

# Dispositivo IoT para la localización con fusión de rangos

Emil J. Khatib, Carlos S. Álvarez-Merino, José Antonio Trujillo, Raquel Barco  
emil@uma.es, cam@ic.uma.es, jats@ic.uma.es, rbarco@uma.es  
Instituto de Investigación TELMA. Universidad de Málaga

**Resumen**—This paper presents the development and evaluation of a novel indoor localization device that integrates Ultra-Wideband (UWB), WiFi, and WiFi Fine Timing Measurement (FTM) technologies. By combining these technologies, our work aims to enhance localization accuracy and reliability compared to systems reliant on a single technology. A hardware prototype is developed, and the necessary infrastructure for its operation is described, along with a specialized localization algorithm that adapts to the characteristics of the combined signals. Measurement results from a test environment demonstrate significant improvements in precision and reliability. This integrated approach also contributes to cost reduction by opportunistically utilizing existing reference points within a scenario.

## I. INTRODUCCIÓN

La capacidad de determinar la ubicación precisa de personas u objetos en escenarios de interiores se ha convertido en una cuestión de creciente interés [1] en diversos campos, como la logística, la seguridad y la gestión de instalaciones, entre otros. A diferencia de la localización en exteriores, donde tecnologías como el GPS/GNSS [2] ofrecen soluciones robustas y ampliamente adoptadas, la localización en interiores presenta desafíos únicos debido a la complejidad de las señales en espacios cerrados, la presencia de obstáculos y la necesidad de una mayor precisión.

Los principales retos [3], [4] para la localización en interiores incluye la atenuación y reflexión de señales en obstáculos, la propagación multicamino, donde una señal puede tomar múltiples caminos para llegar al receptor, y la interferencia de diversas fuentes, lo que complica la tarea de obtener mediciones precisas y fiables. Además, la necesidad de implementar soluciones que requieran una infraestructura mínima y que sean escalables y económicas añade otra capa de complejidad.

En este contexto, han surgido diversas tecnologías intentando solventar estas dificultades, cada una con sus ventajas y limitaciones. El Ultra-Wideband (UWB) [5] y el WiFi [6], incluyendo las extensiones como el WiFi Fine Timing Measurement (FTM) [7], son tecnologías prometedoras debido a su capacidad para proporcionar mediciones precisas del tiempo de llegada de las señales, lo que es crucial para la localización precisa. Sin embargo, la integración efectiva de estas tecnologías y la superación de sus limitaciones individuales sigue siendo un área activa de investigación.

Este trabajo contribuye a este campo al proponer un dispositivo de localización basado en la combinación de UWB, WiFi y WiFi-FTM, buscando explotar las fortalezas de cada tecnología. Se describe el desarrollo de un prototipo hardware, la infraestructura necesaria para su funcionamiento, un algoritmo de localización adaptado a las características de las señales combinadas y los resultados de las mediciones realizadas en un entorno de prueba. Este enfoque integrado ofrece mejoras

significativas en precisión y fiabilidad en comparación con los sistemas basados en una única tecnología, y contribuye a la reducción de costes al aprovechar de forma oportunista los puntos de referencia preexistentes en un escenario.

El resto del documento está organizado de la siguiente manera: en la Sección , se discuten en detalle los desafíos de la localización en interiores y las tecnologías existentes. La Sección describe el diseño y desarrollo del prototipo de hardware, seguido por una descripción de la infraestructura necesaria en la Sección . La Sección presenta el algoritmo de localización desarrollado, mientras que la Sección detalla las mediciones y los resultados obtenidos. Finalmente, la Sección concluye el trabajo y esboza las direcciones futuras de investigación en este campo.

## II. LOCALIZACIÓN EN INTERIORES

La localización en interiores busca resolver el problema de determinar la posición precisa de un objeto o persona dentro de un espacio cerrado, donde las señales de GPS son ineficaces debido a la falta de visibilidad directa con los satélites. La formulación matemática de este problema puede describirse a través de la relación entre la posición desconocida de un dispositivo  $p = (x, y, z)$  y la posición conocida de varios puntos de referencia  $p_i = (x_i, y_i, z_i)$

Tradicionalmente, hay dos grandes familias de soluciones para la localización en interiores: las basadas en trilateración [?] y las basadas en *fingerprinting* [6]. La trilateración utiliza la distancia  $d_i = \sqrt{(x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2}$  a tres o más puntos de referencia para determinar la ubicación exacta del objeto o persona. En la práctica, dicha distancia no es conocida a priori, por lo se obtiene una estimación  $\hat{d}_i$ . Para ello, se usan tecnologías radio como UWB, WiFi y Bluetooth, donde cada tecnología ofrece diferentes grados de precisión en la estimación y requisitos de infraestructura. El principal coste de este método es la necesidad de que en cada punto se reciban al menos  $N + 1$  puntos de referencia, siendo  $N$  el número de dimensiones de las coordenadas (normalmente 2 o 3). Esto conlleva la necesidad de desplegar una infraestructura relativamente densa de puntos de referencia que permitan calcular la distancia. Técnicas como la fusión oportunista [8] permiten reducir la necesidad de infraestructura.

