA), *Time of Arrival* (ToA) y *Received Signal Strength* (RSS) [1]. La medida del AoA y el ToA requiere de hardware especial y no es sencilla de conseguir con todo el hardware WiFi comercial. Sin embargo, lo más común, barato y disponible en cualquier equipo WiFi es la medición de la potencia de señal recibida (RSS).

En un entorno interior el canal inalámbrico a 2.4GHz, usado en el estándar IEEE 802.11, se comporta de forma estocástica y es complejo de caracterizar debido a la disposición física de los muros y obstáculos, el predominio de la propagación NLoS (*No Line of Sight*), es decir sin tener visión directa entre el emisor y el receptor, y efectos de desvanecimientos de la señal (*fading*) debidos al multicamino (*multipath*) y la propia naturaleza dinámica del entorno (movilidad de objetos y las propias personas). Por tanto se constata que la potencia de la señal recibida RSS no sigue un modelo determinista ideal sino que es una variable aleatoria difícil de modelar y dependiente del entorno y escenario de interés.

A su vez los algoritmos de localización se pueden clasificar como basados en la distancia o como un problema de reconocimiento de patrones. Así un ejemplo de algoritmo basado en distancia sería el basado en triangulación donde, a partir de un modelo de canal, se calcula la distancia relativa de un MS con al menos tres AP para estimar su posición. Debido a la naturaleza estocástica de un canal inalámbrico estos métodos producen errores bastante elevados y no son muy aconsejables para interiores.

Un algoritmo de localización fundamentado en reconocimiento de patrones usa una señal característica, como la RSS, que forma un patrón determinado en varios puntos específicos y conocidos. La técnica de medir los patrones característicos de la RSS se denomina RF *fingerprint* y requiere una campaña de medidas (proceso *offline* también denominado de calibración) para crear el "mapa radio" (*radio map*) del entorno de interés. Se constata que los puntos del *radio map* deben ser significativos y con una cantidad mínima para lograr una adecuada precisión. Durante la fase *online* de localización, la posición del MS se estima comparando la señal medida con el *radio map*. Existen varias propuestas de algoritmos basados en reconocimiento de patrones que usan la técnica del *fingerprint*: RADAR [2] es una de las primeras propuestas de sistemas de localización usando WiFi que usa el algoritmo

KNN (*K-Nearest Neighbors*) donde la señal muestreada de un transmisor se compara con todos los patrones del *radio map* buscando el patrón de referencia con la menor distancia Euclídea. EKAHAU [3] es el principal sistema de localización comercial WiFi que usa clasificadores bayesianos y técnicas estadísticas para inferir la posición. Battiti *et. al.* [4] propone el uso de una red neuronal del tipo perceptrón multicapa en un entorno de 640 m² con 3 AP usando medidas reales obtenidas de terminales WiFi; se fija y expone una única arquitectura de la red neuronal obteniéndose un error medio de 1.82 metros.

En el presente artículo se parte del trabajo de Battiti *et. al.* [4] pero estudiando y comparando el desempeño de varias arquitecturas del perceptrón multicapa y parámetros de aprendizaje en un entorno tipo oficina de mayor superficie (2500 m²) con tres AP pero además del error medio, se usa la probabilidad del error que es una métrica más representativa y exigente para evaluar un sistema de localización. Finalmente, se analiza mediante simulación la influencia del canal en el aprendizaje de la red neuronal y en el error cometido, usando modelos del canal determinista hasta un canal aleatorio con una alta variabilidad.

El resto del artículo se estructura en los siguientes apartados. En la sección II se describe el modelo del entorno y del canal usado, así como el escenario de simulación. A continuación se definen las métricas para evaluar el desempeño del sistema. En la sección IV se explica y justifica la arquitectura del perceptrón multicapa escogida y sus principales parámetros de configuración. Después en la sección V se presentan y analizan los resultados para finalizar con la sección VI de Conclusiones.

II. MODELADO DEL ENTORNO Y CANAL

Un objetivo del presente trabajo de investigación ha sido el desarrollo de una herramienta de simulación para estudiar y probar sistemas de localización basados en herramientas matemáticas de reconocimiento de patrones RSS usando la técnica de *fingerprint*. En este enfoque se ha querido evitar el tener que hacer tediosas campañas de medidas de la potencia de la señal recibida. Se pretende tener modelos fiables que marquen una tendencia de toda la capa física y, de una forma controlada, analizar la tendencia de la bondad y desempeño de la herramienta matemática de localización ante un canal estocástico y con un coste computacional asumible.

