

Sistema de posicionamiento en interiores utilizando señales de radio estaciones FM comerciales y Deep Learning

J. Roman^a, D. Marquez-Viloria^{a, *}, R. A. Velásquez^b, J. Botero-Valencia^a

^aGrupo de Automática, Electrónica y Ciencias Computacionales, Instituto Tecnológico Metropolitano, Medellín, Colombia.

^bGrupo de Sistemas Embebidos e Inteligencia Computacional, SISTEMIC, Facultad de Ingeniería, Universidad de Antioquia, Medellín, Colombia.

Resumen

Para dar solución al problema de posicionamiento en interiores, muchos autores han propuesto el uso de diversas técnicas. Desde la simulación de un Sistema de Posicionamiento Global (GPS) a través de antenas Pseudolites, la construcción de campos magnéticos artificiales, el uso de diversos sensores como visión, ultrasonido, unidades de medida inercial, entre otros. Hasta el uso de transmisores y receptores en el rango de la Radio Frecuencia como los presentes en una oficina. Muchos de los sistemas anteriormente mencionados dependen para su correcto funcionamiento de una instalación y configuración de equipos en el lugar de posicionamiento, lo cual puede llevar en ocasiones a costosas implementaciones. Es por esto que para realizar este trabajo hemos propuesto una metodología de posicionamiento en interiores que no requiere de adecuaciones e instalaciones en el lugar de aplicación. La metodología propuesta hace uso de las radio estaciones FM existentes y utiliza algoritmos de Deep Learning como algoritmo de posicionamiento.

Palabras Clave:

Estimación de la posición, Frecuencia Modulada, interiores, Señales de radio, Sistemas de posicionamiento

Indoor positioning system using FM radio stations signals and Deep Learning

Abstract

For the problem of indoor positioning, many authors have proposed the use of diverse techniques. From the simulation of a Global Positioning System (GPS) through Pseudolite antennas, the construction of artificial magnetic fields, the use of various sensors such as vision, ultrasound, inertial measurement units, among others. Up to the use of transmitters and receivers in the range of Radio Frequency as those present in an office. Many of the aforementioned systems depend for their correct operation of an installation and configuration of equipment in the place of positioning, which can sometimes lead to costly implementations. That is why to carry out this work we have proposed an indoors positioning methodology that does not require adjustments and installations in the place of application. The proposed methodology makes use of the existing FM radio stations and uses Deep Learning algorithms as positioning algorithm.

Keywords:

Frequency Modulation, Indoor, Position Estimation, Positioning Systems, Radio Signals

1. Introducción

Los sistemas de posicionamiento global (GPS) son una herramienta fundamental, no solo en aplicaciones militares, sino también en un sin número de aplicaciones civiles como navegación terrestre, marítima y aérea, o sistemas de información

geográfica. Un problema esencial de los sistemas de posicionamiento global actuales es su incapacidad para proporcionar una posición precisa al interior de edificaciones. Esta limitación de los sistemas GPS dificulta el despliegue de aplicaciones que requieren posicionamiento preciso en interiores. Tradicionalmen-

*Autor para correspondencia: davidmarquez@itm.edu.co

To cite this article: J. Roman, D. Marquez-Viloria, J. Botero-Valencia, R. A. Velásquez 2020. Indoor Positioning System Using FM Radio Stations Signals and Deep Learning. Revista Iberoamericana de Automática e Informática Industrial 17, 34-43. <https://doi.org/10.4995/riai.2019.10894>

Attribution-NonCommercial-NoDerivatives 4,0 International (CC BY-NC-ND 4,0)

te, los sistemas de posicionamiento en interiores (IPS por sus siglas en inglés) han sido utilizados para localizar personas u objetos en grandes edificaciones y lugares cerrados. Por ejemplo, localizar pacientes en un hospital, encontrar gente atrapada en un edificio colapsado o en llamas, encontrar trabajadores en una planta, etc. Otras posibles aplicaciones de los IPS son navegación en aeropuertos, estaciones ferroviarias, y centros comerciales; y navegación de sistemas robóticos dentro de edificios.

La utilidad y posibilidades de un IPS son indiscutibles, y la comunidad académica ha propuesto diversas tecnologías para la implementación de estos sistemas: magnéticos, ultrasonido, pseudolites, ópticos, RF, etc. De Angelis et al. en (De Angelis et al., 2015) y Blankenbach et al. en (Blankenbach et al., 2012), proponen un IPS utilizando principios magnéticos, el cual puede desplegarse en áreas pequeñas y que además utiliza sensores disponibles en teléfonos celulares, los cuales, a su vez, actúan como estación móvil. La tecnología de ondas mecánicas de ultrasonido también ha sido trabajada por diversos autores (Suzuki et al., 2009; Ruiz et al., 2014; Murata et al., 2014; Yazici et al., 2011). En particular, Yazici et al. en (Yazici et al., 2011) propone un sistema de posicionamiento por ultrasonido llamado SESKON que utiliza la técnica de diferencia en tiempo de llegada (TDOA por sus sigla en inglés), La cual implementa un modo de sincronización alternativo al tradicional, alcanzando un error máximo de 16mm a velocidades de 200 mm/s. En un intento de reusar los receptores GPS para posicionamiento en interiores, algunos autores han propuesto el uso de satélites falsos (*pseudolites*) que emiten señales análogas a las del GPS (Niwa et al., 2008; Vervisch-Picois et al., 2010; Vervisch-Picois and Samama, 2012; Selmi et al., 2012). Los pseudolites emiten señales que permiten que un receptor GPS comercial estime la posición con errores en el orden de centímetros. Diversos IPS ópticos han sido propuestos en la literatura, algunos utilizan luz visible (Sertthin et al., 2009; Luo et al., 2013; Do et al., 2013; Yamaguchi et al., 2014), otros luz infrarroja (Lee et al., 2004; Domingo-Perez et al., 2014), y algunos otros utilizan cámaras de vídeo y visión artificial (Mustafah et al., 2012; Regula et al., 2012; Chao et al., 2013). IPSs que utilizan como principio la propagación de señales de radiofrecuencia (RF) han sido propuestos con casi todos los tipos de sistemas de comunicación inalámbrica: WiFi, GSM, ZigBee, Ultra Wide Band, FM, etc. En esta categoría existen diferentes técnicas para estimar la posición: potencia recibida (RSSI) de las fuentes de RF, el tiempo de vuelo (TOF), TDOA, fingerprinting, etc. En la Sección 2 presentaremos las principales técnicas utilizadas en RF.

Cada una de las tecnologías mencionadas tiene ventajas y desventajas que deben ser evaluadas a la hora de implementar un IPS, por ejemplo, la precisión de algunas de estas solo se alcanza bajo ciertas condiciones controladas, y otras exigen el montaje de infraestructura adicional, lo cual las hace costosas. En este sentido, los IPSs basados en RF permiten ahorrarse los costos de infraestructura, ya que en general utilizan infraestructura de comunicaciones previamente instalada. Adicionalmente, el avance de la tecnología de semiconductores permite no solo integrar transceptores RF en casi cualquier dispositivo electrónico, sino también realizar los cálculos necesarios para estimar la posición en pequeños sistemas embebidos de bajo costo. Por otro lado, las técnicas de posicionamiento que utilizan RF y fingerprinting permiten solventar algunos de los pro-

blemas comunes de línea de vista, efectos multitrayectoria y pérdidas de señal asociadas a elementos estructurales de edificaciones. El fingerprinting consiste en caracterizar puntos de interés en un área de navegación. De esta forma se construye una base de datos con mediciones por ejemplo de RSSI en dichos puntos. Esta base de datos permite luego estimar la posición comparando respecto a mediciones hechas por la estación móvil (Campos and Lovisolo, 2015).

