

UNIVERSIDAD NACIONAL DE INGENIERÍA
FACULTAD DE CIENCIAS



TESIS

*Técnicas para la localización en interiores basado
en bluetooth-fingerprinting mediante algoritmos
de inteligencia artificial*

**PARA OBTENER EL TÍTULO PROFESIONAL DE:
LICENCIADO EN CIENCIA DE LA COMPUTACIÓN**

Elaborado por:

JESÚS ENRIQUE LOVÓN MELGAREJO

Asesor:

JOSÉ MANUEL CASTILLO CARA

LIMA - PERÚ

2018

*Este trabajo está dedicado a mis padres,
por haberme brindado una educación de calidad,
por sus consejos y ayuda cuando más los necesité.*

Agradecimientos

Agradezco infinitamente a mi familia, en especial a mis padres, por el esfuerzo y la confianza depositada en mí, por su orientación incondicional durante mi etapa de estudiante universitario.

Agradezco también al profesor Manuel Castillo-Cara por asesorarme y darme la oportunidad de pertenecer a este gran proyecto, que ha permitido desarrollarme como profesional en el ámbito de la investigación y más que todo por su amistad.

Al Programa Nacional de Innovación para la Competitividad y Productividad (Innovate Perú), por financiar este proyecto de investigación, de acuerdo al contrato FINCyT 363-PNICP-PIAP-2014.

Así también a mis profesores de la Universidad Nacional de Ingeniería (UNI) por las enseñanzas que me transmitieron; en especial a los profesores Rommel Romero y Oswaldo Velasquez por la formación y orientación hacia el análisis y desarrollo óptimo de problemas, que hoy en día forman parte de mi línea de investigación. Además, a los profesores de la Universidad Castilla de La Mancha (UCLM) : Luis Orozco-Barbosa, Ismael García-Varea y Enrique Arias, por compartir sus conocimientos y experiencias en el transcurso de este trabajo.

Finalmente, agradezco a todas las personas que de una u otra manera han contribuido en mi formación profesional y que no es necesario mencionarlas con nombre propio.

Resumen

En la actualidad, la geolocalización permite brindar mejores servicios de forma personalizada a cada usuario, principalmente mediante el uso de tecnologías ubicuas como Global Positioning System (GPS). Sin embargo, esta se ve limitada cuando no se encuentra en la línea de visión de los satélites, perdiendo precisión y utilidad, encontrándose inútil en problemas tales como determinar la ubicación de un usuario en un edificio de múltiples pisos.

Debido a la utilización masiva de Smartphones en la sociedad actual, los cuales incorporan varios periféricos como la tecnología Bluetooth, en la presente Tesis se estudia en profundidad el problema de localización en interiores; analizando sus características, dificultades y variables. Para ello se utiliza la tecnología Bluetooth Low Energy 4.0 (BLE4.0), la cual es un protocolo más ligero y de ahorro de energía al Bluetooth convencional; se determina la posición utilizando como fuente el Received Signal Strength Indication (RSSI), el cual es emitido por dispositivos conocidos como Beacons. Se aplican técnicas de trilateración bajo un modelo de radiopropagación, basado en la ecuación de Rappaport; y fingerprinting, usando algoritmos de Machine Learning para realizar clasificación: Support Vector Machine (SVM) y k-Nearest Neighbors (k-NN).

Estas técnicas se aplicaron y analizaron en distintos espacios físicos de experimentación, reconociendo los criterios que juegan un rol importante al realizar un despliegue y configuración del entorno para localización. Por último se propone un método novedoso para reconocer la mejor configuración del entorno a utilizar con el fin de mejorar la precisión de esta técnica.

Abstract

Currently, geolocation allows to provide better services in a personalized way to each user, mainly through the use of ubiquitous technologies such as GPS. However, this is limited when it is not in the line of sight of satellites, losing accuracy and performance, being useless in problems such as determining the location of a user in a multi floor building.

Due to the massive use of Smartphones in today's society, which incorporate several peripherals such as Bluetooth technology, in this thesis we study in depth the problem of indoor localization; analyzing its characteristics, difficulties and variables. To this aim, the technology BLE4.0 is used, which is a lighter and energy-saving protocol compared to conventional Bluetooth; the position is determined using as source the RSSI, which is issued by devices known as Beacons. Trilateration techniques are applied under a radiopropagation model, based on the Rappaport equation; and fingerprinting, using Machine Learning algorithms to perform classification: SVM and k-NN.

These techniques were applied and analyzed in different physical experimentation spaces, recognizing the criteria that play an important role when performing a deployment and configuration on the environment for indoor localization. Finally, a novel method is proposed to recognize the best configuration of the environment to be used in order to improve the precision of this technique.

Índice general

Resumen	III
1. Introducción	1
1.1. Motivación	1
1.2. Objetivos	3
1.3. Estructura de la Memoria	4
2. Antecedentes	6
2.1. Conceptos Previos	6
2.1.1. Bluetooth - BLE4.0	6
2.2. Trabajos Relacionados	9
2.2.1. Localización en interiores Estándar	9
Wi-Fi y Bluetooth	9
ZigBee	10
2.2.2. Localización con BLE 4.0	11
3. Mecanismos experimentales y algoritmos	13
3.1. Dispositivos móviles	13
3.2. Modelo de radiopropagación	14
3.2.1. Ecuación de Rappaport	14
3.3. Fingerprinting	15
3.3.1. k-Nearest Neighbors (k-NN)	16
3.3.2. Support Vector Machine (SVM)	17
3.4. Relevancia de los emisores	18
3.4.1. ExtraTrees	18
3.4.2. Gradient Boosting Classifier	19

3.5. Métricas	19
4. Minería de datos para Bluetooth-Smartphone	20
4.1. Sobre la atenuación del RSSI	20
4.1.1. Pasillo 1	20
4.1.2. Pasillo 2	22
4.2. Resultados experimentales	25
4.2.1. Área experimental 1	25
Caso 1: k-NN	27
Caso 2: SVM	29
4.2.2. Área experimental 2	31
4.3. Conclusiones sobre el RSSI y Intensidad de Transmisión (TxPower)	37
5. Minería de datos para Bluetooth-Antena	38
5.1. Atenuación de la señal y análisis del receptor	38
5.1.1. Análisis de precisión del receptor	38
5.1.2. Análisis del comportamiento del RSSI	39
5.2. Relevancia de los Beacons	44
5.3. Análisis de intensidad de transmisión simétrica	48
5.4. Análisis de intensidad de transmisión asimétrica	50
5.5. Localización basada en intensidad de transmisión asimétrica . . .	52
5.6. Análisis empírico de intensidad de transmisión asimétrica	56
5.7. Multipath Fading y su efecto en localización	58
6. Conclusiones y Trabajo a Futuro	60
6.1. Conclusiones	60
6.2. Trabajo a Futuro	61
6.2.1. Benchmark para mejorar la precisión con Algoritmos Clasificadores	61
6.2.2. Desarrollo de software de calibración automática	61
6.2.3. Métodos híbridos de posicionamiento en interiores usando Wi-Fi y Bluetooth	62

6.2.4. Evaluación óptima de Configuración Asimétrica de Intensidades	62
6.3. Competencias adquiridas	62
A. Jaalee Beacons	69
B. Áreas experimentales	72
B.1. Pasillo 1	72
B.2. Pasillo 2	72
B.3. Área experimental 1	74
B.4. Área experimental 2	74

Índice de figuras

2.1. Los 40 canales de BLE4.0 y los 3 canales más comunes de Wi-Fi. BLE4.0 solo utiliza los canales 37,38 y 39. Fuente: Faragher et al.[3]	7
2.2. Variación de RSSI en posición estática. Fuente: Faragher et al.[3] .	8
4.1. Valores RSSI experimentales y teóricos. TxPower = 0x06 en pasillo 1. Fuente: Elaboración propia.	21
4.2. Valores RSSI experimentales y teóricos. TxPower = 0x07 en pasillo 1. Fuente: Elaboración propia.	21
4.3. Valores RSSI experimentales y teóricos. TxPower = 0x08 en pasillo 1. Fuente: Elaboración propia.	21
4.4. Valores RSSI experimentales y teóricos. TxPower = 0x06 en pasillo 2. Fuente: Elaboración propia.	23
4.5. Valores RSSI experimentales y teóricos. TxPower = 0x07 en pasillo 2. Fuente: Elaboración propia.	23
4.6. Valores RSSI experimentales y teóricos. TxPower = 0x08 en pasillo 2. Fuente: Elaboración propia.	23
4.7. Distribución de Beacons para el área experimental 1. Fuente : Elaboración propia.	26
4.8. Error de posicionamiento(m) usando k-NN, según WD y MD. Mapas de calor para TxPower = 0x07. Fuente: Elaboración propia.	28
4.9. Error de posicionamiento(m) usando SVM. Mapas de calor para TxPower = 0x07. Fuente: Elaboración propia.	28
4.10. Error acumulado para 5-NN usando WD, excluyendo el Beacon Be09. Fuente: Elaboración propia.	32

4.11. Distribución de Beacons para el área experimental 2. Fuente: Elaboración propia.	32
4.12. Error de posicionamiento(m) usando k-NN. Mapas de calor para TxPower = 0x04. Fuente: Elaboración propia.	35
4.13. Error de posicionamiento(m) usando k-NN. Mapas de calor para TxPower = 0x07. Fuente: Elaboración propia.	35
5.1. RSSI (dBm) para Antena BLE4.0 y Smartphone con TxPower = 0x04 para cada sector(1,15) del área experimental 2. Fuente: Elaboración propia.	41
5.2. Comparación de RSSI para distintos Beacons con TxPower = 0x04. Fuente: Elaboración propia.	43
5.3. Score de relevancia para cada Beacon usando el algoritmo ExtraTrees para distintas TxPower. Fuente: Elaboración propia. .	46
5.4. Score de relevancia para cada Beacon usando el algoritmo Gradient Boosting Classifier para distintas TxPower. Fuente: Elaboración propia.	47
5.5. Valores RSSI para los mejores (arriba) y peores (abajo) TxPower, para los Beacons 'Be07', 'Be09' y 'Be10' en el área experimental 2, capturados por la Antenna BLE4.0. Fuente: Elaboración propia. .	49
5.6. Valores RSSI para distintas TxPower para los Beacons BLE4.0 'Be11', 'Be07' y 'Be08'. Fuente: Elaboración propia.	51
5.7. Error de posicionamiento para k-NN (k=5). En ambos gráficos se muestran las 3 mejores y peores combinaciones de TxPower. Fuente: Elaboración propia.	53
5.8. Error de posicionamiento para SVM (con kernel polinomial de grado 2). Se muestran las 3 mejores y peores combinaciones de TxPower. Fuente: Elaboración propia.	54
5.9. Valores RSSI usando las configuración de TxPower más relevante, para cada Beacon: [4,1,2,1,1]. Fuente: Elaboración propia. 55	
A.1. Características de los Beacons Jaalee. Fuente: Jaalee web	69