A. Modelado del canal WiFi en un entorno interior

Teniendo en cuenta los requisitos preestablecidos, se ha escogido un modelo de canal para el estándar IEEE 802.11 a 2.4GHz que está recomendado para la estimación de la potencia de la señal recibida [5,6]. Este modelo está basado en un modelo de *path-loss* a dos pendientes y se ha modificado añadiendo las pérdidas por atenuaciones debidas a obstáculos (como muros, puertas, ventanas, etc.) [7].

El modelo de *path-loss* consiste en una pérdidas por espacio libre, L_{FS} con pendiente de pérdidas α_1 para distancias menores que una distancia d_{BP} (denominado punto de ruptura o *Breaking Point*) y α_2 para distancias mayores del punto de ruptura. El modelo de *path-loss* de espacio libre se define como:

$$L_{FS}(d) = L_0 + 10\alpha_1 \log_{10}(d) + X \quad (1)$$

Para el caso general de *path-loss* tenemos la siguiente función de pérdidas con la distancia:

$$L(d) = \begin{cases} L_{FS}(d) + \sum L_{obs} + X, & d \leq d_{BP} \\ L_{FS}(d_{BP}) + 10\alpha_2 \log_{10}\left(\frac{d}{d_{BP}}\right) + \sum L_{obs} + X, & d > d_{BP} \end{cases} \quad (2)$$

Donde L es la atenuación (en dB) a una distancia d entre un emisor y el receptor para el modelo de canal propuesto que tiene tres términos: a) componente de *path-loss* en dB, d es la distancia considerada como la línea que recorre el rayo directo (en metros), α_1, α_2 es la pendiente de pérdidas antes y después del denominado punto de ruptura o d_{BP} (en metros). b) Además se ha añadido un término de pérdidas por obstáculos que suma las pérdidas debidas a que la señal atraviese un muro, una puerta, etc. Dependiendo del tipo de obstáculo y material en [7] se definen los valores aconsejables de L_{obs} (dB). c) Finalmente la componente aleatoria X modela el efecto del *shadow fading* mediante una variable aleatoria gaussiana de media cero y varianza σ_x :

$$f_x(x) = \frac{1}{\sqrt{2\pi}\sigma_x} e^{-\frac{x^2}{2\sigma_x^2}} \quad (3)$$

B. Descripción de la herramienta de simulación

El simulador está implementado en Matlab y usa la toolbox de Redes Neuronales [8] para desarrollo del motor de localización.

La herramienta de simulación permite caracterizar y representar un entorno de interior formado por plantas, habitaciones, pasillos y obstáculos. Una vez representado se crea un sistema de referencia cartesiano del escenario donde se posicionan los AP.

A continuación se definen los parámetros del modelo de canal según la eq. (2). En este modelo hay una componente determinista, dependiente de la geometría y materiales de los muros, puertas y ventanas, y una componente aleatoria que modela la variabilidad del canal.

La capa física implementada en el simulador incorpora el modelo de *path-loss* con *shadowing*, las pérdidas de atenuación por obstáculos, la ganancia y diagrama de radiación de las antenas de los AP y MS y parámetros básicos del hardware como la potencia de transmisión y el umbral de sensibilidad.

Una vez que se definen los parámetros de la capa física se se seleccionan una serie de puntos en el escenario, ya sea por medio de un mallado o *grid*, generados de forma aleatoria o simplemente seleccionando manualmente un número de puntos secuenciales (que podrían representar la ruta seguida por un MS).

Seguidamente se pasa a una segunda fase que engloba dos cálculos; por cada punto de acceso y para cada punto generado sobre el layout 2D se realiza un cálculo de la componente determinista del modelo en el que se evalúan las pérdidas producidas por la distancia (según modelo de *path-loss* fijado) y por obstáculos atravesados (muros, puertas y otros). A su vez se realiza un segundo cálculo que incorpora posibles efectos del canal que añaden una componente aleatoria a la señal, como puede ser el efecto de *shadowing*.

El hecho de trabajar de esta manera permite realizar las simulaciones de forma más rápida al poder obtener sólo una vez la parte determinista, y sobre dicho cálculo aplicar de forma rápida varios modelos controlados con parámetros que

incorporen cualquier aleatoriedad a la señal. De esta forma se tiene una herramienta de simulación abierta para incorporar otros efectos y fenómenos (como la variabilidad del hardware, etc.).