Este trabajo presenta una técnica para realizar posicionamiento en interiores utilizando las señales emitidas por radio estaciones comerciales de FM. La técnica propuesta, utiliza fingerprinting y algoritmos de aprendizaje profundo (Deep Learning) para estimar la posición de la estación base. El desempeño de la técnica se evalúa respecto a técnicas previamente utilizadas en la literatura (Moghtadaiee et al., 2011; Chen et al., 2013) que estiman la posición con algoritmos KNN regresivo (k-vecinos mas cercanos) y fingerprinting. A diferencia de otros trabajos donde los experimentos se realizan en lugares vacíos, nuestros experimentos se realizaron en un espacio residencial amoblado y habitado.

Este artículo está organizado de la siguiente manera: en el capítulo 1 el lector podrá encontrar la Introducción, en el capítulo 2 el Estado del Arte, posteriormente en el capítulo 3 la metodología propuesta, en el capítulo 4 un análisis de resultados y por último en el capítulo 5 las conclusiones.

2. Estado del arte

Diferentes metodologías que utilizan fingerprint se han usado ampliamente en trabajos pasados con señales de radiofrecuencia, principalmente utilizando WiFi (Zhuang et al., 2015; Al et al., 2017; Niu et al., 2015; Swangmuang and Krishnamurthy, 2008; Le et al., 2014; Zou et al., 2015; Zhao and Wang, 2017; Torteeka and Chundi, 2014; Le Dortz, N. and Gain, F. and Zetterberg, 2012). Esto debido en gran parte a que la tecnología WiFi se encuentra comúnmente en muchos lugares cerrados y edificios. Sin embargo, hay zonas que no cuentan con este tipo de señales, además, debido a su longitud de onda, las señales emitidas por los transmisores son atenuadas fácilmente ante obstáculos como las paredes (Ali-Rantala et al., 2003) y otros tipos de objetos de diferentes materiales comúnmente encontrados en interiores. Para resolver esta dificultad algunos autores han propuesto utilizar señales de una menor frecuencia como GSM (Anastasijevic and Nešković, 2012; Machaj and Brida, 2014; Tian et al., 2014; Varshavsky et al., 2007) y FM (Popleteev et al., 2012; Interaction, 2010; Moghtadaiee et al., 2011; Chen et al., 2013; Moghtadaiee and Dempster, 2014; Matic et al., 2010). Los trabajos mencionados anteriormente que son basados en FM requieren de la instalación de algún tipo de infraestructura como antenas para transmitir sus propias señales FM y facilitar la estimación de la posición. En (Popleteev et al., 2012) se hace uso de las radio estaciones comerciales FM, lo que evita la instalación de una infraestructura propia para la generación de señales FM.

La gran mayoría de técnicas o algoritmos de posicionamiento utilizados con Fingerprint en los trabajos anteriormente citados, se enfocan en técnicas de aprendizaje de máquinas como KNN (k-Nearest Neighbors), wKNN (Weighted k-Nearest Neighbors), SVM (Support Vector Machines) y GP (Gaussian

Process) para clasificar y determinar la posición estimada. Esto implica un alto costo computacional al momento de calcular la posición.

Para solucionar esto, algunos autores han propuesto utilizar Deep learning en el contexto de redes WiFi (Wang et al., 2015; Wietrzykowski, 2017; Siller, 2016), el cual, si bien requiere un alto costo computacional para su entrenamiento, simplifica de manera considerable la ejecución de los algoritmos de prueba. Sin embargo, debido a que este enfoque no había sido explorado, hasta el momento, utilizando señales FM de radio estaciones comerciales existentes, decidimos enfocar nuestro trabajo en este ámbito.

3. Metodología

3.1. Hardware

Para la adquisición de datos se utilizó un sistema de Radio Definido por Software (SDR) RTL-SDR basado en el chip RTL2832u. Este dispositivo está compuesto por 2 chips: un sintonizador de señales de radio Raphael Micro R820T que de manera conjunta con una antena permite la adquisición de señales de radio en un rango de frecuencia entre 100 Khz a 1700 Mhz y un chip conversor ADC de 8-bit Realtek RTL2832u. El RTL2832u se encarga de transformar la señal analógica recibida por el chip R820T de una antena telescópica común, sacada de un radio receptor de bajo costo con una longitud de 52 cm de largo para adquisición de las señales FM, en una señal digital compuesta por dos componentes uno Real/Inphase(I) y uno Imaginario/quadrature(Q). Esta señal es por último acondicionada y llevada a una interfaz USB permitiendo así leer, almacenar y procesar esta información en un computador o sistema embebido como se muestra en la Figura 1. Para leer la información del RTL-SDR se puede usar el software SDR#, Matlab y GNU Radio para Windows OS y GQRX para Mac OS y Linux. Una alternativa al uso de software comercial es la posibilidad de aplicar comandos propios de los drivers desde una consola como CMD de Windows o Terminal de Linux.

En este trabajo se optó por esta última posibilidad, ya que a través de consola podemos adquirir los datos brutos utilizando comandos como `rtl_sdr`, `rtl_power`, `rtl_fm` y `rtl_test`. El comando utilizado durante este trabajo fue `rtl_power`, el cual entrega información del espectro de frecuencia como un índice de potencia de la señal o RSSI en un rango de frecuencias deseado. Esta información es usada para capturar las características de un punto de interés.

Un sistema operativo basado en Linux fue elegido en este trabajo con el objetivo de que los experimentos realizados en una computadora personal sean migrados posteriormente a un sistema embebido como el Raspberry Pi que permita ampliar el espectro de aplicación del sistema de posicionamiento propuesto como la navegación de drones o robots móviles en interiores.

Para realizar la lectura de datos a través de un terminal de Linux, es necesario instalar inicialmente los controladores USB requeridos para que el dispositivo sea leído correctamente y posteriormente descargar, instalar y compilar las librerías como se describe en (Danymol et al., 2013).



Figura 1: Fotografía de prototipo de pruebas durante muestreo

3.2. Montaje Experimental

Para el montaje experimental se definió la utilización de un área de experimentos organizada como un plano de dos dimensiones y con 23 puntos coordenados utilizados para la recolección de muestras RSSI de FM y construcción del Fingerprint de entrenamiento. Las muestras recogidas sirvieron como insumo para el entrenamiento y prueba de los algoritmos propuestos con Deep Learning y del algoritmo comparativo KNN Regresivo. A continuación, detallaremos un poco más el montaje experimental.

3.2.1. Área

Para el montaje experimental se utilizó un espacio cerrado ubicado en un tercer piso residencial y habitado, el cual cuenta con muros de concreto con espesor de 10cm, ventanas y diversos obstáculos como muebles y electrodomésticos. Como se observa en la Figura 2, este está dividido básicamente en 4 espacios: dos habitaciones, una cocina y un pasillo, abarcando estos un área de 289cm X 1011cm. En este espacio se distribuyeron 23 puntos, cada uno correspondiente a una coordenada (x,y) y distanciado de sus puntos vecinos 100cm.

3.2.2. Radio Estaciones Utilizadas

Para el experimento, se tuvo en cuenta todas las radioestaciones FM comerciales presentes en la ciudad de Medellín, Colombia. Estas radio estaciones están distribuidas en el espectro radioeléctrico desde los 88.9 Mhz hasta los 107.9 Mhz, para un total de 29 radioestaciones que aportan información de potencia en los diferentes puntos utilizados.