En el caso de UWB y WiFi-FTM, la medición de tiempo de llegada (Time of Arrival, ToA) de la señal permite calcular la distancia entre el objeto y el punto de referencia con alta precisión, de forma similar a como se hace en GPS. Esta estimación está sujeta a errores producidos por bloqueos y reflexiones. Otra opción es usar la potencia recibida, como se hace en WiFi y Bluetooth al no ofrecer un protocolo para la medición de tiempo. En este caso, se aprovechan los modelos

de propagación  $r_i = f(d_i)$  que relacionan la potencia recibida de un punto de referencia  $r_i$  con la distancia  $d_i$ .

No obstante, la medida de la distancia con la potencia es mucho menos precisa, dado que en interiores existen obstáculos, efectos de guiado y reflexiones que cambian mucho y de formas imprevisibles el modelo de propagación. En estos casos, el fingerprinting puede proporcionar mejores resultados. En fingerprinting, se parte del hecho de que el entorno, a pesar de su complejidad radioeléctrica, es relativamente estático, por lo que la potencia recibida  $p_i$  en un punto del espacio desde un punto de referencia permanece estable en el tiempo. Si se toman medidas de  $N$  puntos de referencia, se puede crear un vector  $R = (r_1, r_2, \dots, r_N)$  de potencias medidas. Cada punto del espacio  $j$  tendrá un vector  $R_j$  característico y relativamente estable en el tiempo, por lo que la localización consiste en tomar medidas de potencia de los  $N$  puntos de referencia, generar un vector  $R$  y buscar el vector  $R_j$  más parecido. A pesar de verse menos afectado por los efectos de la propagación en interiores, fingerprinting no está exento de sus propios problemas. En primer lugar, se necesita siempre una fase previa de creación del mapa de vectores característicos, lo cual conlleva un coste preliminar alto. Los cambios en el entorno, tanto a corto plazo (puertas, personas, etc.) como a largo plazo (cambios en los puntos de referencia, muebles, etc.) hacen que los vectores característicos cambien con el tiempo, llevando a posibles errores en la localización. Para mitigar dichos errores, es recomendable recrear los mapas con cierta frecuencia, lo cual incrementa aún más los costes del método.

Una tercera aproximación, cada vez más estudiada, es la proporcionada por la IA [9]. Los modelos de IA, particularmente las redes neuronales, pueden ser entrenados para interpretar complejas señales de radio y patrones ambientales, aprendiendo a correlacionarlos con ubicaciones específicas. Por ejemplo, un modelo de IA puede ser formulado para predecir la posición  $p$  dado un conjunto de señales  $S = \{s_1, s_2, \dots, s_N\}$ , donde cada señal  $s_i$  es una característica derivada de la señal de radio, como la potencia recibida o el tiempo de llegada de un punto de referencia concreto. La relación aprendida por el modelo puede representarse como  $p = f(S, \theta)$  donde  $f$  es la función modelada por la red neuronal y  $\theta$  representa los parámetros del modelo aprendidos durante el entrenamiento.

### III. DISPOSITIVO DE LOCALIZACIÓN

En este trabajo se presenta un dispositivo que toma medidas de señales radio diversa índole de distintos tipos de puntos de referencia, con el fin de usarlos de forma oportunista para obtener la localización en interiores. El dispositivo se apoyará en un servidor (descrito en la Sección IV) para realizar la estimación de la localización en base a las medidas obtenidas.

El dispositivo, representado en la Figura 1, tiene cuatro componentes hardware diferenciados:

- Microcontrolador ESP32-S2-Saola-1: Plataforma de desarrollo de bajo consumo que integra Wi-Fi y tiene capacidades para aplicaciones de IoT. Esta versión tiene soporte de WiFi-FTM, con lo que es ideal para aplicaciones de sensado de distancia. Además de para medir las distancias a puntos de referencia WiFi-FTM,




Fig. 1. Foto del dispositivo.

se utilizará como núcleo del sistema, conteniendo el firmware descrito más abajo.