C. Descripción del escenario

El escenario objeto de estudio emula un entorno de oficinas típicas de 50mx50m que incorpora tres habitaciones y un pasillo (ver figura 2). Se considera que las habitaciones quedan separadas por paredes interiores de tipo ladrillo, que incorporan atenuaciones de 3dB cada una, según se especifica en [7]. A su vez, estas habitaciones se consideran oficinas típicas que, según los parámetros recomendados en [5,6] tienen un coeficiente $\alpha_1=2$ y $\alpha_2=3.5$ con un cambio de pendiente a 5 metros. Como parámetros recomendados, la variable aleatoria del *shadowing* puede oscilar entre 3 y 5 dB.

En el escenario simulado se han considerado varios canales, donde la componente determinista es idéntica, y donde se varía la componente aleatoria entre 1, 3 y 6 dB. Esta componente aleatoria máxima de 6 dB persigue incorporar y ser una primera aproximación a otros efectos aleatorios como las irregularidades en el diagrama de radiación de la antena y la variabilidad del hardware.

La potencia de transmisión se fija a 0 dBm y el umbral de sensibilidad de los receptores en -100 dBm. Las antenas de los AP y MS se consideran isotrópicas. Por último, los AP se sitúan a una altura de 2.2 metros y los MS se consideran que están a una altura media de 1.5m.

III. MÉTRICAS DEL SISTEMA DE LOCALIZACIÓN

Mediante la herramienta de simulación se obtiene como resultado final un conjunto de puntos (x,y) reales y los correspondientes valores (x',y') estimados. Se usa la distancia Euclídea como métrica para comparar la posición real y la estimada con la herramienta matemática. Del procesamiento estadístico se obtienen la función de densidad de probabilidad (fdp) del error de la posición.

A. Mean Absolute Error (MAE)

A partir de la fdp se calcula la esperanza del error que se denomina *Mean Absolute Error* (MAE) o error medio. Este estadístico es un punto de partida para evaluar un sistema de localización, pero es insuficiente para analizar su desempeño.

B. Precisión

La precisión se define como la probabilidad del error. Es decir, dada una posición (x',y') estimada, se garantiza con una cierta probabilidad que la posición real se encuentra a distancia menor o igual al error. Dicho de otra forma, si se obtiene una precisión de E metros con una probabilidad P cuando la red estime una posición, el punto (x,y) real se encuentra contenido con probabilidad P en el área delimitada por el punto estimado y un disco de radio E.

IV. ARQUITECTURA DE LA RED NEURONAL

Los modelos de redes neuronales son técnicas de autoaprendizaje que pueden resultar efectivas para resolver problemas de localización actuando como aproximadores universales. Una propiedad muy importante es que no se requiere un conocimiento previo de la geometría del entorno

(disposición de las habitaciones, muros y obstáculos), el modelo de propagación del canal ni la posición de los AP.

En el sistema que se presenta partimos de que las medidas de potencia de señal recibidas de un terminal móvil desde diferentes puntos de acceso (al menos tres) aportan la información necesaria para determinar la localización de su posición dentro de un área de trabajo. La función no lineal existente en un canal real entre potencia y distancia puede ser modelada de forma aproximada mediante redes neuronales a partir de la optimización de ciertos parámetros (pesos) de la misma, garantizándose un buen aprendizaje de la relación entre entradas (potencias de señal) y salidas (posición (x,y)), resultando estimaciones de las coordenadas con errores permisibles.

Por tanto, el objetivo es conseguir que nuestra red neuronal sea capaz de estimar dichas coordenadas (x,y) a partir de tres entradas: un vector de potencias de la señal que reciben tres puntos de acceso (RSS₁, RSS₂, RSS₃) durante un mismo intervalo de tiempo.

Para afrontar este problema se ha planteado un tipo de red neuronal muy común en problemas de clasificación y aproximación de funciones denominado redes neuronales multicapa (del inglés *Multilayer Perceptron*, MLP). Estas redes requieren de una fase de entrenamiento mediante un aprendizaje supervisado a partir del *radio map* creado del entorno en la que tenemos un conjunto de entradas (medidas RSS en puntos (x,y) conocidos) y salidas deseadas (posiciones (x,y) reales del terminal móvil), para optimizar los pesos de la red en base a la minimización de una función de error, consiguiendo así reducir en la medida de lo posible el error de generalización.