3.2.3. Construcción de base de datos de potencia

La base de datos con el índice de potencia RSSI de las radio estaciones fue construida ubicando el dispositivo RTL-SDR y la antena receptora, en cada uno de los de puntos o coordenadas mostradas en la Figura 2. La vivienda utilizada como área de experimentos esta ubicada en la ciudad de Medellín, Colombia (Latitud: 6.278246, Longitud: -75.57701 Altitud = 1521 metros), con un clima promedio templado

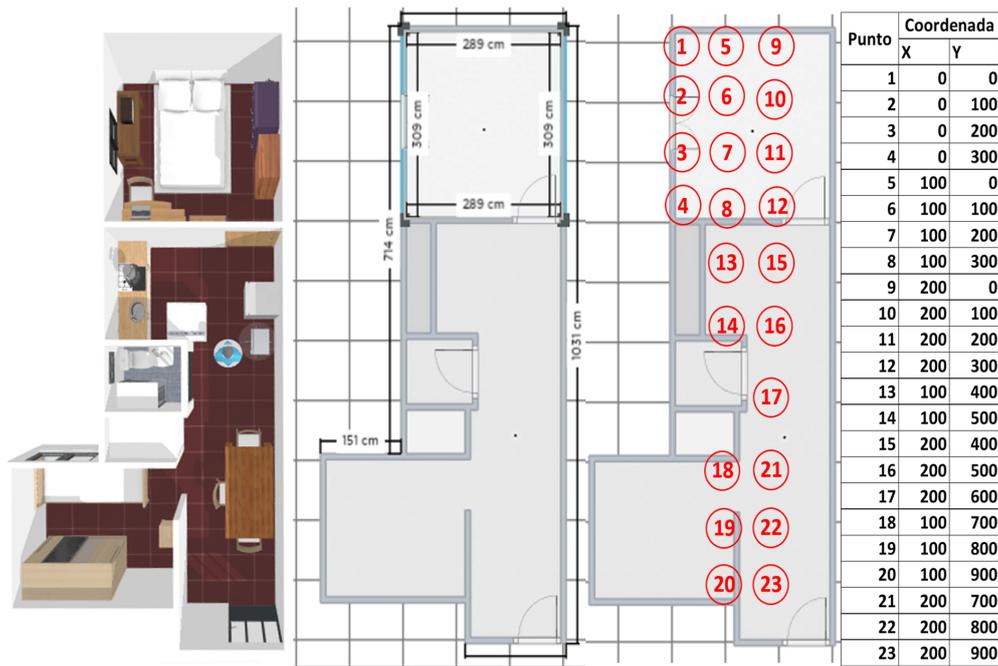


Figura 2: Plano del área de experimentos

húmedo, de alrededor de 21.5C durante el año. Las sesiones de datos fueron recopilados en horas y días diferentes en un período de 3 meses. Para cada coordenada del área de experimentos, se realizó un total de 6 sesiones de toma de datos. El tiempo de adquisición fue de 5 minutos por sesión de toma de datos a una frecuencia de 1 muestra/segundo, para un total de 300 muestras por sesión. Teniendo así para cada coordenada un total de 1800 muestras. Las muestras obtenidas contienen información de potencia de las 29 radioestaciones. Cada muestra contiene los datos del índice de potencia de las frecuencias encontradas cada 10kHz entre 88.4 MHz y 107.9 MHz. Todas las muestras de cada sesión de toma de datos son obtenidas automáticamente con el comando *rtl power* de Linux. Este comando toma los datos y los almacena en un archivo CSV creando la base de datos.

3.3. Preprocesamiento de datos

Para el procesamiento de datos se utilizó un script realizado en el software Matlab que se encarga de unir los diferentes archivos CSV en una matriz que consolida la información de todos los muestreos realizados. Con la matriz consolidada se normalizaron los datos sobre un offset de cero para facilitar el tratamiento matemático. La gráfica de la información de la matriz consolidada nos presenta el espectro de magnitud en el rango de frecuencia de las radio estaciones como se observa en la Figura 3. Podemos observar que los picos de mayor potencia en el espectro están formados por los puntos de la gráfica que se encuentran cercanos a las frecuencias de las portadoras otorgadas a cada radio estación comercial, es decir, el ancho de banda ocupado por cada una de ellas. En la Tabla 1 se muestra la frecuencia de portadora de cada una de las radio estaciones FM utilizadas.

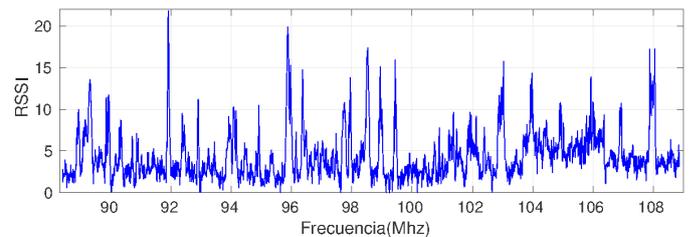


Figura 3: Espectro de magnitud FM entre 88.4 Mhz y 108.8 Mhz

El ancho de banda de cada radioestación es 200 khz, y el tamaño de paso del espectro capturado es de 10 khz. Como resultado tenemos un total de 20 puntos relevantes para cada radioestación. Teniendo en cuenta lo anterior, hay información del muestreo que no presenta una relevancia significativa en el espectro, por lo cual podemos simplificar la cantidad de puntos del Fingerprint solo con aquellos que se encuentran dentro del ancho de banda alrededor de las frecuencias fundamentales y así obtener únicamente 29 columnas de datos, cada una correspondiente a una radioestación FM.

Aunque inicialmente se pensó en utilizar 19 de los 20 puntos relevantes alrededor de la frecuencia central para cada radio estación, luego de realizar algunas pruebas de entrenamiento del sistema, no se logró una convergencia satisfactoria, por lo cual se propuso reducir estos 19 valores realizando alguno de los siguientes 3 tratamientos de los datos:

Tabla 1: Frecuencias Radio Estaciones Comerciales FM

Frecuencias FM (Mhz)					
89,21	89,9	90,3	90,97	91,91	92,4
92,9	93,97	94,42	94,9	95,89	96,42
96,93	97,92	98,94	99,42	99,94	100,4
100,9	101,42	101,92	102,92	103,93	104,32
104,98	106	106,37	107	108	

3.3.1. Sumatoria de datos

$$x_i = \sum_{j=-9}^9 f_{i,j} \quad \text{Donde } i \in \{1, \dots, 29\}$$

Se suman los 19 datos alrededor de cada frecuencia portadora de cada una de las radio estaciones, esta información se convierte la nueva matriz de Fingerprint.

3.3.2. Promedio de datos

$$x_i = \frac{\sum_{j=-9}^9 f_{i,j}}{19} \quad \text{Donde } i \in \{1, \dots, 29\}$$

Se promedian los 19 datos alrededor de cada frecuencia portadora de cada una de las radio estaciones, esta información se convierte la nueva matriz de Fingerprint.

3.3.3. Valor Máximo en rango

$$x_i = \max_{-9 \leq j \leq 9} (f_{i,j}) \quad \text{Donde } i \in \{1, \dots, 29\}$$

Se calcula el valor máximo entre los 19 datos alrededor de cada frecuencia portadora de cada una de las radio estaciones, esta información se convierte la nueva matriz de Fingerprint.