B.1. Pasillo 1 del Instituto de Investigación en Informática de Albacete (i ³ A) Fuente: Elaboración propia.	73
B.2. Pasillo 2 del i ³ A	73
B.3. Área experimental 1 del i ³ A. Fuente: Elaboración propia.	75
B.4. Área experimental 2 del i ³ A. Fuente: Elaboración propia.	75

Índice de cuadros

4.1. Error Cuadrático Medio y Desviación Estándar para cada TxPower en pasillo 1. Fuente: Elaboración propia.	22
4.2. Error Cuadrático Medio y Desviación Estándar para cada TxPower en pasillo 2. Fuente: Elaboración propia.	22
4.3. Error Cuadrático Medio y Desviación Estándar para cada TxPower en pasillo 1, hasta 8m. Fuente: Elaboración propia. . . .	24
4.4. Error medio usando k-NN y criterio MD para el área experimental 1. Fuente: Elaboración propia.	27
4.5. Error medio usando k-NN y WD para el área experimental 1. Fuente: Elaboración propia.	29
4.6. Error medio usando SVM para distintos grados de kernel en área experimental 1. Fuente: Elaboración propia.	30
4.7. Tiempos de ejecución para cada técnica, en milisegundos (ms). Fuente: Elaboración propia.	30
4.8. Datos de entrenamiento y validación. Fuente: Elaboración propia.	33
4.9. k -NN - error medio (m), usando MD y WD, para distintas configuraciones de Beacons con TxPower = 0x04 y TxPower = 0x07. Fuente: Elaboración propia.	34
4.10. Coeficiente de error con las mejores configuraciones para k -NN, usando MD y WD. Fuente: Elaboración propia.	36
5.1. Precisión global, para k-NN usando MD ($k = 5$) y SVM (polinomial $g = 2$) con TxPower = 0x04. Fuente: Elaboración propia.	39
5.2. Número de muestras de RSSI capturados en distintos TxPower. Fuente: Elaboración propia.	45

5.3. Precisión global usando la Antena BLE4.0 para k-NN ($k = 5$) usando MD y SVM (kernel polinomial $g = 2$) para distintos TxPower. Fuente: Elaboración propia.	48
5.4. Precisión local por sector en porcentaje (%), usando k-NN moda ($k = 5$). Las esquinas y costados son las posiciones de los Beacons. La configuración de intensidades es [4,1,2,1,1]. Fuente: Elaboración propia.	54
5.5. Precisión local por sector en porcentaje (%), usando SVM (kernel polinomial $g = 2$). Las esquinas y costados son las posiciones de los Beacons. La configuración de intensidades es [4,1,2,1,1]. Fuente: Elaboración propia.	56
5.6. Error acumulado de posicionamiento con distintos TxPower para k-NN ($k = 5$) usando WD y MD; y SVM (kernel polinomial $g = 2$). Fuente: Elaboración propia.	57
5.7. Error medio para k-NN ($k = 5$) usando distancia WD y MD; y SVM (kernel polinomial $g = 2$) para distintas TxPower. Fuente: Elaboración propia.	57
5.8. Precisión para k-NN usando MD ($k = 5$) (derecha) y SVM (kernel polinomial $g = 2$) (izquierda). Mejores y peores configuraciones asimétricas de intensidades, y la mejor configuración simétrica de intensidades (en letra <i>cursiva</i>). Fuente: Elaboración propia.	58
A.1. RSSI base según TxPower a 1 metro. Fuente: Jaalee web.	71
A.2. Intervalos entre transmisión según cada TxPower. Fuente: Jaalee web	71

Índice de Acrónimos

GPS Global Positioning System

RSSI Received Signal Strength Indication

TxPower Intensidad de Transmisión

dB Decibelios

BLE4.0 Bluetooth Low Energy 4.0

k-NN k-Nearest Neighbors

SVM Support Vector Machine

ms milisegundos

s segundos

MHz Megahercios

GHz Gigahercios

WD Distancia Ponderada

MD Distancia por Moda

ExtraTrees Extremely Randomized Trees

i³A Instituto de Investigación en Informática de Albacete

UCLM Universidad Castilla - La Mancha

ECM Error Cuadrático Medio

ReTiCS Sistemas Concurrentes y Tiempo Real

Capítulo 1

Introducción

En este capítulo se presenta el problema a tratar, comentando inicialmente los alcances en la actualidad de la geolocalización, sus aplicaciones y limitaciones; y el porqué es interesante encontrar métodos alternativos que usen herramientas de alcance masivo como Smartphones. También se presentan los objetivos planteados y la estructura principal del mismo para una mejor orientación del lector.

1.1. Motivación

La geolocalización es parte esencial para el desarrollo de servicios y aplicaciones, ya que mejoran la experiencia del usuario en la personalización de ofertas o sugerencias de actividades según el entorno en el que se encuentre. Por mencionar algunas de sus aplicaciones Google Fit o Runtastic brindan reportes para deportistas, sobre una ruta o sesión de ejercicio a campo abierto; Uber o Taxibeat estiman una tarifa y tiempo de llegada según la posición actual del usuario hasta su destino; AccuWeather o WeatherOn emiten notificaciones en tiempo real si existe algún cambio brusco en el clima, según la posición actual del usuario.

Con GPS y el uso masivo de Smartphones que poseen integrados este sensor, se ha logrado satisfacer la mayoría de demandas que involucran este servicio bajo la condición de que sean en lugares abiertos. Este sistema de localización trabaja con satélites; para determinar la ubicación con mayor

precisión necesita encontrarse en la línea de visión de estos, con la menor cantidad de obstáculos posibles. Esta limitación impulsa a investigar algunos métodos alternativos para llevar la geolocalización al siguiente nivel: lugares bajo techo o muy aglomerados; es decir, lugares en el que el entorno sea un obstáculo para el correcto funcionamiento del sistema GPS y obtención de una triangulación satelital óptima.

En la actualidad es común el uso de Smartphones, la mayoría de estos dispositivos vienen integrados con distintos sensores como acelerómetro, giroscopio, antenas Bluetooth, Wi-Fi, GPS, entre otros. Considerando que el uso de tecnologías inalámbricas tiene una gran presencia en el mercado, se están desarrollando técnicas que permiten realizar la localización en entornos cerrados usando estos dispositivos, haciendo análisis del RSSI que emiten. El RSSI es un valor numérico dado en Decibelios (dB) que puede ser capturado por un dispositivo con un receptor de señales. Estas señales son afectadas en dos ámbitos principales, una es la distancia entre emisor y receptor, la otra es la interferencia que exista en el medio pudiendo ser ruido y/u obstáculos.

Aprovechando las instalaciones de routers Wi-Fi en la mayoría de centros comerciales y empresas, existen grandes avances haciendo uso de estos en un intento de reutilizar lo que ya está establecido. Sin embargo, al ser dispositivos que fueron implementados para la transmisión de información, la actualización de la señal RSSI que se obtiene no es tan rápida en la mayoría de casos. Este aspecto puede causar un retraso en la actualización de la posición en tiempo real.

Tomando en cuenta estos avances y con la reciente tecnología Bluetooth con protocolo 4.0 (disponible en dispositivos móviles), la presente Tesis realiza un análisis de los principales criterios que afectan a un correcto despliegue y configuración de un entorno para localización en interiores. Se implementan una serie de algoritmos óptimos basados en técnicas de Inteligencia Artificial

para la localización en interiores con Beacons como emisores. Cabe resaltar que los Beacons son dispositivos BLE4.0 con la particularidad que se alimentan de una batería y su tiempo de vida es de varios años.

1.2. Objetivos

El objetivo de esta Tesis es realizar un análisis de los criterios y variables principales a tener en cuenta al desplegar y configurar un entorno para localización en interiores, además, proponer un método para encontrar la configuración óptima. Este entorno está basado en la señal RSSI emitida por dispositivos Bluetooth.

Para el desarrollo de esta plataforma de localización se desarrollará una aplicación basada en Android, usando las librerías nativas de Bluetooth de esta; se trabajará con una API 18 (Android 4.3 Jelly Bean) mínimamente ya que es a partir de esta versión cuando existe soporte para BLE4.0. También se utilizará una Raspberry Pi 2 con una antena Bluetooth incorporada.

Por otro lado, se llevará a cabo un post procesamiento de datos desde una laptop; se realizará el análisis usando scripts en Matlab, aprovechando las librerías implementadas de k-NN y SVM; y configuración y programación de una Raspberry Pi 2.

Concretamente, se pueden determinar los objetivos de este proyecto como:

- Desarrollar un análisis sobre la tecnología BLE4.0.
- Analizar técnicas de localización en interiores aplicadas sobre BLE4.0.
- Implementar pruebas de validación para determinar qué técnica es la mejor.
- Desarrollar una aplicación móvil en Android para la captura de datos desde el dispositivo para distintas configuraciones de espacio.

- Desarrollar scripts para el análisis de datos basados en Machine Learning o trilateración.
- Estudiar técnicas y librerías de software apropiadas para el desarrollo del proyecto.
- Análisis del conjunto de datos obtenidos de los BLE4.0 mediante técnicas basadas en Data Mining.
- Utilizar técnicas algorítmicas basadas en inteligencia artificial para el análisis y desarrollo del sistema de localización.

1.3. Estructura de la Memoria

El presente trabajo tiene la siguiente estructura, que se detalla a continuación para la mejor orientación del lector.

- **Introducción.** Se presenta la coyuntura actual sobre el desarrollo de este estudio y las limitaciones principales que existen en este campo, así como los últimos enfoques que se desarrollan para sobrellevarlos. Además, se indican los objetivos.
- **Antecedentes.** En este capítulo se introducen conceptos previos, esencialmente de la tecnología usada en el proyecto, BLE4.0; y los trabajos que existen actualmente (usando esta tecnología y otras basadas en localización inalámbrica como Wi-Fi).
- **Mecanismos experimentales y algoritmos.** Se explica el procedimiento analítico previo al estudio, requerimientos y la definición de las métricas utilizadas durante la investigación.
- **Minería de datos para Bluetooth-Smartphone.** Se analizan los criterios encontrados para el problema de localización, con el fin de mejorar la configuración del sistema.