El error de generalización es un concepto muy importante que define el comportamiento de la red neuronal ya entrenada ante ejemplos de entradas nunca antes vistos por la misma (no usados como muestras de entrada en la fase de entrenamiento). Es decir, el concepto habla de la capacidad de generalización de la red en términos de error ante muestras genéricas que pudiesen aparecer. A cada época de entrenamiento, se le introduce en un orden aleatorio el conjunto de muestras de entrenamiento, de manera que la red adapte los pesos cada vez para minimizar la función de error. Si se sobreentrena en exceso la red neuronal con demasiadas épocas se corre el riesgo de que la red adapte sus pesos demasiado bien a las muestras del conjunto usado para el aprendizaje y sea muy precisa para los ejemplos de entrenamiento, pero pierda capacidad de generalización cometiendo errores altos en la posición estimada ante patrones de entrada no vistos nunca antes. En cambio, si no se usara el suficiente número de épocas en el entrenamiento se puede llegar a cometer errores altos por falta de optimización de los pesos.

La arquitectura del perceptron multicapa utilizada se organiza como sigue: las entradas se procesan secuencialmente a través de las distintas capas ocultas de la red, donde cada unidad ("neurona") calcula un producto escalar entre un vector de pesos y el vector de salidas dado por la capa previa. Una vez calculado dicho producto escalar, se aplica una función de transferencia (función de activación de la neurona) cuya salida forma parte del vector de entradas de la siguiente capa. Las funciones de transferencia evaluadas son la tangente hiperbólica y la sigmoidea para las neuronas de la capa oculta. La función de activación de las neuronas de

la capa de salida es la función identidad (lineal) para no limitar los valores de salida obtenidos por la red.

Por tanto, las arquitecturas evaluadas tienen tres neuronas en la capa de entrada (cada una conectada a un AP), un número variable de capas ocultas (1, 2 y 3) con un mismo número de neuronas en cada capa (desde 4 hasta 128 neuronas) y dos neuronas en la capa de salida que devuelven la coordenada X y la coordenada Y de la posición.

Para el entrenamiento de la red se ha utilizado un algoritmo iterativo basado en el método tradicional de Newton que se denomina algoritmo Levenberg Marquardt [9], el cual ha demostrado presentar un buen rendimiento para el entrenamiento de este tipo de redes en otros problemas de aproximación de funciones. Este algoritmo se basa en el uso del gradiente para minimizar la función de error usando la técnica de retropropagación (el inglés *back-propagation*) la cual se explica en el capítulo 11 de [10].

Respecto a la función de error a minimizar en el entrenamiento se ha usado el error cuadrático medio (MSE), definido como:

$$MSE = \sum_{n=1}^N (t_n - o_n(\omega))^2 \quad (4)$$

Donde se observa como la función depende tanto de la diferencia entre las salidas estimadas por la red que es función de los pesos ω en ese instante, como de las salidas deseadas (también denominadas *target*) asociadas a la entrada.

El número de muestras de entrenamiento es un parámetro importante porque refleja cuantos datos se necesitan para que una red pueda aprender adecuadamente las características y particularidades de los patrones RSS del entorno y así aproximar la posición del terminal móvil.

V. METODOLOGÍA DE TRABAJO

En el trabajo de investigación realizado se emplea una herramienta de simulación y en la metodología de trabajo se han seguido las siguientes fases:

A. Caracterización del entorno y layout 2D

En este paso se define el *layout 2D* indicando las habitaciones y obstáculos existentes. Se genera un sistema de referencia cartesiano del entorno. Finalmente para dicho entorno se crea una capa de puntos de acceso que se fijan con unas coordenadas (x,y) determinadas y se les da un atributo de altura, necesario para calcular la distancia Euclídea con un MS.

B. Parámetros del modelo de capa física

En esta fase se ajustan los valores del modelo de *path-loss* para cada una de las zonas del entorno. En especial se configura la variabilidad del canal debida al *shadowing* fijando el valor de la componente gaussiana expresada en dB. A su vez, se configura el tipo de muro (según el material y el grosor) y se definen los parámetros de las pérdidas de atenuación (en dB) causadas cuando la señal atraviesa dicho muro. Finalmente, se fija el diagrama de radiación de las antenas de los AP y MS, la potencia de transmisión y el umbral de sensibilidad del hardware WiFi.