3.4. Entrenamiento

Para el entrenamiento del sistema se utilizó el criterio de validación cruzada 80-20 para los datos del Fingerprint. Tanto para las técnicas propuestas con Deep Learning como para la técnica de KNN Regresivo que servirá de comparación. Como se muestra en la Figura 4, para el experimento se realizó un exploración de la configuración de la red, variando las capas ocultas de la arquitectura desde 1 hasta 10 y el número de neuronas por capa entre 2 y 20 neuronas para un total de 180 posibles arquitecturas. Tomando como entradas la información procesada en FM y obteniendo como salida las coordenada (x,y) pertenecientes al plano de experimento presentado en la Figura 2. Para cada una de las arquitecturas probadas se realizó el cálculo del promedio del error absoluto y se eligieron las mejores arquitecturas de menor a mayor error.

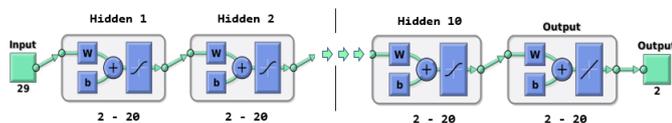


Figura 4: Red Neuronal Feedforward con 29 entradas y 2 salidas

3.5. Métricas

3.5.1. Error absoluto

El Error Absoluto es el valor absoluto resultante de la diferencia entre el valor encontrado y el valor esperado. Esta métrica, puede servir para establecer un punto de comparación entre las diferentes arquitecturas de red.

$$AE_i = ||Y_i - X_i||$$

Donde Y_i es el vector de coordenadas (x,y) resultantes a la salida de la red neuronal y X_i es el vector de coordenadas (x,y) esperado.

3.5.2. Promedio del error absoluto

El promedio del error absoluto (MAE) es la sumatoria del valor absoluto resultante de la diferencia entre el valor encontrado y el valor esperado sobre la cantidad de muestras. Esta métrica al igual que el Error Absoluto puede servir para establecer un punto de comparación entre las diferentes arquitecturas de red.

$$MAE = \frac{\sum_{i=1}^n ||Y_i - X_i||}{n}$$

Donde Y_i es el vector de coordenadas (x,y) resultantes a la salida de la red neuronal, X_i es el vector de coordenadas (x,y) esperado y n es la longitud del vector.

4. Resultados Experimentales

En esta sección se estableció como fue la elección de la configuración de la red neuronal a utilizar para FM, tomando como insumo la base de datos con el RSSI de FM procesado con información de los 23 puntos coordenados descrita anteriormente. Una vez la configuración de la red neuronal es establecida, se realiza la validación de la misma (estimación de la posición) con 3 muestras de datos diferentes. En una primera instancia los datos de prueba, luego, en una segunda instancia con un conjunto de datos capturados posteriormente y que coinciden con la grilla de medición y por último, datos intermedios a la grilla.

4.1. Exploración de la configuración de la red

Eligiendo como datos de entrada la información procesada por cada uno de los métodos propuestos en capítulo anterior para FM (sumatoria de datos, promedio de datos y valor máximo rango), se realizó la exploración de las 180 configuraciones posibles de la red por cada método, para determinar las mejores configuraciones de capas y neuronas por capa. El criterio para determinar las mejores configuraciones fue el promedio del error absoluto de los datos de salida de la red.

Los resultados obtenidos de las 540 configuraciones se pueden observar en la Figura 5, donde se gráfica el promedio del error absoluto para los métodos mencionados con un color diferente cada uno. Como se observa en la figura, los menores errores corresponden al valor máximo y a la sumatoria de datos con errores inferiores a 0.15 cm en X y a 1 cm en Y. De los datos observados en este rango, los que presentan los menores dos errores son el de la sumatoria de datos con la configuración de 3 capas - 18 neuronas y el del valor máximo rango con una configuración de 4 capas - 19 neuronas. El primero con un promedio de error absoluto de 0.05 cm en la coordenada X y de 0.11 cm en la coordenada Y y el segundo con un promedio del error absoluto de alrededor de 0.07 cm en la coordenada X y 0.15 cm en la coordenada Y.

Teniendo en cuenta los resultados de estas dos configuraciones, utilizaremos las redes neuronales correspondientes a estas para la estimación de la posición con FM, junto con el algoritmo comparativo de KNN Regresivo.

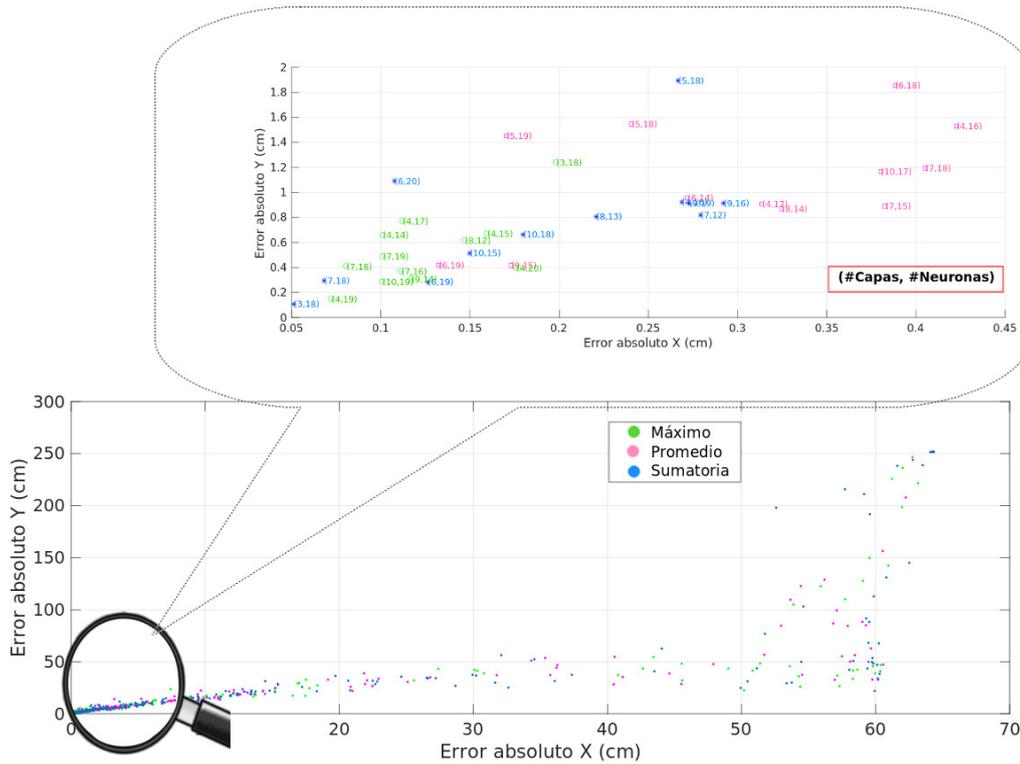


Figura 5: Errores absolutos FM según configuración de la red

4.2. Evaluación de desempeño

A continuación se mostrará entre las dos configuraciones de red anteriormente mencionadas y un algoritmo de KNN regresivo, el cual presenta mejores resultados al realizar una estimación de la posición para cada una de las 23 coordenadas elegidas con la información de las radio estaciones FM.

Para ello los resultados se presentan de dos maneras, una gráfica y una numérica, utilizando una tabla de resultados con el promedio del error absoluto MAE de 20 iteraciones para cada una de las 23 coordenadas. La gráfica hace uso del MAE como la distancia en X y Y de una elipse cuyo centro es la coordenada real esperada. Se utiliza la elipse por la facilidad visual que esta figura ofrece en la comparación de resultados. A menor tamaño de la elipse y mayor cercanía de su centro a la coordenada original, mayor será la precisión de la estimación para ese punto.