- **Minería de datos para Bluetooth-Antena.** Con el análisis del capítulo anterior se propone un método que brinda la mejor configuración en un entorno, para mejorar la localización, utilizando intensidades de transmisión asimétrica en los emisores.
- **Conclusiones y Trabajo a Futuro.** Finalmente se exponen las conclusiones de este estudio y se plantean los posibles enfoques para seguir la investigación del tema.

Capítulo 2

Antecedentes

En este capítulo se presenta la tecnología BLE4.0: su funcionamiento, sus limitaciones y su protocolo de comunicación. Además, se listan las tecnologías alternas utilizadas para resolver problemas de localización en interiores y los estudios más relevantes que moldearon la línea de partida de esta Tesis, así como los problemas sobre los cuales se desarrolla.

2.1. Conceptos Previos

Se presenta la tecnología BLE4.0 indicando sus principales características y principal funcionamiento.

2.1.1. Bluetooth - BLE4.0

La tecnología BLE4.0 se ha difundido rápidamente en los últimos años, estando presente en la mayoría de dispositivos móviles, como Smartphones, en los cuales Android incluyó el soporte para plataformas Bluetooth de bajo consumo de energía (conocido como BLE4.0) desde la versión 4.3 (API 18) [1]. Posteriormente surgió en dispositivos iOS desde el SDK 5 [2], en los que Apple desarrolló los iBeacons. Estos dispositivos pueden emitir pequeños paquetes de información, caracterizados por poder determinar zonas de cercanía a través de la intensidad de la señal (RSSI) que se captura [2]; y debido a que tienen un bajo consumo de energía pueden durar años funcionando sin necesidad de un cambio de batería; incluyendo que son pequeños, ligeros y muy fáciles de

instalar. Actualmente el mercado ofrece dispositivos que tienen por defecto BLE4.0.

El rango de señal que emite Bluetooth es bajo y susceptible a factores de ruido —elementos físicos en el espacio de desarrollo como: muebles, tránsito de personas, muros, ventanas y demás obstáculos. En este contexto, nos encontramos con un estudio experimental complicado ya que depende precisamente de los valores capturados de intensidad.

Los Beacons (y cualquier dispositivo BLE4.0 en general) trabajan en la banda de 2.4 Gigahercios (GHz) y puede emitir señal en intervalos desde 100 milisegundos (ms) hasta 10 segundos (s) aunque esto afecta directamente al tiempo de vida de la batería. Por otro lado, los Beacons tienen niveles configurables de intensidad de transmisión, que dependiendo del proveedor difieren en el cálculo, pudiendo ser por distancia de cobertura o intensidad de la señal. Tienen un alcance de hasta 100 metros en teoría pero en la práctica se alcanza aproximadamente hasta 80 metros.

BLE4.0 usa 40 canales para emitir información, de 2 Megahercios (MHz) cada una. El protocolo usa mensajes de corta duración para reducir el consumo de energía. Para evitar la interferencia entre dispositivos, ya que Wi-Fi y BLE4.0 usan la misma banda de 2.4 GHz, BLE4.0 hace uso de los canales etiquetados como 37 (2402 MHz), 38 (2426 MHz) y 39 (2480 MHz) como muestra la Figura 2.1. Esta información filtrada de canales no está disponible, excepto usando aplicaciones de iOS 7 o superior. [3]




FIGURA 2.1: Los 40 canales de BLE4.0 y los 3 canales más comunes de Wi-Fi. BLE4.0 solo utiliza los canales 37,38 y 39. Fuente: Faragher et al.[3]

BLE4.0 emite en estos canales de forma cíclica, y usa el resto una vez que se empareja con un dispositivo. Sin embargo, como muestra la Figura 2.2, el ruido de cada canal y de todo el conjunto final es muy notorio, lo que dificulta el estudio directo del RSSI de estos dispositivos. Este hecho provoca que se tome un tiempo considerable de lecturas de RSSI para obtener resultados confiables, debido a que estando en un lugar estático existen variaciones de hasta 20dBm en menos de 20 segundos.

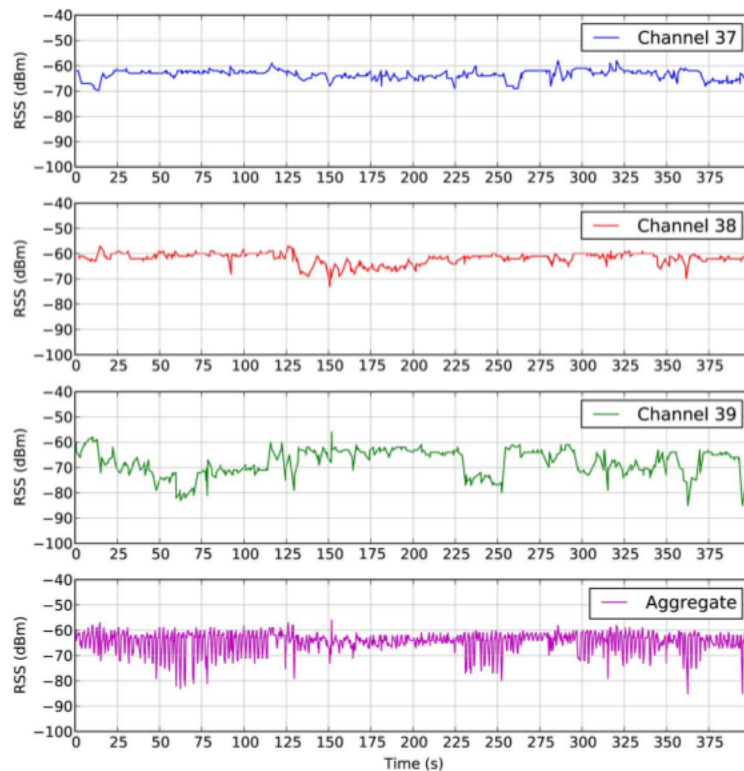


FIGURA 2.2: Variación de RSSI en posición estática. Fuente: Faragher et al.[3]

A continuación se describen los progresos realizados, consultados hasta la fecha de finalización de esta Tesis, sobre técnicas y enfoques de localización en interiores por medios inalámbricos.

2.2. Trabajos Relacionados

La localización en interiores es un tema de investigación interesante en la actualidad, de hecho, se conocen distintas tecnologías que son muy utilizadas, por ejemplo: Wi-Fi, Bluetooth, ZigBee; también las técnicas y algoritmos recomendables para este problema, como trilateración, medida de la distancia (ecuación de Rappaport) o algoritmos de clasificación.

Los Beacons han estimulado el interés de investigadores, siendo la principal ventaja de esta tecnología el costo de mantenimiento e instalación. El desarrollo de la localización en interiores se basa en el uso de los valores RSSI recogidos por dispositivos móviles, y luego evaluados con un enfoque de triangulación o fingerprinting. Sin embargo, últimamente otros criterios están siendo explorados, como estudiar el comportamiento del RSSI en distintos escenarios y determinar la mejor configuración del entorno [4] o *crowdsensing*, donde se actualiza constantemente una base de datos para un mejor perfilamiento de los Beacons [5].

A continuación se presentan los avances principales en este tema dividido en 2 secciones: técnicas de localización estándar y técnicas de localización usando solo tecnología BLE4.0.

2.2.1. Localización en interiores Estándar

Se introducen los principales trabajos llevados a cabo mediante el uso de Wi-Fi, Bluetooth y ZigBee.

Wi-Fi y Bluetooth

Existen estudios basados en la señal RSSI de dispositivos, tanto en emisores Wi-Fi como Bluetooth, por ejemplo, usando la intensidad de routers Wi-Fi, eliminando el ruido por filtros de Kalman y brindando un mejor modelo del RSSI permitiendo hacer la localización en tiempo real [6]. Por otro lado,

tenemos técnicas complejas de postprocesamiento como es la eliminación de outliers con RANSAC y así mejorar la localización con filtro de partículas como expone en [7].

Como parte de las técnicas que implementan un modelo de radiopropagación de la señal, hay estudios basados en Wi-Fi [8] y técnicas de trilateración consiguiendo una precisión con un error de alrededor de 2 metros. Con un enfoque parecido al anterior, pero basados en estudios de Bluetooth, existen avances utilizando trilateración y analizando el RSSI de Bluetooth [9], calculando el tiempo de llegada de la señal [10] con un error de similar magnitud que el anterior.

Además, existen otro tipo de enfoques que dependen del espacio a analizar, por ejemplo, usando diagramas de Voronoi [11], usando un método híbrido que combina fingerprinting con trilateración [12] o modelando una distribución de probabilidad que se ajuste mejor al problema [13].

ZigBee

Otras tecnologías no han surgido exitosamente en el mercado comercial, pero en el contexto académico han tenido una buena acogida, como es el caso de ZigBee.

ZigBee es una tecnología creada para configurar áreas personales de redes inalámbricas (WPAN), al mismo estilo que Bluetooth y Wi-Fi, pero de bajo costo y un mayor rendimiento de batería. Al igual que los casos anteriores se estudió esta tecnología basándose en su RSSI, obteniendo un error de 1.5-2 metros, con una densidad de la distribución de los sensores de 0.27 nodos por m^2 [14].

2.2.2. Localización con BLE 4.0

El uso de técnicas fingerprinting para localización en interiores es amplio. Esta técnica discretiza un área y reconoce por similitud de patrones, en este caso el valor capturado de RSSI, a qué sector discreto corresponde la señal o vector de señales. Es decir, se trata de reducir el problema a uno de clasificación. En estos estudios se hace uso de Beacons o algún otro dispositivo BLE4.0 pero por la alteración continua de las señales RSSI de estos es necesario un tiempo de espera de hasta 3 minutos, con el fin de poder conseguir valores confiables [15, 16].

En [3], los autores llevan a cabo un estudio experimental con 19 Beacons. Su estudio incluye un análisis de las intensidades de transmisión (TxPower) de los Beacons en relación a la precisión obtenida en un espacio usando localización en interiores. Los resultados demuestran que la configuración inicial, tomada como la intensidad máxima de los Beacons fue innecesariamente alta para el despliegue de su experiencia. A lo largo de sus pruebas todos los Beacons fueron configurados con la misma intensidad y entre sus resultados se observan algunos aportes entre la relación del número de Beacons y la intensidad de transmisión a utilizar.

En [17], Kriz et al, realizaron un experimento de localización utilizando un conjunto de Wi-Fi Access Points (AP) acompañados de dispositivos BLE4.0. El mecanismo de localización estuvo basado en Weighted-Nearest Neighbours en el algoritmo Signal Space. Los principales objetivos de este estudio fueron el de mejorar la localización en interiores mediante la introducción del uso de dispositivos BLE4.0 y el despliegue de un sistema que se actualiza constantemente según los niveles de RSSI reportados por los dispositivos móviles (receptores). Durante su experiencia variaron dos parámetros de los dispositivos BLE4.0, la duración del escaneo de la señal RSSI y la densidad. La intensidad utilizada en los Beacons fue la máxima en todo el experimento.