C. Cálculo de coberturas de los AP y generación de datos de aprendizaje y testeo

Para el cálculo de la cobertura que ofrecen los AP en el entorno una vez fijados todos los parámetros del modelo (tanto del canal, como del hardware y los parámetros de las antenas del terminal como de cada AP) se genera un mallado (*grid*) de puntos fijando una distancia mínima de separación (resolución del *grid*) entre los mismos. A continuación se calcula la potencia que recibe cada AP desde un supuesto terminal colocado en cada uno de dichos puntos del *grid* obteniéndose la cobertura que ofrece cada AP en el área total evaluada en los puntos del *grid*.

Para la generación de campañas de datos tanto para entrenar la red como para testearla posteriormente, se fija un número total de puntos que se generan de forma aleatoria intentando cubrir todo el mapa interior de forma que el conjunto de muestras final sea suficientemente representativo de todo el escenario bajo estudio. Posteriormente, y al igual que para el cálculo de la cobertura, se calcula la potencia recibida por cada AP según el modelo de canal parametrizado.

Las muestras de aprendizaje emulan una campaña de medidas para generar el *radio map* según la técnica del *fingerprint* explicada anteriormente. Se genera un *radio map* para el caso de un canal determinista (variable aleatoria del *shadowing* de 0 dB), y para los casos de un canal con una variabilidad de 1 dB, 3 dB y 6 dB. Por tanto, cada *radio map* generado refleja la tendencia de un canal con nula variabilidad (determinista) hasta una alta variabilidad (*shadowing* de 6 dB).

A su vez, fijada la variable aleatoria gaussiana del canal, se genera un fichero de testeo con 800 muestras totalmente independientes y diferentes a las muestras de aprendizaje.

D. Comprobación de la red neuronal y extracción de los estadísticos de localización

Una vez que la arquitectura de la red neuronal converge a una solución, se le pasa el fichero de testeo y se compara cada punto la posición (x,y) real con la posición (x',y') estimada por la red. Se obtienen los estadísticos de error medio, la probabilidad de error al 95% y al 80%.

E. Análisis de resultados, tendencias y replanteamiento de hipótesis

Se analizan los resultados y se observan las tendencias en los estadísticos del error y la correlación con la arquitectura de la red y con los principales parámetros de configuración. Se vuelven a plantear hipótesis sobre el efecto de una arquitectura (número de capas ocultas y neuronas en capa oculta) y/o combinación de parámetros en la tendencia del error de generalización y se repiten los pasos previos.

F. Verificación y validación de los resultados

Una vez que una tendencia se ha contrastado para una determinada arquitectura y parámetros de configuración se vuelve a repetir el proceso de simulación pero variando hasta tres veces el *radio map* de entrenamiento y/o las muestras de testeo. Se debe volver a verificar la misma tendencia para contrastar y validar los resultados.

VI. RESULTADOS Y ANÁLISIS

Se han realizado 6400 redes entrenadas barriendo distintos parámetros de la arquitectura de la red como el número de capas ocultas, el número de neuronas por capa oculta o la función de transferencia de cada neurona combinado con distintos parámetros de la fase de entrenamiento de la red como el número de épocas o el número de muestras de entrenamiento de la red.

En aras de centrarse en los datos y resultados más relevantes, se resumen a continuación las principales pruebas y conclusiones obtenidas para descartar ciertas configuraciones y no explicarlas de forma extensa en los resultados.

Normalización de las señales de entrada a los AP

En la fase de entrenamiento se ha comprobado que la normalización de las entradas de los valores RSS en un rango de valores entre $[-1,1]$ (a partir del valor máximo medido de -29dBm y mínimo en el umbral de sensibilidad de -100dBm) era positiva de cara a la minimización del error de generalización y la convergencia del mismo en el entrenamiento. Por tanto los resultados se focalizan en el caso de datos normalizados.

Arquitecturas de una capa con 4, 8, 16 y 32 neuronas

Se ha comprobado que las arquitecturas que menores errores de generalización han obtenido eran de sólo una capa oculta. Con arquitecturas de 2, 3 y 4 capas no se conseguían mejores resultados por lo que no se van a exponer estos casos. Además, se ha comprobado que opciones de 64, 128 ó 256 neuronas en capa oculta no aportan ventajas sustanciales e incrementan bastante el coste computacional.