4.2.1. Datos de prueba

En la Figura 6 y en la Tabla 2 es posible observar los resultados para las dos configuraciones de red elegidas y para el KNN regresivo en términos del promedio del error absoluto, para los datos de prueba obtenidos durante la construcción de la base de datos de entrenamiento del sistema. De manera general, observamos que las redes neuronales presentan una mejor estimación de la posición que el KNN regresivo con promedios de error absoluto inferiores a 1 cm para todos los puntos, mientras que el KNN presenta un promedio de error absoluto para puntos como el 3 y el 8 superior a los 20 cm para la coordenada Y. Que si bien no es un error grande comparado con otras técnicas, nos permite verificar un comportamiento con una mejoría del 95 % de las redes para los puntos de prueba respecto al KNN.

4.2.2. Datos posteriores

Días posteriores a la construcción del Fingerprint, se recolectaron datos adicionales en cada una de las 23 coordenadas coincidentes con la grilla. Estas mediciones fueron probadas de manera similar a la subsección anterior, con los algoritmos de redes neuronales y el KNN regresivo obteniendo los resultados presentados en la Figura 7 y en la Tabla 3.

Tabla 2: Promedio del error absoluto FM para puntos de prueba

P	Red 3 - 18		Red 4 - 19		KNN Regresivo	
	x (cm)	y (cm)	x (cm)	y (cm)	x (cm)	y (cm)
1	0,012	0,024	0,071	0,073	0,238	0,000
2	0,036	0,020	0,191	0,171	0,000	0,000
3	0,090	0,097	0,034	0,073	11,463	23,171
4	0,025	0,050	0,041	0,049	1,786	5,357
5	0,010	0,012	0,041	0,045	0,698	2,868
6	0,280	0,493	0,268	0,395	3,704	11,852
7	0,019	0,040	0,057	0,206	0,889	9,889
8	0,040	0,116	0,059	0,072	9,322	21,412
9	0,029	0,245	0,148	0,416	0,000	3,577
10	0,034	0,034	0,047	0,063	3,977	7,953
11	0,045	0,481	0,051	0,074	5,789	10,175
12	0,320	0,405	0,069	0,092	4,138	1,552
13	0,012	0,035	0,093	0,051	0,000	0,818
14	0,032	0,055	0,107	0,215	0,000	0,000
15	0,026	0,035	0,063	0,246	0,690	4,138
16	0,008	0,054	0,029	0,041	0,000	1,538
17	0,048	0,071	0,040	0,057	0,058	0,175
18	0,025	0,033	0,056	0,110	0,000	0,000
19	0,015	0,037	0,046	0,055	0,000	0,000
20	0,037	0,023	0,029	0,054	0,000	0,000
21	0,018	0,036	0,036	0,127	0,000	0,000
22	0,007	0,027	0,037	0,055	0,000	0,000
23	0,011	0,036	0,050	0,633	0,000	0,000

En la Tabla 3 y en la Figura 7 observamos que el promedio del error absoluto para algunos puntos aumenta respecto al calculado para los puntos de prueba de la Figura 2. Esto se debe a varios factores, como a que desde el momento en que se recolectaron los datos para entrenamiento y prueba hasta los datos posteriores e intermedios, hubo cambios físicos en el espacio de experimentos en la distribución de muebles y electrodomésticos. Como vemos en (Ali-Rantala et al., 2003; Adler and Schmitt, 2014; Xia et al., 2017) los efectos multi-trayectoria y pérdidas de señal pueden cambiar de acuerdo a la distribución del espacio, afectando así el RSSI. Otro factor a tener en cuenta según (Kuflik et al., 2012) es que los metales, los techos y demás superficies reflectivas en un espacio cerrado pueden causar falsos positivos en el RSSI de algunas ubicaciones del espacio. Un último factor que puede afectar las mediciones posteriores son los cambios de diales que se dan mas comunmente en radioestaciones FM a principio de año, lo que puede afectar el índice del RSSI por la potencia de emisión de cada radioestación.

Tabla 3: Promedio del error absoluto FM para puntos posteriores

P	Red 3 - 18		Red 4 - 19		KNNR	
	x (cm)	y (cm)	x (cm)	y (cm)	x (cm)	y (cm)
1	34,74	82,44	17,45	35,42	12,50	123,33
2	0,04	0,02	5,32	1,77	0,00	0,00
3	1,05	1,51	32,13	17,26	0,00	0,00
4	1,15	19,77	0,73	0,36	0,00	0,00
5	25,68	33,06	0,31	0,93	0,00	0,00
6	0,06	0,02	0,39	0,42	1,45	0,00
7	0,36	1,35	50,13	75,37	14,16	45,00
8	0,18	0,43	0,21	1,73	0,00	0,00
9	0,01	0,07	12,55	36,91	0,00	0,00
10	0,02	0,02	0,82	1,04	1,66	1,66
11	19,62	28,83	0,62	4,05	0,00	0,00
12	0,19	0,56	0,63	0,36	11,04	3,12
13	0,03	0,03	4,52	1,29	0,00	0,00
14	5,14	1,73	0,81	12,72	8,12	24,37
15	0,37	0,33	6,10	3,42	2,08	1,45
16	0,27	7,32	3,61	15,47	11,67	22,71
17	17,03	79,16	0,80	34,88	0,00	344,17
18	0,67	1,13	6,99	41,93	0,00	10,62
19	1,27	1,26	3,38	3,58	0,00	0,00
20	0,01	0,02	0,054	0,21	0,00	17,71
21	0,16	0,21	1,41	7,13	0,00	0,00
22	0,44	24,11	0,25	26,85	1,67	82,08
23	0,63	18,45	1,44	3,21	0,00	55,63

En la Tabla 3 y en la Figura 7(a) vemos que para la red neuronal con configuración de 3 capas y 18 neuronas el promedio del error absoluto tiende a ser menor a 20 cm en las coordenadas X y Y para la mayoría de los puntos, excepto para puntos como el 5, el 11, el 22, el 1 y el 17, alcanzando para estos dos últimos un promedio del error absoluto en Y de alrededor de los 80 cm. Por otro lado la red neuronal de 4 capas y 18 neuronas de la Figura 7(b) presenta un comportamiento similar a la red anterior para algunas de las coordenadas, llegando a un máximo promedio del error absoluto de 50 cm en X y 75 cm en Y en el punto 7. Por su parte el KNN Regresivo de la Figura 7(c) presenta para todas sus coordenadas un promedio de error absoluto inferior a los 15 cm en la coordenada X, pero errores superiores a los 80 cm para puntos como el 1 y el 22 para la coordenada Y, llegando a un promedio del error absoluto superior a los 320 cm para el punto 17. Obteniendo así, aproximadamente, un 25 % menos

de error en la estimación de la posición para puntos posteriores con las redes neuronales.

4.2.3. Coordenadas intermedias

Teniendo en cuenta que los algoritmos utilizados tienen un carácter regresivo, estos fueron utilizados para realizar la estimación de la posición en algunos puntos coordenados intermedios diferentes a los utilizados en el entrenamiento.

Tabla 4: Coordenadas Intermedias

Punto	X (cm)	Y (cm)
1	0	250
2	200	150
3	150	300
4	150	400
5	200	450
6	150	900
7	200	650
8	200	750
9	150	700
10	200	850

En la Tabla 5 y en la Figura 8 podemos observar los resultados obtenidos en la estimación de la posición para las coordenadas de la Tabla 4. Tanto en la tabla como en la figura, es evidente que el promedio del error absoluto aumenta para este tipo de estimación.