En [18], Paek et al, evalúan 3 distintos dispositivos en un espacio, analizando intensidades de transmisión, concluyendo finalmente que dependiendo del espacio a trabajar debe estudiarse su configuración, así como el modelo a utilizar para estimar la posición.

En [19], los autores resaltan como parámetro importante la distancia de separación recomendable que debería existir entre Beacons para un despliegue correcto en un espacio, así como también la intensidad de transmisión. La presente investigación analiza todos los parámetros que representan un gran impacto en el resultado de precisión de un método de localización, como son las intensidades de transmisión, la separación entre dispositivos Beacons y el comportamiento del RSSI según el receptor y además un análisis dinámico del mismo.

Capítulo 3

Mecanismos experimentales y algoritmos

Existen 2 técnicas que son las más usadas al trabajar con dispositivos inalámbricos: (i) crear un modelo de radiopropagación, es decir encontrar una relación directa del RSSI con la distancia, como sugiere la ecuación de Rappaport y mejorar el error mediante métodos de filtro de ruido; y (ii) analizar patrones de los valores de RSSI en espacios discretos reduciendo el problema a uno de clasificación. En este capítulo se detallan ambas técnicas, también se presenta el criterio de Feature Selection y las métricas utilizadas.

3.1. Dispositivos móviles

Se utilizaron dos tipos de dispositivos móviles: un Smartphone y una Raspberry Pi 2, como receptores de la señal RSSI.

El Smartphone es un teléfono Motorola E (XT1021) con Android 5.1 el cual fue usado para la primera parte de la Tesis y se implementó una aplicación que pudiera captar las señales RSSI de los Beacons del entorno, además de estadísticas básicas sobre estas medidas como la media y desviación estándar. La Raspberry Pi 2, a la cual se incorporó una antena Bluetooth USB, se utilizó para la segunda parte del trabajo y se implementó un script con el mismo objetivo que la aplicación del Smartphone.

3.2. Modelo de radiopropagación

Con la finalidad de obtener una relación intensidad-distancia se realizó el siguiente procedimiento:

- Se tomaron medidas RSSI de un Beacon durante un minuto con un dispositivo móvil y una aplicación Android desarrollada para este objetivo, considerando la posición del Beacon la posición 0 (0 metros) y desplazándose en línea recta, dejando 1 metro de separación entre estas.
- Se ordenaron los datos por posición y se realizó un filtrado de los valores (opcional). Finalmente, se tomó el valor medio del RSSI por cada punto de medida.
- Se filtraron los valores capturados usando la técnica descrita en [20], donde se ordenan los valores de RSSI capturados y se designa un porcentaje para eliminar en los extremos, manteniendo los valores intermedios; de esta manera se descartan los llamados *outliers*.
- Se determinó la ecuación que mejor se ajusta a los datos capturados usando la ecuación de Rappaport .

3.2.1. Ecuación de Rappaport

Para estimar el valor teórico de la propagación de la señal a través de la distancia se ha usado la ecuación de Rappaport [21], la cual modela señales de Wi-Fi y Bluetooth. Fue modificada ligeramente, con valores constantes que dependen de situaciones específicas, como se detalla a continuación.

$$RSSI = -(10n \log_{10} d + A) \quad (3.1)$$

En la Ecuación 3.1 el valor RSSI depende del valor A , el cual es el RSSI de la fuente a 1 metro de distancia; para calcular este valor se realiza previa calibración en cada dispositivo. El valor d es la distancia donde nos encontramos y el factor n es un coeficiente de ambiente que varía según la

ubicación y el dispositivo a utilizar. Este valor puede calcularse fácilmente al despejar los valores conocidos de la ecuación en el momento de la calibración.

La principal desventaja de este método es el cálculo del coeficiente de ambiente ya que dependerá del dispositivo y del entorno, por lo cual *es necesaria una calibración para cada dispositivo y sobre cada entorno en el que se trabaje.*

3.3. Fingerprinting

Los métodos fingerprinting usan las capturas hechas de varios dispositivos inalámbricos al mismo tiempo, desde distintas posiciones. En una fase *offline* estas capturas son guardadas con su respectiva posición en una base de datos. Luego, en una fase *online*, con un dispositivo se vuelven a capturar medidas comparándolas con la base de datos y determinando por similitud a cuál espacio pertenecen.

Dada las características del método, *si se decide cambiar la distribución de los Beacons será necesario una nueva toma de medida offline para el nuevo sistema.* Los pasos usados para aplicar esta técnica fueron los siguientes:

- Se discretizó el entorno a trabajar en espacios de $1m^2$ de área, cada espacio se le denominará sector.
- Se capturaron las medidas RSSI de todos los dispositivos en el entorno, desplazándose en todas las direcciones en cada sector.
- En un post-procesamiento, se tomaron las medidas capturadas por cada Beacon como un vector de medidas; es decir, se trabajó con un vector de igual dimensión a la cantidad de Beacons utilizados, cada vector se etiquetó con el sector que corresponde.
- Se tomaron medidas con un dispositivo móvil, usando el mismo formato del paso anterior.

- Se determinó el sector más probable al cual corresponde la nueva medida capturada, usando un algoritmo de aprendizaje que realice clasificación, para determinar su ubicación.

A continuación se describe como trabajan los algoritmos de clasificación utilizados junto a este método:

3.3.1. k-Nearest Neighbors (k-NN)

El algoritmo k-NN, es un método de clasificación muy simple, que compara el valor a clasificar con una base de datos; su resultado se determina por el más frecuente entre los k vecinos más cercanos. Por la simpleza de su funcionamiento es uno de los métodos más usados para clasificación.

La distancia entre dos elementos se determina, generalmente, por la distancia Euclideana —aunque otro criterio de distancia puede ser elegido según el enfoque del problema. Para el presente trabajo se escogió la distancia Euclideana, ya que se acomoda mejor para estos tipos de problema.

El resultado final de la clasificación se determina por múltiples criterios, en este caso se utilizan dos: (i) Distancia por Moda (MD), el método convencional, el cual usa el vecino más frecuente de los 'k' más cercanos; y (ii) Distancia Ponderada (WD), que realiza un peso ponderado entre los 'k' vecinos, para no eliminar información que pueda tener algún tipo de relevancia.

De usar un método $k=5$, es decir 5-NN, se tiene como resultado un vector de 5 elementos. Sea $A = \{y, y, x, x, x\}$ ordenados del más cercano al más lejano. Siendo las posiciones $x = (a, b)$ e $y = (c, d)$. Según los criterios se tienen los resultados:

- Por moda (convencional): La clase que más se repite en A es 'x', por lo tanto el resultado final sería la posición (a, b) .
- Por distancia ponderada : Se puede asignar una penalidad, por ejemplo para A se puede calcular la posición final como :

$$\frac{5y + 4y + 3x + 2x + x}{15} = \left(\frac{6a + 9c}{15}, \frac{6b + 9d}{15} \right) \quad (3.2)$$

Se utilizó la función *knnsearch*, propia de las librerías de Matlab. Para los cálculos utilizados en este trabajo, se utilizó la versión Matlab R2014a [22].

3.3.2. Support Vector Machine (SVM)

El método SVM aprende de una serie de entradas y las relaciona con salidas específicas, sirve tanto para clasificación como para regresión. De manera convencional, SVM es un clasificador binario no probabilístico.

Se utiliza un conjunto de entrada para construir el modelo, en esta etapa se ejecuta la fase de aprendizaje. Luego, el modelo puede reconocer nuevas entradas y asignarles una salida, según crea correcta.

SVM, como clasificador lineal, construye un hiperplano que separa de forma óptima las clases; para clasificadores no lineales, utiliza funciones kernel que maximizan el margen entre las clases, transformando el espacio en una mayor dimensión. En este trabajo se utilizaron kernel Polinomiales de grado 2 y 3.

Para este trabajo se utilizó $2/3$ de la data como entrenamiento y $1/3$ del resto como validación. Se usó como software Matlab, y la librería *libsvm*, que permite trabajar con mayor facilidad la clasificación entre múltiples clases [23].

3.4. Relevancia de los emisores

Para estudiar la correlación y relevancia de las variables en un problema de clasificación se utiliza una técnica conocida como Feature Selection (Selección de Atributos) con el fin de determinar el mejor subconjunto de variables a considerar.

Según Guyon et al. [24] se diferencian 3 estrategias principales para realizar Feature Selection: métodos de filtro, métodos de wrapper (envolventes) y métodos embedded (empotrados). Aún cuando estas técnicas están orientadas a mejorar el modelo de clasificación, también son usadas para identificar la importancia de las variables del problema [25].

Se usaron dos técnicas conocidas: ExtraTrees y Gradient Boosting Classifier. Esta elección se basa en que ambos algoritmos son robustos y precisos; además, a diferencia de algoritmos como Principal Component Analysis y SelectKBest [26], no necesitan configuración previa de parámetros.

3.4.1. ExtraTrees

Extremely Randomized Trees (ExtraTrees) es un método que construye múltiples modelos (random trees) para cada muestra de los datos de entrenamiento, al final todos estos resultados son promediados [27]. Se utilizó la librería de Python *Sklearn*, con hiperparámetros por defecto.

3.4.2. Gradient Boosting Classifier

Gradient Boosting Classifier también hace uso de árboles de decisión como modelos base y como criterio de selección usa el voto ponderado; además, crea un modelo previo cada vez que es ejecutado [28]. Se utilizó la librería de Python *Sklearn*, con hiperparámetros por defecto.

Estos algoritmos calculan un *score* (puntaje) que representa la importancia o relevancia de cada variable, en porcentaje, en el proceso de clasificación.

3.5. Métricas

Se presentan las métricas utilizadas para el análisis de los resultados obtenidos.

- **Precisión Global**: Es el porcentaje de datos que se clasificaron correctamente en una zona; si la zona tiene varios sectores, este valor es la media de la precisión de cada sector.
- **Precisión Local**: Similar que Precisión Global, Precisión Local representa el porcentaje de datos clasificados correctamente pero de un sector.
- **Error Medio (Global)**: Es el promedio de los errores de cada sector en una zona. Indica la distancia promedio del punto predicho en la clasificación y el punto correcto.
- **Error Local**: Similar que Error Medio, pero respecto a un sector.