Función de transferencia tangente hiperbólica

Se ha comprobado que el uso de una función de transferencia del tipo tangente hiperbólica $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$, ofrece en general, mejores resultados para este problema en comparación con la función sigmoide, mientras que en la capa de salida se ha mantenido la función identidad para no limitar la salida.

Número de épocas

Para valores altos de épocas no se ha producido sobreentrenamiento. Se ha observado como para este problema el uso de entrenamientos con menos de 80 épocas y números de muestras entre 400 y 800 las redes conseguían errores de generalización aceptables y muy parecidos.

A. Resultados obtenidos

Los datos que se presentan a continuación están seleccionados para los siguientes rangos:

- Número de neuronas de la capa oculta: 4, 8, 16, 32.
- Variabilidad del canal: 0 dB, 1 dB, 3 dB, 6 dB.
- Número de muestras del *radio map*: 50, 100, 200, 400, 800.

En las tablas I-IV se muestra una selección de datos de las arquitecturas y configuraciones de interés. Se observa que para pocas muestras de aprendizaje, una red de 4 neuronas se comporta mejor que las redes con más neuronas aunque el error medio es significativo. Una tendencia que se empieza a observar es que conforme aumenta la aleatoriedad del canal, el error medio aumenta pero no de una forma significativa.

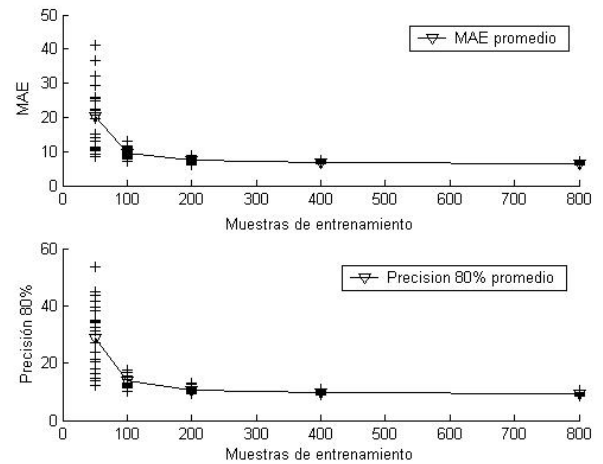


Fig. 1. Error medio y precisión vs. número de muestras de entrenamiento

En la figura 1 se observa la influencia del número de muestras en el error de generalización y en la probabilidad del error para un escenario de 16 neuronas y un canal con 6 dB de variabilidad. Es interesante destacar que para pocas muestras se obtiene un error medio mayor de 20 metros y una precisión de 30 metros con un 80% de probabilidad (es decir cuando la red devuelva un resultado con una probabilidad del 80% el punto estará contenido en un radio de 30 metros). Conforme aumenta el número de muestras el error medio se estabiliza entorno a 10 metros y una precisión a 9 metros con un 80% de probabilidad.

Esta tendencia se observa también en las tablas I-IV donde a partir de 200 muestras no se producen cambios significativos ni en los errores ni en la precisión obtenida para todas las redes neuronales y para los canales evaluados. Esta relación del número de muestras de entrenamiento óptimo tiene implicaciones en el tamaño del *radio map* y el tiempo que hay que invertir en hacer la campaña de medidas en un entorno real y requiere un estudio en mayor profundidad.

Por tanto, a partir de 200 muestras se observa que la red aprende bastante bien y se estabiliza en un error medio entorno a 6 metros. Además, con una probabilidad del 80% cualquier estimación que haga la red se encuentra en un disco de radio 8-9 metros, y con una probabilidad del 95% ese disco tiene un radio de 15-18 metros.

Un efecto interesante es que cuando aumenta la variabilidad del canal (desde 0 a 6 dB) el error medio y la precisión son estables con variaciones reducidas.

En la siguiente figura se genera una trayectoria secuencial de puntos (círculos) por las habitaciones; en cada punto de la ruta el simulador calcula la RSS en cada AP para un canal con variabilidad de 6 dB. A continuación este vector de muestras RSS de los AP se pasa por una red de 32 neuronas entrenada con 800 muestras (error promedio de 6.9 metros, precisión al 80% y 95% de 9.9 y 16.7 metros respectivamente). Con aspas se representa la trayectoria estimada por la red y se puede observar que hay bastante coincidencia entre el valor real y el estimado en determinadas zonas del mapa.