En el caso de la configuración de red 3-18 de la Figura 8(a) y la Tabla 5 vemos que el promedio del error absoluto no excede los 45 cm en X y los 67 cm en Y, a excepción de los puntos 8 y 9 donde el error esta alrededor de los 120 cm para la coordenada Y. Por su parte, para la red 4-19 de la Figura 8(b) y para el KNN de la Figura 8(c), se alcanzan a estimar un promedio del error absoluto superior a los 600 cm para estos mismos puntos. Aunque los resultados anteriores presentan un promedio del error absoluto mayor, vemos que con redes neuronales como la 3-18 podemos llegar a tener un comportamiento regresivo aceptable para la estimación de posiciones intermedias. Como vemos en (Khalajmehrabadi et al., 2017; Nuaimi et al., 2011; Mainetti et al., 2014; Liu et al., 2007; Batistic and Tomic, 2018) el promedio de los errores mínimos para la mayoría técnicas de radio frecuencia para posicionamiento en interiores ronda alrededor 1m y las técnicas que logran superar este umbral requieren de altos costos de implementación de infraestructura o las pruebas son realizadas en áreas pequeñas, lo que minimiza el error. Al igual que lo que mencionamos en la sección anterior, es posible también que las alteraciones del espacio y cambios en los diales de las emisoras, puedan influir también en el grado de imprecisión para algunas coordenadas.

4.3. Tiempo de Ejecución

En la subsección anterior se analizó el comportamiento de las técnicas utilizadas en cuanto a la estimación de la posición. En esta sesión analizaremos cómo se comportan estas técnicas en cuanto al tiempo de ejecución para la estimación, tanto para los puntos del Fingerprint como para los puntos posteriores.

En la Tabla 6 observamos los tiempos de ejecución de cada una de las técnicas, este tiempo se tuvo en cuenta como el tiempo promedio que tarda cada técnica en realizar la estimación de la posición en 20 iteraciones diferentes. Estos tiempos son relativos al desempeño y velocidad del procesador

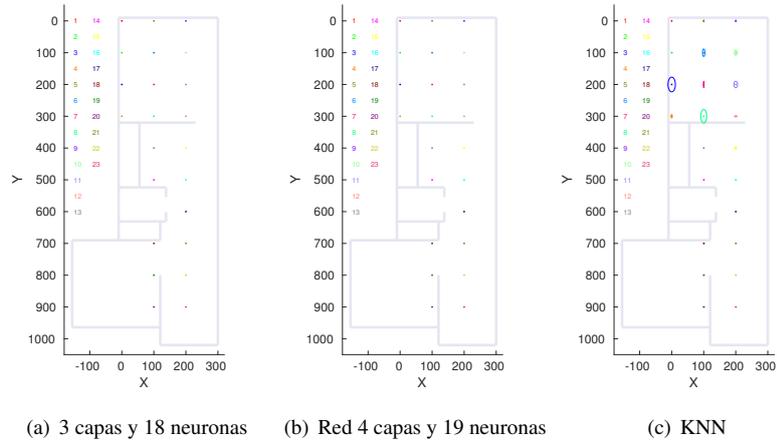


Figura 6: Promedio del error absoluto FM para puntos de prueba

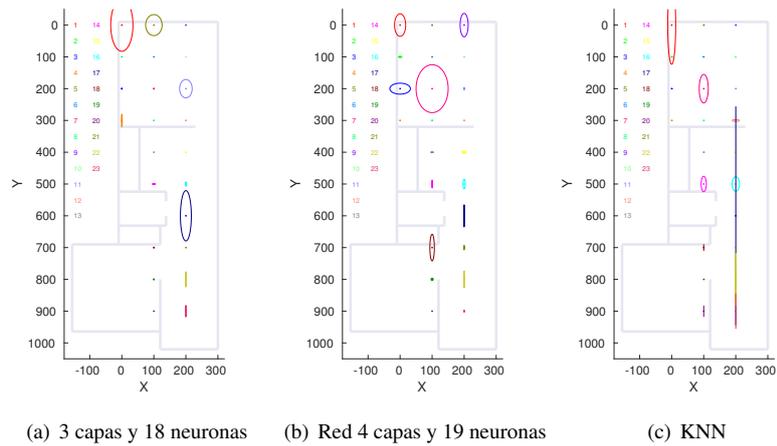


Figura 7: Promedio del error absoluto FM puntos posteriores

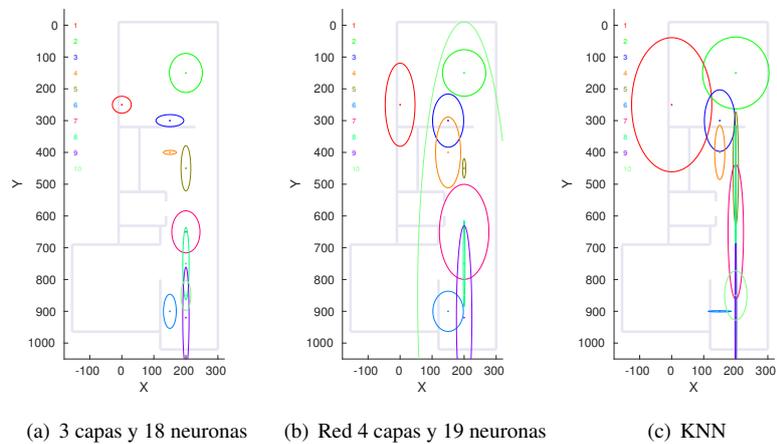


Figura 8: Promedio del error absoluto FM puntos intermedios

Tabla 5: Promedio del error absoluto FM para puntos intermedios

Punto	Red 3 - 18		Red 4 -19		KNN Regresivo	
	x (cm)	y (cm)	x (cm)	y (cm)	x (cm)	y (cm)
1	29,479	26,560	46,563	130,841	125,208	211,042
2	51,447	61,474	67,573	73,121	103,750	113,125
3	43,394	18,959	48,464	83,739	47,917	96,875
4	20,454	6,400	39,150	111,469	15,833	85,417
5	15,235	71,150	5,035	30,486	8,333	177,500
6	20,027	53,676	47,588	63,315	36,250	2,083
7	44,017	66,169	77,251	149,503	24,167	211,667
8	9,904	113,669	2,718	135,115	1,667	435,000
9	9,865	159,037	24,107	289,177	2,500	233,750
10	15,145	47,882	145,353	861,136	35,000	77,500

y capacidad de RAM del computador, por lo que varían de una máquina a otra. En nuestro caso se utilizó un computador con un procesador Intel Core i7-4510U y con una capacidad de memoria RAM de 8 GB.

Con los resultados presentados en la Tabla 6, confirmamos que el comportamiento de las redes se destacan más que el del KNN regresivo, tanto para los puntos del Fingerprint como para los puntos posteriores. Esto se debe a que el KNN requiere siempre entrenar el sistema completo antes de hacer la estimación de una coordenada.

También podemos observar que para los puntos del Fingerprint la configuración de 3 capas 18 neuronas se comporta un poco más rápido que la configuración de 4 capas 19 neuronas. Para los puntos posteriores esta diferencia no es tan perceptible y ambas configuraciones tienen un tiempo de ejecución equiparable.

Tabla 6: Tiempo de ejecución algoritmo estimador de la posición en FM

Algoritmo	Tiempo de ejecución (s)	
	Puntos Fingerprint	Puntos Posteriores
Red 3 - 18	0,0497	0,041
Red 4 - 19	0,0637	0,0425
KNNR	8,2418	2,6169

5. Conclusiones

En este artículo hemos presentado una técnica para posicionamiento en interiores, a través de Deep Learning, utilizando el RSSI de las señales emitidas por radio estaciones comerciales FM entre los 88.4 MHz y los 107.9 MHz.