Capítulo 4

Minería de datos para Bluetooth-Smartphone

Se presenta el análisis realizado al problema de localización en interiores identificando las variables principales que impactan en el resultado final como: el comportamiento del RSSI, la selección de la zona de despliegue, la técnica, el dispositivo receptor y la TxPower. Para la realización de las pruebas se utilizaron dispositivos Beacons Jaalee, cuyas especificaciones técnicas pueden encontrarse en el Apéndice A.

4.1. Sobre la atenuación del RSSI

Para estudiar la atenuación del RSSI se realizaron pruebas en 2 lugares distintos del i³A de la Universidad Castilla - La Mancha (UCLM), cuyas especificaciones pueden encontrarse en el Apéndice B.

Para este método se usaron Beacons Jaalee y como dispositivo móvil un Smartphone con Android 5.1 — con la antena Wi-Fi desactivada para evitar posibles interferencias.

4.1.1. Pasillo 1

Se colocó 1 Beacon en un punto inicial y se tomó medidas cada 1 metro de distancia, capturando medidas RSSI en cada punto durante un minuto.




FIGURA 4.1: Valores RSSI experimentales y teóricos. TxPower = 0x06 en pasillo 1. Fuente: Elaboración propia.




FIGURA 4.2: Valores RSSI experimentales y teóricos. TxPower = 0x07 en pasillo 1. Fuente: Elaboración propia.




FIGURA 4.3: Valores RSSI experimentales y teóricos. TxPower = 0x08 en pasillo 1. Fuente: Elaboración propia.

Discusión

Las figuras 4.1, 4.2 y 4.3 muestran las gráficas obtenidas de los valores RSSI capturados, tanto de forma sin procesar y después de un filtro de ruido. También se grafica la curva teórica según la ecuación de Rappaport en cada caso.

La precisión se compara según cada intensidad por medio de la desviación estándar, calculada en el Cuadro 4.1 para cada caso. Se señala que el rango de valores RSSI que toman los dispositivos varían según la intensidad utilizada; en algunos casos, como muestran las gráficas, el valor filtrado coincide con el valor sin procesar.

CUADRO 4.1: Error Cuadrático Medio y Desviación Estándar para cada TxPower en pasillo 1. Fuente: Elaboración propia.

TxPower	Error Cuadrático Medio	% Desv. Estándar
0x06	8.26	13.06
0x07	13.64	16.06
0x08	3.67	9.13

CUADRO 4.2: Error Cuadrático Medio y Desviación Estándar para cada TxPower en pasillo 2. Fuente: Elaboración propia.

TxPower	Error Cuadrático Medio	% Desv. Estándar
0x06	12.02	13.33
0x07	6.41	16.87
0x08	6.62	25.72

4.1.2. Pasillo 2

Se realizó el mismo procedimiento que en el paso anterior. Las figuras 4.4, 4.5 y 4.6 muestran las gráficas obtenidas de los valores RSSI capturados, de




FIGURA 4.4: Valores RSSI experimentales y teóricos. TxPower = 0x06 en pasillo 2. Fuente: Elaboración propia.




FIGURA 4.5: Valores RSSI experimentales y teóricos. TxPower = 0x07 en pasillo 2. Fuente: Elaboración propia.




FIGURA 4.6: Valores RSSI experimentales y teóricos. TxPower = 0x08 en pasillo 2. Fuente: Elaboración propia.

forma sin procesar y después de un filtro de ruido, incluyendo la curva teórica de Rappaport en cada caso. En el Cuadro 4.2 se observa el Error Cuadrático Medio (ECM) y Desviación Estándar.

Discusión

De estos resultados, se identifica que el rango y amplitud de valores son irregulares y no hay sentido en buscar una relación directa de RSSI - distancia. Las gráficas muestran un mismo valor RSSI para distintas distancias del Beacon, por lo que trabajar con un método de trilateración no es una solución viable ya que no brindaría una precisión confiable.

Sin embargo, en ambos pasillos se pueden determinar comportamientos similares, por ejemplo, en distancias de 1 a 8 metros los puntos experimentales se ajustan mejor, valores más allá de estas distancias ya no reflejan un comportamiento en especial; en excepción de TxPower = 0x08 en el que el decaimiento de la señal no es notorio. A pesar de esto, las intensidades más bajas presentan un mejor ajuste en los valores teóricos.

El Cuadro 4.3 muestra los resultados al analizar el Pasillo 1, considerando los primeros 8 metros. Al comparar estos resultado con el Cuadro 4.1 se observa una mejora respecto al error medio y rango de desviaciones estándar, a excepción de la TxPower= 0x08. De esta comparación se concluye que limitar el tamaño del área experimental puede jugar un rol importante al aplicar otra técnica.

CUADRO 4.3: Error Cuadrático Medio y Desviación Estándar para cada TxPower en pasillo 1, hasta 8m. Fuente: Elaboración propia.

TxPower	Error Cuadrático Medio	% Desv. Estándar
0x06	2.25	6.81
0x07	9.45	13.37
0x08	3.66	9.11

4.2. Resultados experimentales

Del análisis previo, la distancia entre emisor y receptor juega un rol importante en la estimación del RSSI, se consideraron distintos tipos de configuraciones al momento de iniciar el despliegue de las áreas experimentales. Para realizar este análisis se aplicó la técnica de fingerprinting.

Se utilizó el laboratorio Sistemas Concurrentes y Tiempo Real (ReTiCS) para estas pruebas, donde se analizaron dos variables: la discretización del espacio y la distribución de los Beacons. Los resultados finales determinaron la relevancia que tienen estas variables y el TxPower base sobre el cual trabajar.

La primera configuración se trabajó sobre un área de $12m^2$, discretizando un rectángulo de 4x3 metros en sectores de $1m^2$, se probaron con distribuciones de 4 y 5 Beacons colocados alrededor de este rectángulo.

La siguiente configuración fue en el mismo laboratorio sobre un área de 9.6 x 6.3 metros, discretizando sectores de $1m^2$, esta vez separados por distancias de 0.5 metros y formando un rectángulo de 5x3 espacios discretos en toda el área descrita. Los detalles de estas áreas se especifican en el Apéndice B.

4.2.1. Área experimental 1

Sobre un área de $12m^2$, discretizados en sectores contiguos de $1m^2$, distribuidos en una matriz de 4x3. Se consideraron los siguientes criterios al momento de realizar la experiencia:

- En cada sector se tomaron medidas en el sitio, estático y caminando en todas las direcciones.
- Se tomaron muestras durante 5 a 6 minutos en cada sector.
- Para determinar un vector de medidas la aplicación móvil espera a captar valores RSSI de todos los Beacons al menos una vez, si se han calculado




FIGURA 4.7: Distribución de Beacons para el área experimental 1.
Fuente : Elaboración propia.

más de uno se toma la media, dejando un vector de 4 o 5 dimensiones como cada elemento.

- No se realiza filtro de ruido para este tipo de medidas.

El espacio analizado se muestra en la Figura 4.7, donde se trabaja con 5 Beacons inicialmente, etiquetados como: Be07, Be08, Be09, Be10 y Be11. Todos los Beacons trabajan con $TxPower = 0x07$, ya que el espacio a analizar es pequeño y se busca notar una reducción obvia del RSSI para identificar sectores; como se explicó anteriormente, para distancias menores a 8 metros se obtienen menos errores en la estimación de la posición.

Para determinar puntos ciegos en la configuración, o una cantidad menor de Beacons sin comprometer el desempeño, se hicieron 5 pruebas extras en esta área, cada uno retirando un Beacon de la distribución.

Las siguientes pruebas se trabajaron utilizando una data de 231 elementos de entrenamiento y 99 elementos de validación elegidos aleatoriamente. Los resultados mostrados corresponden al valor medio del algoritmo ejecutado 50 veces.

Caso 1: k-NN

Se utilizó el algoritmo k-NN variando el hiperparámetro k con valores $k = 1, 3, 5$ para identificar el que brinda mejores resultados. Se realizaron dos enfoques: usando la moda (MD) y la distancia ponderada (WD); considerando la posición de cada sector (x,y) el punto medio de cada metro cuadrado.

Los Cuadros 4.4 y 4.5 muestran el nivel de error para cada configuración usando los dos enfoques, resaltando en negrita el mejor resultado y configuración. Además, las figuras 4.8a y 4.8b indican el error en los sectores, con mapas de calor, de los mejores resultados.

CUADRO 4.4: Error medio usando k-NN y criterio MD para el área experimental 1. Fuente: Elaboración propia.

Configuración	k=1	k=3	k=5
<i>Be07, Be08, Be09, Be10, Be11</i>	1.52 m	1.74 m	1.69 m
<i>Be08, Be09, Be10, Be11</i>	1.64 m	1.73 m	1.75 m
<i>Be07, Be09, Be10, Be11</i>	1.56 m	1.71 m	1.68 m
<i>Be07, Be08, Be10, Be11</i>	1.52 m	1.66 m	1.61 m
<i>Be07, Be08, Be09, Be11</i>	1.54 m	1.64 m	1.63 m
<i>Be07, Be08, Be09, Be10</i>	1.51 m	1.72 m	1.68 m




FIGURA 4.8: Error de posicionamiento(m) usando k-NN, según WD y MD. Mapas de calor para TxPower = 0x07. Fuente: Elaboración propia.

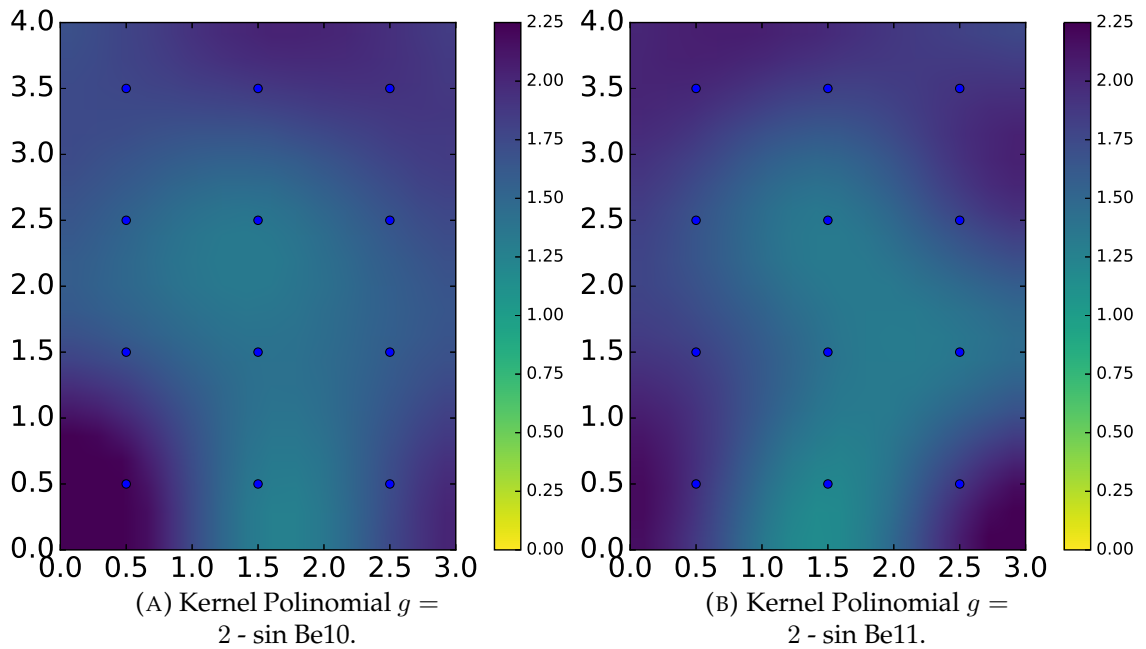


FIGURA 4.9: Error de posicionamiento(m) usando SVM. Mapas de calor para TxPower = 0x07. Fuente: Elaboración propia.