- Placa UWB Qorvo DWM1001: Módulo integrado que ofrece capacidades de comunicación y localización precisas utilizando tecnología UWB. En este dispositivo, se utilizará para medir las distancias con puntos de referencia UWB. Se conecta al microcontrolador mediante un puerto serie.
- Placa de carga de batería DFR0208: Circuito de gestión de carga diseñado para facilitar la recarga segura de baterías de ion-litio.
- Batería de ion-litio 852040: Fuente de alimentación recargable que proporciona 3.7 V de alimentación y con una capacidad de 620 mAh.

El firmware que se ejecuta en el módulo ESP32 está basado en FreeRTOS [10]. Integra tres *tasks* o tareas que se ejecutan de forma regular:

- Tarea de medida de WiFi-FTM: Realiza un escaneo de los puntos de acceso disponibles, comprobando si soportan FTM. Para cada punto de acceso con FTM, realiza una estimación de la distancia y la envía, junto con el SSID y la potencia medida (RSSI) a la tarea de comunicación.
- Tarea de medida de UWB: Realiza un escaneo de los *anchors* disponibles y calcula la distancia para cada uno de ellos. Envía a la tarea de comunicación la estimación junto con el identificador y el RSSI.
- Tarea de comunicación: recibe las medidas de las tareas anteriores en una cola y genera un paquete JSON con ellas. A continuación se conecta a una red WiFi predefinida y envía el paquete con las medidas a una IP predefinida donde se ejecuta el servidor descrito en la Sección IV.

La tarea de comunicación debe conectarse a la red WiFi sólo para enviar los paquetes, y desconectarse a continuación. Esto es así porque la funcionalidad de escaneo y medida de distancias FTM sólo funciona cuando el dispositivo no está conectado a ninguna red WiFi.

### IV. INFRAESTRUCTURA

El dispositivo descrito en la Sección III contiene las funciones de recogida de datos de distancia, pero no se encarga del cálculo de la posición. Esta funcionalidad se encuentra desagregada y la realiza un servidor en el que se ejecutan los algoritmos de localización descritos en la




Fig. 2. Mensajes JSON con medidas de distancia.

Sección V. Esto tiene una serie de ventajas; por un lado, el dispositivo de localización es más sencillo y puede usar un hardware relativamente poco potente y con un menor consumo de energía. Por otro lado, la ejecución centralizada de los algoritmos de localización permite mejorar éstos con el tiempo. La centralización de las medidas también abre las puertas a numerosas aplicaciones para la monitorización del entorno radioeléctrico (como por ejemplo, mantener un mapa actualizado de las medidas de potencia en distintos puntos del espacio) y para el entrenamiento de algoritmos de IA.

El servidor desplegado para este sistema consiste en una Raspberry Pi 4 con el sistema operativo Raspbian, y una interfaz WiFi que hace de punto de acceso. El dispositivo descrito en la Sección III se conecta a dicho punto de acceso y envía sus medidas en formato JSON a un servidor que escucha en el puerto 80 de la interfaz de red WiFi.

El software desplegado sobre este servidor se compone de tres elementos principales:

- API web basada en microservicios para la recepción de las cajas JSON con las mediciones. Este *endpoint* está basado en Flask [11]. Una vez recibidas las mediciones, el servicio publica esta información a través de un *broker*.
- Algoritmo de localización: toma los datos publicados por la API web y con ellos calcula la localización usando el algoritmo descrito en la Sección A.
- Broker RabbitMQ [?]: se encarga de comunicar los distintos módulos. Permite extender fácilmente el sistema, añadiendo nuevos módulos (por ejemplo, para añadir una función de persistencia que permita generar datasets, o una función de representación en tiempo real) sin necesidad de modificar otros módulos o parar el servidor.

El API contiene una funcionalidad mínima, permitiendo tan sólo peticiones de tipo POST con contenido JSON en el formato apropiado. En la Figura 2 se representa un mensaje que ilustra el tipo de datos enviados al endpoint. El endpoint enriquece la información recibida del dispositivo con la IP que identifica al dispositivo y una marca temporal.

Si bien en este trabajo se ha optado por usar un servidor físico, la arquitectura de sistema propuesta permite la virtualización del mismo. El servidor podría ser una máquina virtual situada en Internet, o incluso aprovechar funcionalidades avanzadas como son el Edge Computing [12].