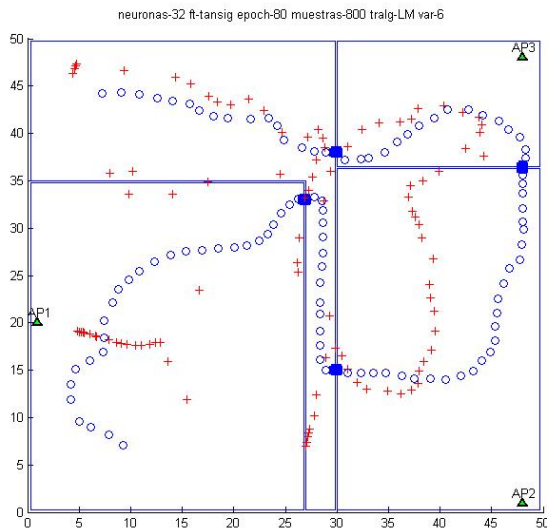


Fig. 2. Escenario con 3 habitaciones, un pasillo y 3 AP. Trayectoria real y estimada por una red entrenada con 32 neuronas y un canal con variabilidad de 6 dB.

VII. CONCLUSIONES

En el presente trabajo de investigación se ha desarrollado un simulador que permite caracterizar un entorno interior y la capa física que incluye el hardware, el diagrama de radiación de las antenas y un modelo de canal basado en *path-loss* de varias pendientes, pérdidas de atenuación por obstáculos y *shadowing*. El sistema propuesto permite definir tendencias complejas en el comportamiento del canal mediante modelos fáciles de implementar y computacionalmente abordables y recrear *radio maps*. El simulador es el soporte de para evaluar herramientas matemáticas de reconocimiento de patrones usando la técnica de RSS *fingerprint*.

Se han evaluado varias arquitecturas de redes neuronales basadas en el perceptron multicapa y se ha comprobado que se obtienen unos resultados y tendencias similares con una capa oculta y un número reducido de neuronas (entre 4 y 32). La función de activación en la capa oculta usada que ofrece mejores resultados es la tangente hiperbólica. A su vez, se ha comprobado que normalizar los valores de RSS de las muestras de entrenamiento hace que la red aprenda mejor.

Un resultado interesante es que conforme aumenta la variabilidad del canal (de 0 a 6 dB), la red filtra la componente aleatoria y los errores promedio y la precisión devuelven valores similares. Por tanto, un resultado preliminar a remarcar es que la red tiende a ser robusta al canal aleatorio, pero este punto hay que validarlo con un estudio en mayor profundidad modificando más parámetros de la capa física.

Para simulaciones de una variabilidad del canal de 6 dB, 200 muestras y 32 neuronas se obtiene un error medio de 6.9 metros y una precisión del 80% de 9.9 metros, es decir, cuando la red entrenada devuelva una estimación con una probabilidad del 80%, el punto estimado estará contenido en un disco de radio 9.9 metros. Battiti *et al.* [4] en un escenario similar con 3 AP obtiene un error medio de 1.8 metros, pero no da datos sobre la precisión y hay que tener en cuenta que el entorno que estudia tiene 640 m² (cuatro veces más pequeño que el escenario de simulación).

Se ha comprobado que para el entorno emulado existe un número óptimo de 200 muestras a partir del cual la red neuronal converge a un error de generalización y no se obtienen mejoras significativas.

Como trabajos futuros se contempla analizar otros escenarios con distintas dimensiones y número de habitaciones, aumentar la complejidad del modelo de la capa física y completar el estudio del número de muestras óptimas para que la red obtenga un error de generalización acotado.

AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por el proyecto nacional TEC2007-67966-01/TCM (CON-PARTE-1) y el proyecto regional SERPA (referencia 2107SE0027) y está también enmarcado en el "Programa de Ayudas a Grupos de Excelencia de la Región de Murcia, Fundación Séneca.