CUADRO 4.5: Error medio usando k-NN y WD para el área experimental 1. Fuente: Elaboración propia.

Configuración	k=1	k=3	k=5
<i>Be07, Be08, Be09, Be10, Be11</i>	1.52 m	1.34 m	1.29 m
<i>Be08, Be09, Be10, Be11</i>	1.64 m	1.40 m	1.35 m
<i>Be07, Be09, Be10, Be11</i>	1.56 m	1.36 m	1.31 m
<i>Be07, Be08, Be10, Be11</i>	1.52 m	1.33 m	1.27 m
<i>Be07, Be08, Be09, Be11</i>	1.54 m	1.32 m	1.28 m
<i>Be07, Be08, Be09, Be10</i>	1.51 m	1.33 m	1.28 m

Discusión

De los cuadros se observa que para $k = 1$ se obtienen los mismos resultados en ambos criterios, para valores $k = 3$ y $k = 5$ el criterio WD tiene los mejores resultados para todas las configuraciones de los Beacons. Con $k = 5$ y el criterio WD se mejora en 0.4 metros. Por otro lado, la configuración que da el menor error es la que omite el Beacon *Be09*, $1.27m$. Se infiere que con una distribución de 1 Beacon por esquina en un área de 4×3 metros se tiene una precisión aceptable; también, según los mapas de calor, las zonas cercanas a los Beacons dan los peores resultados.

Debe tomarse en cuenta que se trabajó en un área pequeña, por lo que aunque el error sea de magnitud pequeña, corresponde aproximadamente el 50 % del área total.

Caso 2: SVM

Se analizaron 3 casos en particular: para un kernel lineal, polinomial de grado 2 y polinomial de grado 3.

El Cuadro 4.6 muestra los errores medios para todas las configuraciones de Beacons según el kernel utilizado, en negrita se indican los mejores resultados.

Las Figuras 4.9a y 4.9b muestran mapas de calor que indican el error en cada sector, de los mejores resultados.

CUADRO 4.6: Error medio usando SVM para distintos grados de kernel en área experimental 1. Fuente: Elaboración propia.

Configuración	Lineal	Polinomial G=2	Polinomial G=3
<i>Be07, Be08, Be09, Be10, Be11</i>	1.65 m	1.64 m	1.65 m
<i>Be08, Be09, Be10, Be11</i>	1.64 m	1.60 m	1.65 m
<i>Be07, Be09, Be10, Be11</i>	1.63 m	1.64 m	1.62 m
<i>Be07, Be08, Be10, Be11</i>	1.65 m	1.62 m	1.62 m
<i>Be07, Be08, Be09, Be11</i>	1.63 m	1.60 m	1.61 m
<i>Be07, Be08, Be09, Be10</i>	1.64 m	1.66 m	1.64 m

Discusión

Del cuadro se observa que el error medio usando SVM es ligeramente mayor que usando k-NN con criterio WD. Los mapas de calor muestran para el caso de k-NN, ver Figura 4.8, que el error de posicionamiento es distribuido aleatoriamente y la zona central tiene el error más bajo del mapa. Para SVM la distribución del error es uniforme, pero de mayor magnitud.

CUADRO 4.7: Tiempos de ejecución para cada técnica, en milisegundos (ms). Fuente: Elaboración propia.

Algoritmo	Tiempo de Ejecución (ms)
k-NN	0.22
SVM - Lineal	27
SVM - Polinomial	33

El Cuadro 4.7 muestra el tiempo de ejecución promedio para cada algoritmo, donde k-NN tiene un tiempo de ejecución más bajo que SVM, teniendo así un mejor perfil para aplicaciones de tiempo real. Por otro lado, la

Figura 4.10 muestra que con 4 Beacons, el algoritmo k-NN, con $k = 5$, consigue una precisión media de aproximadamente $1.5m$.

Con estos resultados se estudia un área de mayor tamaño en la cual se agregan zonas de frontera entre los sectores.

4.2.2. Área experimental 2

Se analizó un espacio de mayor área, 9.6×6.3 metros, dejando 0.5 metros de distancia entre cada sector, de $1m^2$, y con un margen entre los Beacons y los puntos para tomar medidas de aproximadamente entre 0.7 y 1.7 metros. En la Figura 4.11 se observa un diagrama del espacio y la distribución de Beacons utilizada.

Este espacio se encuentra ubicado, igualmente, en el laboratorio ReTiCS. Hay que considerar la presencia intensa de routers y otros dispositivos Bluetooth —tanto Beacons como microcontroladores— presentes en todo el entorno, lo que genera mayor ruido en las medidas obtenidas para la experiencia.

Se utiliza k-NN ya que dio mejores resultados que SVM en el área experimental 1; en este caso se busca estudiar el comportamiento de la TxPower base de los Beacons. También se hace uso del análisis inicial de la ecuación de Rappaport, a mayor TxPower existe un mejor ajuste de la señal para distancias de hasta 8 metros, para reducir el error medio.

Análisis de TxPower en localización

Se utilizan 2 tipos de intensidades de Jaalee: $TxPower = 0x04$ y $TxPower = 0x07$, ver Apéndice A. Sobre la recolección de datos se pueden mencionar los siguientes criterios:




FIGURA 4.10: Error acumulado para 5-NN usando WD, excluyendo el Beacon Be09. Fuente: Elaboración propia.




FIGURA 4.11: Distribución de Beacons para el área experimental 2. Fuente: Elaboración propia.

- Se tomaron medidas de 2 o 3 minutos en cada sector, desplazándose en varias direcciones de forma pausada para no alterar la estabilidad de la señal.
- No se realizó ningún tipo de filtro de ruido para las capturas.
- En este caso se consideraron valores N.A. Como el espacio es mayor los Beacons no llegan a cubrir la zona al 100 %. Este aspecto se utilizará en el análisis como discriminante para determinar con mayor facilidad a qué sector pertenece cada medida.
- Por cada segundo que transcurre se recogen los valores capturados y se calcula la media, si algún Beacon no llegó a capturar ningún valor se le asigna el más bajo (-120) como valor constante al vector de datos.

El Cuadro 4.8 muestra el tamaño de las muestras de entrenamiento y validación utilizadas en cada TxPower, aproximadamente 60 vectores de datos por sector en la zona. En el Cuadro 4.9 se muestran los resultados obtenidos para todas las configuraciones, donde los mejores resultados son mostrados en negrita.

Discusión

Para cada TxPower en el Cuadro 4.9 se tienen los mejores resultados con configuraciones de 5 beacons. Se observa que con la mayor TxPower (0x04) y bajo un criterio WD se llega a reducir el error medio aproximadamente en 17cm.

CUADRO 4.8: Datos de entrenamiento y validación. Fuente: Elaboración propia.

TxPower	RSSI a 1m (dBm)	# datos Entrenamiento	# datos Validación
0x07	-75	757	290
0x04	-57	608	261

CUADRO 4.9: k -NN - error medio (m), usando MD y WD, para distintas configuraciones de Beacons con TxPower = 0x04 y TxPower = 0x07. Fuente: Elaboración propia.

TxPower	Configuración	MD (m)			WD (m)		
		k=1	k=3	k=5	k=1	k=3	k=5
0x04	Be07,Be08,Be09,Be10,Be11	2.25	2.17	2.12	2.25	1.91	1.82
0x04	Be08,Be09,Be10,Be11	2.35	2.32	2.33	2.35	2.04	1.99
0x04	Be07,Be09,Be10,Be11	2.25	2.19	2.17	2.25	1.87	1.84
0x04	Be07,Be08,Be10,Be11	2.30	2.26	2.16	2.30	1.92	1.84
0x04	Be07,Be08,Be09,Be11	2.32	2.34	2.30	2.32	2.00	1.93
0x04	Be07,Be08,Be09,Be10	2.29	2.38	2.23	2.29	2.01	1.91
0x07	Be07,Be08,Be09,Be10,Be11	2.30	2.32	2.29	2.26	2.02	1.96
0x07	Be08,Be09,Be10,Be11	2.35	2.36	2.29	2.35	2.03	1.95
0x07	Be07,Be09,Be10,Be11	2.41	2.44	2.44	2.41	2.12	2.07
0x07	Be07,Be08,Be10,Be11	2.31	2.39	2.37	2.31	2.00	1.90
0x07	Be07,Be08,Be09,Be11	2.39	2.43	2.44	2.39	2.16	2.01
0x07	Be07,Be08,Be09,Be10	2.41	2.52	2.44	2.41	2.12	2.04

Discusión

Las Figuras 4.12 y 4.13 muestran los errores para los sectores, por mapas de calor. En este caso se observa un comportamiento similar al área anterior, donde los errores medios balanceados mejoran el error global. Más aún, los sectores cerca de las esquinas tienen un mayor error que las zonas centrales, el RSSI decrece y es mejor diferenciado, mejorando la clasificación.

Con estos resultados se ha identificado que la discretización del área experimental y distribución de los Beacons impacta directamente en los resultados finales, siendo la mejor configuración hasta el momento el uso de 5 Beacons con TxPower = 0x04 y k -NN ($k = 5$) con un criterio WD.




FIGURA 4.12: Error de posicionamiento(m) usando k-NN. Mapas de calor para TxPower = 0x04. Fuente: Elaboración propia.




FIGURA 4.13: Error de posicionamiento(m) usando k-NN. Mapas de calor para TxPower = 0x07. Fuente: Elaboración propia.