## V. ALGORITMO DE LOCALIZACIÓN

El algoritmo de localización utilizado es el de fusión de tecnologías descrito en [8]. Este algoritmo se diseñó para

combinar rangos obtenidos con UWB, WiFi-FTM y, potencialmente, señales de redes móviles y medidas de potencia para mejorar la precisión y disponibilidad de la localización en interiores. Este enfoque aborda la limitación de la densidad y cobertura de los puntos de referencia requeridos por tecnologías individuales y reduce el costo general de despliegue de la infraestructura para servicios de localización.

El algoritmo propuesto emplea una estimación de máxima verosimilitud (Maximum Likelihood Estimation, MLE) para ponderar las medidas de los diferentes puntos de referencia basándose en su precisión y confiabilidad histórica. La fusión de tecnologías permite aprovechar las fortalezas individuales de cada tecnología, como la alta precisión del UWB o la alta disponibilidad del WiFi, para proporcionar una solución de localización más robusta y precisa en interiores.

El algoritmo funciona de la siguiente manera:

1. Recepción de medidas de distancia: el algoritmo recibe información de distancia del dispositivo hacia múltiples puntos de referencia de diferentes tecnologías.
2. Ponderación inicial de cada punto de referencia: si un punto de referencia es nuevo, se le asigna un peso inicial bajo. Si no, se pondera según la precisión de las mediciones anteriores.
3. Cálculo de la posición: se utiliza el algoritmo de cuadrados mínimos ponderados (Weighted Least Squares, WLS) para calcular la posición del objetivo basándose en las mediciones ponderadas.
4. Estimación de la distancia y el error: se estima la distancia desde la posición calculada a cada punto de referencia y se calcula el error entre las distancias estimadas y las medidas.
5. Actualización de pesos: los pesos de los puntos de referencia se actualizan para la próxima iteración basándose en el error estimado, privilegiando las fuentes de datos más precisas y estables.

Este proceso iterativo permite que el sistema ajuste dinámicamente la importancia de las mediciones de cada tecnología, mejorando la precisión de la localización en entornos interiores complejos y dinámicos. La combinación de diferentes tecnologías de localización mediante un algoritmo de fusión y MLE optimiza la precisión de la localización, haciendo un uso eficiente de la infraestructura disponible y reduciendo los costes de implementación.

## VI. MEDIDAS

En esta sección se describirá brevemente una campaña de medidas tomada para demostrar el funcionamiento del dispositivo. Para ello, se ha habilitado una infraestructura con varios puntos de referencia WiFi-FTM y UWB en aulas de la Universidad de Málaga, tal y como se muestra en la Figura 3. Hay un total de 3 puntos de referencia WiFi-FTM y 3 UWB. Se ha habilitado el servidor descrito en la Sección IV en este escenario, al que un prototipo del dispositivo descrito en la Sección III reporta medidas. Se han tomado medidas en 300 puntos, de los cuales se muestran los primeros 150 en la Figura 3, mostrando en verde el recorrido original y en rojo el recorrido estimado.

Para obtener una estimación del error de localización, se ha representado en la Figura 4 la ECDF del error de localización.

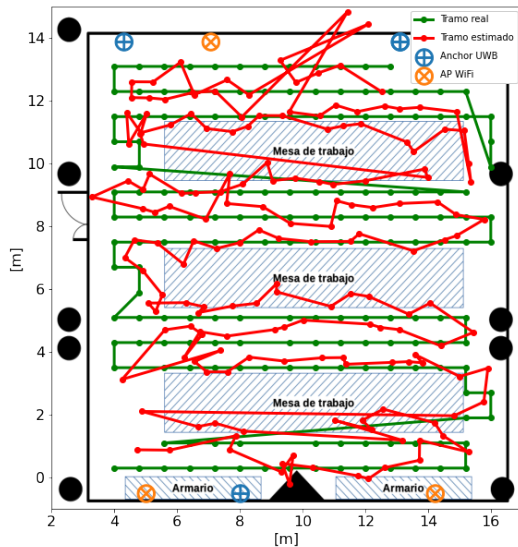


Fig. 3. Mapa del entorno de uno de los recorridos y medidas tomadas.




Fig. 4. Error de localización con los percentiles 50 y 90 marcados.

Se puede observar que el error tiene una mediana de 94cm y un percentil 90 de 4.48m.

## VII. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se ha descrito un prototipo de un dispositivo de localización oportunista. Este dispositivo tiene un funcionamiento muy sencillo, y se limita a tomar medidas de distancia y potencia de distintas tecnologías radio. El dispositivo reporta las medidas a un servidor que, mediante un algoritmo de localización usa dichas medidas para proveer una estimación de la posición. Se ha demostrado el funcionamiento de un prototipo del dispositivo en un escenario de oficina.