La técnica propuesta presenta a nivel general un promedio del error absoluto inferior a 1 cm para los datos de prueba y un promedio del error absoluto inferior a los 70 cm para puntos calculados con las redes neuronales en días posteriores a la construcción del Fingerprint de entrenamiento. El error presentado en los puntos intermedios no permitiría aplicaciones de navegación en interiores, pero este sistema de posicionamiento si garantiza una muy buena aproximación de la posición para complementar sistemas de navegación en robótica móvil sin necesidad de una infraestructura adicional al dispositivo receptor.

La técnica de Deep Learning propuesta fue comparada con una técnica de KNN Regresivo, obteniendo mejores resultados tanto en la estimación como en los tiempos de ejecución para la técnica de Deep Learning.

En trabajos futuros se espera realizar la comparación con otras técnicas diferentes a KNN como Máquinas de Soporte

Vectorial (SVM), también se realizarán pruebas con otras configuraciones de redes neuronales ocultas. Además, se ampliará el espectro para incluir experimentos utilizando señales de radio estaciones comerciales AM.

6. Agradecimientos

Este trabajo fue apoyado por el grupo de investigación AECC (COL0053581) del Instituto Tecnológico Metropolitano a través del proyecto P14208.

Referencias

- Adler, S., Schmitt, S., 2014. Path loss and multipath effects in a real world indoor localization scenario. 2014 11th Workshop on Positioning, Navigation and Communication, WPNC 2014 1.
DOI: 10.1109/WPNC.2014.6843300
- Al, M., Amali, A., Khir, M. H., Saad, N. M., Dass, S. C., 2017. WiFi Fingerprinting Indoor Positioning with Multiple Access Points in a Single Base Station using Probabilistic Method. International Journal of Applied Engineering Research 12 (6), 1102–1113.
- Ali-Rantala, P., Ukkonen, L., Sydanheimo, L., Keskilampi, M., Kivikoski, M., 2003. Different kinds of walls and their effect on the attenuation of radiowaves indoors. IEEE Antennas and Propagation Society International Symposium. Digest. Held in conjunction with: USNC/CNC/URSI North American Radio Sci. Meeting (Cat. No.03CH37450) 3, 1020–1023.
DOI: 10.1109/APS.2003.1220085
- Anastasijev, A., Neškovi, A., 2012. A practical realisation of kNN indoor positioning model for GSM. In: Telecommunications Forum (TELFOR), 2012 20th. No. m. pp. 1–4.
- Batišić, L., Tomic, M., 2018. Overview of Indoor Positioning System Technologies. 2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), 473–478.
DOI: 10.23919/MIPRO.2018.8400090
- Blankenbach, J., Norrdine, A., Hellmers, H., 2012. A robust and precise 3d indoor positioning system for harsh environments. In: Indoor Positioning and Indoor Navigation (IPIN), 2012 International Conference on. IEEE, pp. 1–8.
- Campos, R., Lovisolo, L., 2015. RF Positioning: Fundamentals, Applications, and Tools: GNSS technology and applications series. Artech House, Ch. Fundamentals Of RF Fingerprint, pp. 79–109.
URL: <https://books.google.com.co/books?id=oLTQCgAAQBAJ>
- Chao, H., Gu, Y., Gross, J., Guo, G., Fravolini, M. L., Napolitano, M. R., 2013. A comparative study of optical flow and traditional sensors in uav navigation. In: American Control Conference (ACC), 2013. IEEE, pp. 3858–3863.
- Chen, Y., Lymberopoulos, D., Liu, J., Priyantha, B., 2013. Indoor localization using FM signals. IEEE Transactions on Mobile Computing 12 (8), 1502–1517.
DOI: 10.1109/TMC.2013.58
- Danymol, R., Ajitha, T., Gandhiraj, R., Dec 2013. Real-time communication system design using rtl-sdr and raspberry pi. In: 2013 International Conference on Advanced Computing and Communication Systems. pp. 1–5.
DOI: 10.1109/ICACCS.2013.6938691
- De Angelis, G., Pasku, V., De Angelis, A., Dionigi, M., Mongiardo, M., Moschitta, A., Carbone, P., 2015. An indoor ac magnetic positioning system. IEEE Transactions on Instrumentation and Measurement 64 (5), 1267–1275.