Comparación entre áreas experimentales

Las áreas experimentales 1 y 2 tienen una extensión de $12m^2$ y $60.48m^2$, respectivamente. Para poder comparar directamente los resultados obtenidos entre estos se ha definido un coeficiente de error medio en la Ecuación 4.1.

$$Coeficiente = \left(\frac{Error * Error}{AreaTotal} \right) * 100 \quad (4.1)$$

El Cuadro 4.10 muestra los coeficientes para los mejores resultados según las áreas estudiadas, mostrando en negrita los mejores resultados. El mejor se obtiene con el área experimental 2, usando 5-NN con el criterio WD y una TxPower = 0x04 con la presencia de todos los Beacons.

CUADRO 4.10: Coeficiente de error con las mejores configuraciones para k -NN, usando MD y WD. Fuente: Elaboración propia.

Algoritmo	Área 1	Área 2
k -NN(MD)	[07,08,10,11-k=1]-18.75	[07,08,09,10,11-k=5]-7.49
k -NN(WD)	[07,08,09,10-k=5]-13.34	[07,08,09,10,11-k=5]-5.52

Del mismo Cuadro 4.10 se observa que en ambos casos el área experimental 2 tiene una mejora respecto al área experimental 1, esto define los siguientes criterios al momento de definir un área.

- Un área extensa con fronteras entre los sectores genera una caída del RSSI entre estos, brindando una mejor diferenciación de los valores, aumentando la precisión de clasificación.
- Los Beacons posicionados en las esquinas mejoran notablemente el balance de errores medios dentro del área.

- El Beacon Be09 en medio de un lado del área, ayuda a diferenciar los valores RSSI entre sectores, mejorando la clasificación.
- Al utilizar k -NN, se mejora la precisión usando un criterio WD.

4.3. Conclusiones sobre el RSSI y TxPower

Para resumir los elementos analizados hasta el momento, se puede indicar lo siguiente:

- Por el estudio del comportamiento del RSSI se descarta el uso de métodos que impliquen la relación RSSI-distancia, debido a la alta susceptibilidad de este.
- Se determinó la mejor discretización y despliegue de un área experimental, concluyendo que para trabajar con un método fingerprinting lo recomendable es aplicar regiones de frontera, ya que ayudan a definir una caída del RSSI entre sectores.
- El mejor algoritmo es k -NN, con $k = 5$ y una configuración de los 5 Beacons presentes en el área experimental.

En el siguiente capítulo se realiza un estudio a profundidad del rol que juega la Intensidad de Transmisión TxPower, como última variable considerada para optimizar la localización en interiores de la presente investigación.

Capítulo 5

Minería de datos para Bluetooth-Antena

Para finalizar se realiza un análisis de la intensidad de transmisión (TxPower), de la importancia que tiene en el proceso, y como solución al fenómeno Multipath Fading de los Beacons. Luego se presenta un método Ad-hoc, es decir a fuerza bruta, para encontrar la mejor configuración que brinde resultados óptimos al problema.

5.1. Atenuación de la señal y análisis del receptor

Hasta el momento las pruebas realizadas fueron hechas a través de una aplicación en un Smartphone Android 5.1. Los resultados obtenidos, con un gran margen de error, son poco prometedores respecto a los alcances realizados hasta la fecha según la literatura, por lo que se explorará una comparativa con los resultados obtenidos a través de otro dispositivo, un Raspberry Pi 2, equipado con una antena USB BLE4.0, al cual se llamará Antena BLE4.0 de ahora en adelante en el texto.

5.1.1. Análisis de precisión del receptor

Se realiza la comparación directa entre receptores con los resultados obtenidos utilizando: k -NN con $k = 5$ y SVM con kernel de grado polinomial 2

y 3.

El Cuadro 5.1 muestra que el usar la Antena BLE4.0 brinda mejores resultados que el Smartphone. De hecho, estos resultados muestran que la precisión de la Antena BLE4.0 es aproximadamente 3 veces mejor; por lo tanto, basado en esto, se utiliza la Antena BLE4.0 como dispositivo para las siguientes pruebas de localización.

CUADRO 5.1: Precisión global, para k-NN usando MD ($k = 5$) y SVM (polinomial $g = 2$) con TxPower = 0x04. Fuente: Elaboración propia.

Algoritmo	Smartphone	Antena BLE 4.0
k-NN	21 %	64.6 %
SVM	22.4 %	60.6 %

5.1.2. Análisis del comportamiento del RSSI

Se realizó un estudio del RSSI para comparar objetivamente la ventaja de la Antena BLE4.0 con el Smartphone, para ello se utilizó el área experimental 2 (ver Figura 4.11) y se analizaron valores como desviación estándar y valores medios para cada sector (15 en total) de la zona. El procedimiento de captura de datos fue de la siguiente manera:

- Se fijó un mismo TxPower para todos los Beacons.
- Se capturaron medidas del RSSI en el centro de cada sector, de cada uno de los 5 Beacons, por un tiempo de un minuto.
- Se calculó la media y desviación estándar del RSSI para cada uno de los 5 Beacons.

La toma de medidas se realizó en distintas horas del día, para verificar si existía algún factor externo en la recepción de valores RSSI. En esta toma de medidas se encontraban personas recorriendo parte del área experimental,

para causar interferencia en la señal y obtener valores cercanos a una aplicación real.


El promedio de datos capturados fueron: 15 muestras/segundo para el Smartphone y 86.6 muestras/segundo para la Antena BLE4.0. La Figura 5.1 muestra el valor medio y desviación estándar de los valores RSSI para los Beacons Be07 y Be09 con TxPower = 0x04; se consideró el uso de esta TxPower intermedia como la mejor opción para la evaluación. Además, esta figura, muestra que la Antena BLE4.0 ofrece mejores resultados que el Smartphone, por los altos valores de RSSI y menor desviación estándar.

La Figura 5.1 muestra el comportamiento de los valores de RSSI, los cuales no determinan por si solos una única posición. Con estos resultados, se analiza la variabilidad del RSSI en distintos momentos, etiquetados como Take1 y Take2 y capturados por la Antena BLE4.0, para cada Beacon.


Caso 1: Sector 8

Las Figuras 5.2a y 5.2b muestran los valores RSSI para los Beacons Be07 y Be10 en el sector 8, el centro del área, y las líneas punteadas indican el valor medio. Por la misma distancia que tienen al punto, se espera que ambos Beacons tengan valores RSSI iguales, sin embargo, los valores de Be10 son mayores a los de Be07.

Este hecho puede ser causado por un fenómeno conocido como Multipath Fading, un problema que se detallará después. Sin embargo, este resultado es alentador, pues para distintas tomas se tienen valores medios de RSSI parecidos, lo que indica que la fuente tiene altas posibilidades de replicabilidad, siendo esta una base crítica para la continuación de este estudio.



(A) Para Be07



(B) Para Be09

FIGURA 5.1: RSSI (dBm) para Antena BLE4.0 y Smartphone con TxPower = 0x04 para cada sector(1,15) del área experimental 2.
Fuente: Elaboración propia.

Caso 2: Sector 4

En este sector el Beacon Be07 es más cercano que el Be10, por lo que los valores de RSSI deben ser mayores en el Be07, sin embargo, las Figuras 5.2c y 5.2d muestran que Be07 tiene valores menores que Be10.

Ante este hecho es necesario analizar el espacio físico que rodea a estos Beacons, para determinar el rol que juega el ambiente en la propagación de la señal. En este caso también los valores medios de tomas distintas se mantienen similares.

Caso 3: Sector 15


En este sector Be10 es más cercano que Be07, por lo que similar al sector anterior, se esperan valores más altos de RSSI en Be10. Las Figuras 5.2e y 5.2f muestran todo lo contrario, una vez más, esto puede ser causado por el fenómeno Multipath Fading.

Para este sector en particular los valores medios RSSI de Take1 y Take2 varían. Cabe resaltar que en este sector había un flujo de personas al realizar las tomas, causando ruido e inestabilidad en las señales capturadas.


Discusión

Los Beacons Be07 y Be10 son elegidos ya que están posicionados en esquinas opuestas del área experimental, como se observa en la Figura 4.11, además de tener distintos entornos físicos tales como Be07 que lo rodea entradas de oficinas y Be10 lo rodea una zona de ventanas. Se eligen los sectores 4, 8 y 15 por la simetría respecto a los Beacons escogidos.


Este análisis realizado a la señal de Bluetooth desde distintos receptores, demuestra que ésta es susceptible por medio del fenómeno Multipath Fading. Además, es viable enfocarse en una técnica fingerprinting de los Beacons,




(A) Sector 8 - Para Be07




(B) Sector 8 - Para Be10




(C) Sector 4 - Para Be07



(D) Sector 4 - Para Be10



(E) Sector 15 - Para Be07



(F) Sector 15 - Para Be10

FIGURA 5.2: Comparación de RSSI para distintos Beacons con TxPower = 0x04. Fuente: Elaboración propia.

variando la TxPower, con el fin de mitigar este fenómeno.

El dispositivo receptor juega un rol crítico en el problema. Entre las opciones presentadas de Smartphone y Antena BLE4.0 en una Raspberry Pi 2, se determinó que la Antena BLE4.0 da los mejores resultados.

Además, del análisis de la señal Bluetooth entre los sectores del área experimental, los rangos de valores (dBm) percibidos a una misma distancia no son similares entre los Beacons. Esto probablemente debido al fenómeno Multipath Fading u obstáculos como el tránsito de personas.

5.2. Relevancia de los Beacons

De la sección anterior, se determinó que los valores RSSI percibidos de distintas fuentes no son necesariamente iguales para Beacons en una misma TxPower, es decir, estos valores cambian significativamente según el Beacon. Esta observación nos plantea las causas de esta peculiaridad, que se lista a continuación:

- Es causado por el fenómeno Multipath Fading del Bluetooth.
- La presencia de personas y/o objetos introducen ruido que varía la señal óptima de los dispositivos.
- La batería de tanto receptores como emisores pueden alterar el comportamiento ideal de los dispositivos.

Se analiza preliminarmente la relevancia de cada Beacon con respecto al modelo de clasificación. Este análisis ha sido desarrollado con distintas TxPower.

Se usaron dos algoritmos: Extra Trees y Gradient Boosting Algorithm. Ambos calculan un *score* asociado a cada *feature*, que representa la relevancia,

en porcentaje, para el proceso de clasificación [29]. La situación ideal es que todos los Beacons tengan la misma relevancia en el modelo encontrando una distribución casi uniforme entre los *scores*.


El Cuadro 5.2 muestra el número de muestras (datos) por Beacon en distintas intensidades de transmisión. Si bien los Beacons operan en 8 distintas TxPower, se han descartado las 2 más bajas, TxPower = 0x07 y TxPower = 0x08, pues no cubren toda la extensión del área experimental 2.

CUADRO 5.2: Número de muestras de RSSI capturados en distintos TxPower. Fuente: Elaboración propia.