Este trabajo abre las puertas a nuevas oportunidades de desarrollo. Concretamente, se han identificado las siguientes líneas:

- Desarrollo de un algoritmo de localización basado en IA: gracias a la posibilidad de acumular medidas en el servidor, una posible línea de trabajo es la de desarrollar un modelo de IA tal y como se describe en la Sección II.

- Virtualización del servidor: tal y como se describe en la Sección I, otra posibilidad existente es usar un servidor completamente virtualizado. Para ello, se debe modificar mínimamente el firmware del dispositivo y los componentes software del servidor.
- Desarrollo de una aplicación de creación de mapas de interiores: la prueba realizada en este trabajo partía de un escenario donde la posición de los puntos de referencia estaba codificada en el servidor. Un aspecto importante para la practicalidad del sistema es facilitar la inclusión de dicha información en un escenario nuevo. Para ello, se ha identificado la necesidad de desarrollar un software con una interfaz gráfica sobre la que añadir información de los puntos de referencia.
- Simultaneous Location And Mapping (SLAM): como alternativa, una opción al punto anterior sería la de usar algoritmos de localización y mapeo simultáneos [13], que eliminan la necesidad de introducir la información de los puntos de referencia a mano.

## AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado por la Universidad de Málaga en el marco del I Plan Propio de Investigación y Transferencia de la Universidad de Málaga, bajo el proyecto DOLI (E31722).

## REFERENCIAS

- [1] H. Huang, G. Gartner, J. M. Krisp, M. Raubal, and N. Van de Weghe, "Location based services: ongoing evolution and research agenda," *Journal of Location Based Services*, vol. 12, no. 2, pp. 63–93, 2018.
- [2] E. D. Kaplan and C. Hegarty, *Understanding GPS/GNSS: principles and applications*. Artech house, 2017.
- [3] F. Zafari, A. Gkelias, and K. K. Leung, "A survey of indoor localization systems and technologies," *IEEE Communications Surveys & Tutorials*, vol. 21, no. 3, pp. 2568–2599, 2019.
- [4] K. Wu, J. Xiao, Y. Yi, D. Chen, X. Luo, and L. M. Ni, "Csi-based indoor localization," *IEEE Transactions on Parallel and Distributed Systems*, vol. 24, no. 7, pp. 1300–1309, 2012.
- [5] F. Mazhar, M. G. Khan, and B. Sällberg, "Precise indoor positioning using uwb: A review of methods, algorithms and implementations," *Wireless Personal Communications*, vol. 97, no. 3, pp. 4467–4491, 2017.
- [6] C. Basri and A. El Khadimi, "Survey on indoor localization system and recent advances of wifi fingerprinting technique," in *2016 5th international conference on multimedia computing and systems (ICMCS)*. IEEE, 2016, pp. 253–259.
- [7] Y. Yu, R. Chen, L. Chen, S. Xu, W. Li, Y. Wu, and H. Zhou, "Precise 3-d indoor localization based on wi-fi ftm and built-in sensors," *IEEE Internet of Things Journal*, vol. 7, no. 12, pp. 11753–11765, 2020.
- [8] C. S. Alvarez Merino, H. Q. Luo-Chen, E. J. Khatib, and R. Barco, "Wifi ftm, uwb and cellular-based radio fusion for indoor positioning," *Sensors*, vol. 21, no. 21, 2021. [Online]. Available: <https://www.mdpi.com/1424-8220/21/21/7020>
- [9] M. D'Aloia, A. Longo, G. Guadagno, M. Pulpito, P. Fornarelli, P. N. Laera, D. Manni, and M. Rizzi, "IoT indoor localization with AI technique," in *2020 IEEE International Workshop on Metrology for Industry 4.0 & IoT*. IEEE, 2020, pp. 654–658.
- [10] "Freertos," Último acceso: 01/04/2024. [Online]. Available: <https://www.freertos.org>
- [11] "Flask," Último acceso: 01/04/2024. [Online]. Available: <https://flask.palletsprojects.com/>
- [12] C. Wang, C. Liang, F. R. Yu, Q. Chen, and L. Tang, "Computation offloading and resource allocation in wireless cellular networks with mobile edge computing," *IEEE Transactions on Wireless Communications*, vol. 16, no. 8, pp. 4924–4938, 2017.
- [13] R. Liu, S. H. Marakkalage, M. Padmal, T. Shaganan, C. Yuen, Y. L. Guan, and U.-X. Tan, "Collaborative slam based on wifi fingerprint similarity and motion information," *IEEE Internet of Things Journal*, vol. 7, no. 3, pp. 1826–1840, 2019.