- Do, T.-H., Hwang, J., Yoo, M., 2013. Tdoa based indoor visible light positioning systems. In: Ubiquitous and Future Networks (ICUFN), 2013 Fifth International Conference on. IEEE, pp. 456–458.
- Domingo-Perez, F., Lázaro-Galilea, J. L., Martín-Gorostiza, E., Salido-Monzú, D., Wieser, A., 2014. Evolutionary optimization of sensor deployment for an indoor positioning system with unknown number of anchors. In: Ubiquitous Positioning Indoor Navigation and Location Based Service (UPINLBS), 2014. IEEE, pp. 195–202.
- Interaction, M., 2010. Indoor Positioning Using FM Radio. *International Journal of Handheld Computing Research (IJHCR)* 1 (3), 19–31.
- Khalajmehrabadi, A., Member, S., Gatsis, N., Akopian, D., Member, S., 2017. Modern WLAN Fingerprinting Indoor Positioning Methods and Deployment Challenges (c), 1–30. DOI: 10.1109/COMST.2017.2671454
- Kuflik, T., Lanir, J., Dim, E., Wecker, A., Corra, M., Zancanaro, M., 2012. Indoor Positioning in Cultural Heritage : Challenges and a Solution, 1–5.
- Le, W., Wang, Z., Wang, J., Zhao, G., Miao, H., 2014. A Novel WiFi Indoor Positioning Method Based on Genetic Algorithm and Twin Support Vector Regression. In: Control and Decision Conference (2014 CCDC), The 26th Chinese. No. 61174059. pp. 4859–4862.
- Le Dortz, N. and Gain, F. and Zetterberg, P., 2012. Wifi Fingerprint Indoor Positioning System Using Probability Distribution Comparison. *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on*, 2301–2304.
- Lee, C., Chang, Y., Park, G., Ryu, J., Jeong, S.-G., Park, S., Park, J. W., Lee, H. C., Hong, K.-s., Lee, M. H., 2004. Indoor positioning system based on incident angles of infrared emitters. In: Industrial Electronics Society, 2004. IECON 2004. 30th Annual Conference of IEEE. Vol. 3. IEEE, pp. 2218–2222.
- Liu, H., Member, S., Darabi, H., Banerjee, P., Liu, J., 2007. Survey of Wireless Indoor Positioning Techniques and Systems 37 (6), 1067–1080.
- Luo, P., Zhang, M., Zhang, X., Cai, G., Han, D., Li, Q., 2013. An indoor visible light communication positioning system using dual-tone multi-frequency technique. In: Optical Wireless Communications (IWOW), 2013 2nd International Workshop on. IEEE, pp. 25–29.
- Machaj, J., Brida, P., 2014. Using GSM Signals for Fingerprint-based Indoor Positioning System. In: ELEKTRO, 2014. pp. 64–67. DOI: 10.1109/ELEKTRO.2014.6847872
- Mainetti, L., Patrono, L., Sergi, I., 2014. A Survey on Indoor Positioning Systems. 2014 22nd International Conference on Software, Telecommunications and Computer Networks (SoftCOM). DOI: 10.1109/SOFTCOM.2014.7039067
- Matic, A., Popleteev, A., Osmani, V., Mayora-Ibarra, O., 2010. FM radio for indoor localization with spontaneous recalibration. In: Pervasive and Mobile Computing. Vol. 6. Elsevier B.V., pp. 642–656. URL: <http://dx.doi.org/10.1016/j.pmcj.2010.08.005> DOI: 10.1016/j.pmcj.2010.08.005
- Moghtadaiee, V., Dempster, A. G., 2014. FM Radio Signals. *IEEE TRANSACTIONS ON BROADCASTING* 60 (2), 336–346.
- Moghtadaiee, V., Dempster, A. G., Lim, S., 2011. Indoor localization using FM radio signals: A fingerprinting approach. 2011 International Conference on Indoor Positioning and Indoor Navigation, IPIN 2011, 3–9. DOI: 10.1109/IPIN.2011.6071932
- Murata, S., Yara, C., Kaneta, K., Ioroi, S., Tanaka, H., 2014. Accurate indoor positioning system using near-ultrasonic sound from a smartphone. In: Next Generation Mobile Apps, Services and Technologies (NGMAST), 2014 Eighth International Conference on. IEEE, pp. 13–18.
- Mustafah, Y. M., Azman, A. W., Akbar, F., 2012. Indoor uav positioning using stereo vision sensor. *Procedia Engineering* 41, 575–579.
- Niu, J., Wang, B., Cheng, L., Rodrigues, J. J. P. C., 2015. WicLoc : An Indoor Localization System based on WiFi Fingerprints and Crowdsourcing. In: 2015 IEEE International Conference on Communications (ICC). pp. 3008–3013.
- Niwa, H., Kodaka, K., Sakamoto, Y., Otake, M., Kawaguchi, S., Fujii, K., Kanemori, Y., Sugano, S., 2008. Gps-based indoor positioning system with multi-channel pseudolite. In: Robotics and Automation, 2008. ICRA 2008. IEEE International Conference on. IEEE, pp. 905–910.
- Nuaimi, K. A., Ain, A., Ain, A., 2011. A Survey of Indoor Positioning Systems and Algorithms, 185–190.
- Popleteev, A., Osmani, V., Mayora, O., 2012. Investigation of indoor localization with ambient FM radio stations. In: 2012 IEEE International Conference on Pervasive Computing and Communications. pp. 19–23.
- Regula, G., Góźse, I., Soumelidis, A., 2012. Position estimation using novel calibrated indoor positioning system. In: Instrumentation and Measurement Technology Conference (I2MTC), 2012 IEEE International. IEEE, pp. 1142–1147.
- Ruiz, D., Garcia, E., Urena, J., Villadangos, J. M., Garcia, J. J., De Marziani, C., 2014. Performance comparison of correlation-based receive filters in an ultrasonic indoor positioning system. In: Instrumentation and Measurement Technology Conference (I2MTC) Proceedings, 2014 IEEE International. IEEE, pp. 1548–1551.
- Selmi, I., Vervisch-Picois, A., Gottesman, Y., Samama, N., 2012. Optical and radio calibration of the repealite based indoor positioning system. In: Indoor Positioning and Indoor Navigation (IPIN), 2012 International Conference on. IEEE, pp. 1–8.
- Sertthin, C., Tsuji, E., Nakagawa, M., Kuwano, S., Watanabe, K., 2009. A switching estimated receiver position scheme for visible light based indoor positioning system. In: Wireless Pervasive Computing, 2009. ISWPC 2009. 4th International Symposium on. IEEE, pp. 1–5.
- Siller, M., 2016. A Fingerprinting Indoor Localization Algorithm Based Deep Learning. In: 2016 Eighth International Conference on Ubiquitous and Future Networks (ICUFN). pp. 1006–1011.
- Suzuki, A., Iyota, T., Choi, Y., Kubota, Y., Watanabe, K., Yamane, A., 2009. Measurement accuracy on indoor positioning system using spread spectrum ultrasonic waves. In: Autonomous Robots and Agents, 2009. ICARA 2009. 4th International Conference on. IEEE, pp. 294–297.
- Swangmuang, N., Krishnamurthy, P., 2008. An effective location fingerprint model for wireless indoor localization. *Pervasive and Mobile Computing* 4 (6), 836–850. URL: <http://dx.doi.org/10.1016/j.pmcj.2008.04.005> DOI: 10.1016/j.pmcj.2008.04.005
- Tian, Y., Denby, B., Pierre, U., 2014. Hybrid Indoor Localization using GSM Fingerprints , Embedded Sensors and a Particle Filter. In: Wireless Communications Systems (ISWCS), 2014 11th International Symposium on. pp. 542–547.
- Torteeke, P., Chundi, X., 2014. Indoor positioning based on Wi-Fi Fingerprint Technique using Fuzzy K-Nearest Neighbor. *Applied Sciences and Technology (IBCAST), 2014 11th International Bhurban Conference on*, 461–465. DOI: 10.1109/IBCAST.2014.6778188
- Varshavsky, A., Lara, E. D., Hightower, J., Lamarca, A., Otsason, V., 2007. GSM indoor localization. *Pervasive and Mobile Computing* 3, 698–720. DOI: 10.1016/j.pmcj.2007.07.004
- Vervisch-Picois, A., Samama, N., 2012. First experimental performances of the repealite based indoor positioning system. In: Wireless Communication Systems (ISWCS), 2012 International Symposium on. IEEE, pp. 636–640.
- Vervisch-Picois, A., Selmi, I., Gottesman, Y., Samama, N., 2010. Current status of the repealite based approach: A sub-meter indoor positioning system. In: Satellite Navigation Technologies and European Workshop on GNSS Signals and Signal Processing (NAVITEC), 2010 5th ESA Workshop on. IEEE, pp. 1–6.
- Wang, X., Gao, L., Mao, S., Pandey, S., 2015. DeepFi : Deep Learning for Indoor Fingerprinting Using Channel State Information. In: Wireless Communications and Networking Conference (WCNC), 2015 IEEE. pp. 9–12.
- Wietrzykowski, J., 2017. Low-Effort Place Recognition with WiFi Fingerprints Using Deep Learning. In: Automation 2017. ICA 2017. DOI: https://doi.org/10.1007/978-3-319-54042-9_7
- Xia, S., Liu, Y., Yuan, G., Zhu, M., Wang, Z., 2017. Indoor Fingerprint Positioning Based on Wi-Fi : An Overview. DOI: 10.3390/ijgi6050135
- Yamaguchi, S., Mai, V. V., Thang, T. C., Pham, A. T., 2014. Design and performance evaluation of vlc indoor positioning system using optical orthogonal codes. In: Communications and Electronics (ICCE), 2014 IEEE Fifth International Conference on. IEEE, pp. 54–59.
- Yazici, A., Yayan, U., Yücel, H., 2011. An ultrasonic based indoor positioning system. In: Innovations in Intelligent Systems and Applications (INISTA), 2011 International Symposium on. IEEE, pp. 585–589.
- Zhao, J., Wang, J., 2017. WiFi Indoor Positioning Algorithm Based on Machine Learning. In: Electronics Information and Emergency Communication (ICEIEC), 2017 7th IEEE International Conference on. DOI: 10.1109/ICEIEC.2017.8076562
- Zhuang, Y., Syed, Z., Georgy, J., 2015. Autonomous smartphone based WiFi positioning system by using access points localization and crowdsourcing. *Pervasive and Mobile Computing*. URL: <http://dx.doi.org/10.1016/j.pmcj.2015.02.001> DOI: 10.1016/j.pmcj.2015.02.001
- Zou, H., Luo, Y., Lu, X., Jiang, H., Xie, L., 2015. A Mutual Information Based Online Access Point Selection Strategy for WiFi Indoor Localization. In: Automation Science and Engineering (CASE), 2015 IEEE International Conference on. pp. 24–28. DOI: 10.1109/CoASE.2015.7294059