REFERENCIAS

- [1] K. W. Kolodziej, J. Hjelm, *Local Positioning Systems: LBS Applications and Services*, ed. CRC, 2006
- [2] P. Bahl, V.N. Padmanabhan, *RADAR: An in-building RF-based user location tracking system*, IEEE INFOCOM, pages 775-784, 2000
- [3] EKAHAU, <http://www.ekahau.com>
- [3] R. Battiti and A. Villani and T. Le Nhat, *Neural network models for intelligent networks: deriving the location from signal patterns*, in Proceedings of Annual Symposium on Autonomous Intelligent Networks and Systems, 2002
- [5] V. Erceg et al., *TGn Channel Models*, IEEE 802.11 document 03/940r3, Mayo 2004
- [6] J. Medbo, P. Schramm, *Channel models for HIPERLAN/2*, ETSI/BRAN document no. 3ERI085B
- [7] T. Rappaport, *Wireless Communications: Principles and Practice*, ed. Prentice Hall, 2001
- [8] MATLAB Neural Tool Box; <http://www.mathworks.com/>
- [9] M.Hagan, M.Menhaj, "Training Feedforward networks with the Marquardt algorithm", IEEE T. Neural Networks 5 pag 989-993, 1994
- [10] R.Want and B.Schilit, *Expanding the horizons of location-aware computing*, IEEE Computer, 34(8):31-34, August 2001

Tabla I ERROR Y PRECISIÓN PARA 50 MUESTRAS ENTRENAMIENTO Y 80 ÉPOCAS

N	Componente aleatoria canal: 0dB				Componente aleatoria canal: 1dB				Componente aleatoria canal: 3dB				Componente aleatoria canal: 6dB			
	4	8	16	32	4	8	16	32	4	8	16	32	4	8	16	32
MAE	11.8	10.7	12.2	22.5	7.04	8.3	19.8	32.9	27.1	14.3	17.5	36.5	8.20	11.5	14.9	27.2
P80%	13.4	13.2	32.6	65.2	16.9	24.3	24.4	45.9	11.8	17.9	28.0	51.3	12.8	17.8	21.6	43.4
P95%	52.5	33.0	32.6	65.2	16.9	24.3	70.3	114.5	26.0	52.0	46.1	155.2	19.1	34.2	50.2	88.7

Tabla II ERROR Y PRECISIÓN PARA 100 MUESTRAS ENTRENAMIENTO Y 80 EPOCAS

N	Componente aleatoria canal: 0dB				Componente aleatoria canal: 1dB				Componente aleatoria canal: 3dB				Componente aleatoria canal: 6dB			
	4	8	16	32	4	8	16	32	4	8	16	32	4	8	16	32
MAE	7.8	6.6	10.4	12.0	6.5	6.0	12.7	14.9	6.0	6.7	8.5	11.8	6.8	9.1	8.8	25.7
P80%	11.9	9.2	14.4	16.1	10.2	8.9	11.5	18.4	9.1	10.7	11.8	17.8	10.1	11.8	12.9	36.4
P95%	18.1	16.4	29.3	42.1	17.0	18.3	36.4	51.2	16.1	16.7	27.5	34.5	15.8	28.9	21.9	85.4

Tabla III ERROR Y PRECISIÓN PARA 200 MUESTRAS ENTRENAMIENTO Y 80 EPOCAS

N	Componente aleatoria canal: 0dB				Componente aleatoria canal: 1dB				Componente aleatoria canal: 3dB				Componente aleatoria canal: 6dB			
	4	8	16	32	4	8	16	32	4	8	16	32	4	8	16	32
MAE	6.5	6.0	6.8	11.3	6.1	5.5	5.6	7.4	5.7	5.0	5.6	5.7	6.6	6.2	7.5	8.8
P80%	9.6	8.6	10.0	15.4	9.6	8.2	8.8	10.6	9.0	7.4	8.3	8.6	9.2	9.5	10.1	13.5
P95%	16.9	15.8	18.7	36.8	15.9	16.1	15.5	23.7	14.8	15.8	16.9	17.4	16.1	16.0	20.8	24.1

Tabla IV ERROR Y PRECISIÓN PARA 400 MUESTRAS ENTRENAMIENTO Y 80 EPOCAS

N	Componente aleatoria canal: 0dB				Componente aleatoria canal: 1dB				Componente aleatoria canal: 3dB				Componente aleatoria canal: 6dB			
	4	8	16	32	4	8	16	32	4	8	16	32	4	8	16	32
MAE	5.9	5.7	6.2	6.3	6.1	5.5	5.6	6.6	5.8	5.1	5.0	5.1	6.6	6.0	7.3	6.9
P80%	9.4	8.1	9.7	9.2	8.9	8.2	8.4	10.3	8.8	7.9	7.7	8.0	9.3	8.4	10.6	9.9
P95%	15.7	16.9	15.7	18.7	15.2	15.7	15.6	18.7	14.9	15.5	15.4	17.5	16.6	17.3	18.0	16.7