TxPower	Número de muestras por Beacon
0x01	5003
0x02	5246
0x03	4844
0x04	5134
0x05	4697
0x06	4198

Las Figuras 5.3 y 5.4 muestran los *scores* obtenidos para los 5 Beacons en las 6 TxPower, usando el algoritmo de ExtraTrees y Gradient Boosting Algorithm respectivamente. La Figura 5.3a muestra que Be11 es más relevante en el modelo de clasificación que el resto de Beacons. Por otro lado, para TxPower= 0x02, Be10 es el más relevante. Sin embargo, en las Figuras 5.3d y 5.4d con $Tx = 0x04$ se muestra una distribución más uniforme, donde todos los Beacons tienen igual participación.


De estos resultados, ningún valor se desvía más del 5% y ninguno de ellos excede el 30% del total de relevancia. Estas figuras permiten confirmar que la configuración del experimento es balanceada y por lo tanto es posible explorar con libertad la TxPower para mejorar el método de localización.




(A) $TxPower = 0x01$




(B) $TxPower = 0x02$




(C) $TxPower = 0x03$



(D) $TxPower = 0x04$




(E) $TxPower = 0x05$




(F) $TxPower = 0x06$


FIGURA 5.3: Score de relevancia para cada Beacon usando el algoritmo ExtraTrees para distintas $TxPower$. Fuente: Elaboración propia.




(A) $TxPower = 0x01$




(B) $TxPower = 0x02$




(C) $TxPower = 0x03$



(D) $TxPower = 0x04$



(E) $TxPower = 0x05$



(F) $TxPower = 0x06$

FIGURA 5.4: Score de relevancia para cada Beacon usando el algoritmo Gradient Boosting Classifier para distintas $TxPower$.
Fuente: Elaboración propia.

5.3. Análisis de intensidad de transmisión simétrica

Se obtuvieron resultados con cada TxPower aplicando los algoritmos estudiados previamente, k-NN con $k = 5$ y SVM con kernel de grado polinomial=2. El Cuadro 5.3 muestra que la mayor precisión con estos algoritmos son 65 % y 61.7 % respectivamente, con los mejores resultados en negrita.

CUADRO 5.3: Precisión global usando la Antena BLE4.0 para k-NN ($k = 5$) usando MD y SVM (kernel polinomial $g = 2$) para distintos TxPower. Fuente: Elaboración propia.

TxPower	Algoritmo	
	k-NN	SVM
0x01	62.3 %	57.7 %
0x02	61.5 %	52.6 %
0x03	65.0 %	58.0 %
0x04	64.6 %	60.6 %
0x05	56.6 %	50.4 %
0x06	63.8 %	61.7 %

La Figura 5.5 muestra los valores RSSI para los Beacons Be07, Be09 y Be11 con la mejor y peor TxPower usando el algoritmo k-NN, TxPower= 0x03 y TxPower= 0x05. De estas imágenes se identifica que los mejores resultados se dan cuando los sectores son bien diferenciados; incluso en las Figuras 5.5a, 5.5b y 5.5c se localiza la posición del Beacon por lo altos valores de RSSI que se presentan alrededor, lo que no ocurre en las Figuras 5.5d , 5.5e y 5.5f, donde gran parte del mapa de calor es uniforme.

Esta fenómeno de la atenuación de la señal es conocido como *Multipath Fading* y es uno de los principales obstáculos al desarrollar un mecanismo robusto y preciso de localización basado en BLE4.0 [13]. En la presencia de este




FIGURA 5.5: Valores RSSI para los mejores (**arriba**) y peores (**abajo**) TxPower, para los Beacons 'Be07', 'Be09' y 'Be10' en el área experimental 2, capturados por la Antena BLE4.0. Fuente: Elaboración propia.

fenómeno, la información derivada de los valores de RSSI puede llevar a malas interpretaciones y por lo tanto malos resultados en el proceso de clasificación.

Las propuestas teóricas estudiadas para mitigar este fenómeno se basan en el control de la TxPower como un enfoque efectivo[30]. Sin embargo, este proceso no es tan directo, por ejemplo, para el Beacon Be10 con TxPower= 0x05 (ver Figura 5.5f) brinda una buena diferenciación del sector, pero según el Cuadro 5.3 es la que da el peor resultado. Esto muestra que la configuración de cada Beacon juega un rol importante en el resultado final de clasificación.

5.4. Análisis de intensidad de transmisión asimétrica

De lo anterior se observa que la TxPower afecta al desempeño de un algoritmo de clasificación, principalmente debido al fenómeno MultiPath Fading. A partir de esta observación se analiza una configuración de Beacons con TxPower asimétrica, esto es, que cada Beacon tenga la mejor TxPower tanto para el Beacon individual y para todo el conjunto de dispositivos.

Esta idea se basa en que la Figura 5.6 muestra los valores RSSI para 3 Beacons Be11, Be07 y Be08, donde Be07 y Be11 tienen las mejores características con TxPower= 0x04, mientras que para Be08 se configura mejor con TxPower= 0x01. Por lo tanto, se explorará el resto de opciones bajo este enfoque y así determinar si existe alguna mejora a la solución del problema.

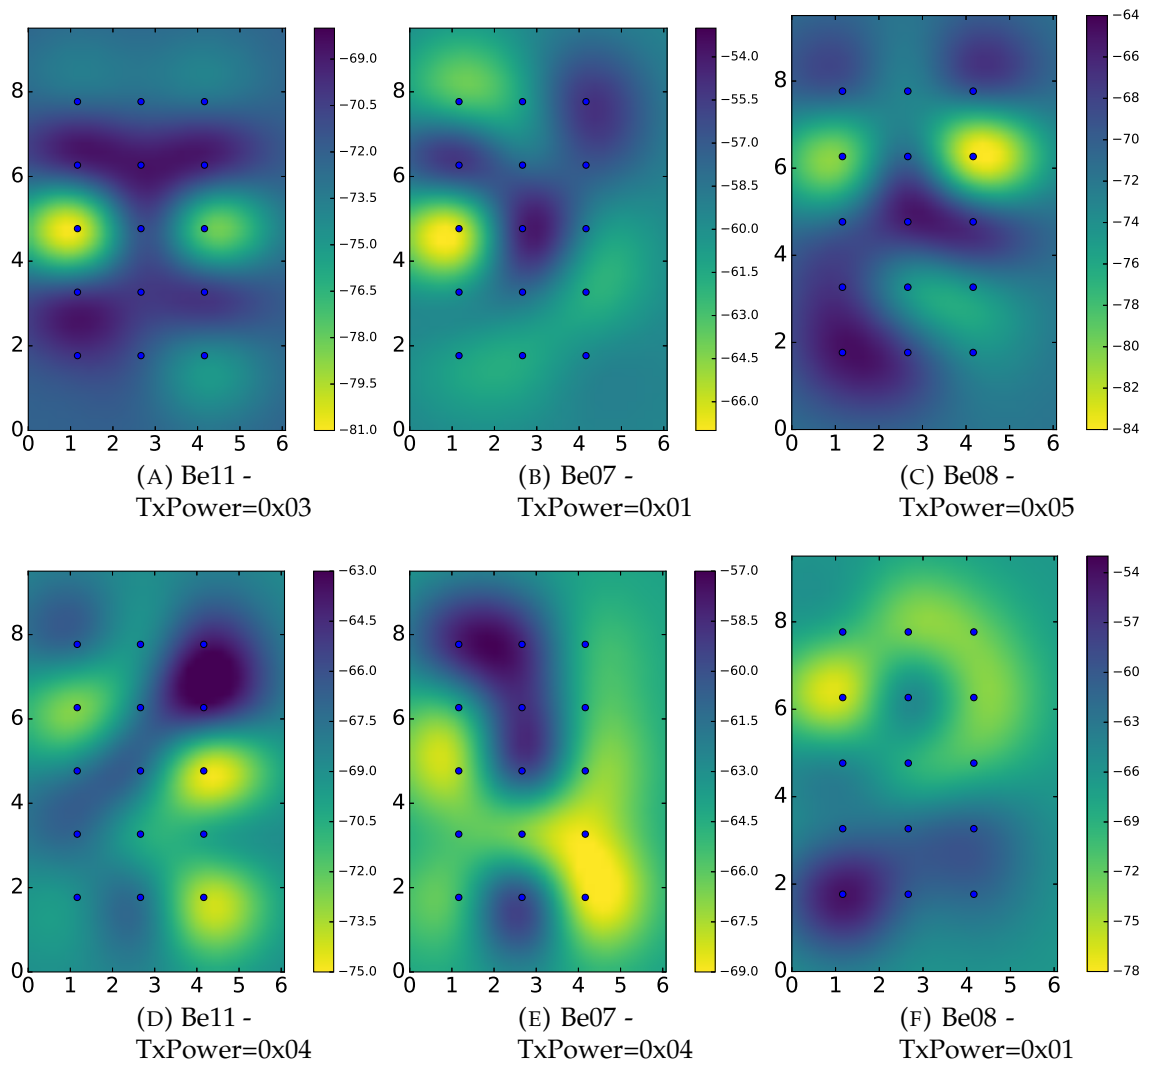


FIGURA 5.6: Valores RSSI para distintas TxPower para los Beacons BLE4.0 'Be11', 'Be07' y 'Be08'. Fuente: Elaboración propia.


5.5. Localización basada en intensidad de transmisión asimétrica

Se realizó una búsqueda intensiva evaluando todas las combinaciones de TxPower para cada Beacon. En cada combinación se realizó una evaluación calculando el error medio y global. En este caso, la plataforma está compuesta de 5 Beacons, cada uno con 6 niveles de TxPower, por lo que se obtiene en total 7776 combinaciones por procesar.


Las Figuras 5.7 y 5.8 muestran los resultados de las 3 mejores y 3 peores configuraciones encontradas. La Figura 5.7 muestra los resultados obtenidos por k-NN con criterios MD y WD, siendo el mejor resultado la configuración Be07 con TxPower = 0x04, Be08 con TxPower = 0x01, Be09 con TxPower = 0x02, Be10 con TxPower = 0x01 y Be11 con TxPower = 0x01, el cual es representado por el vector [4,1,2,1,1], indicando las TxPower de cada uno ordenadamente. Esta configuración obtiene un error $< 3m$ el 95 % del tiempo.

La Figura 5.8 muestra la mejor configuración, la misma que k-NN [4,1,2,1,1], con una precisión de 75.57% y la Figura 5.9 muestra los mapas de calor del RSSI de esta configuración, se observa en este caso que las posiciones de cada Beacon son bien diferenciadas, siendo así un factor relevante para obtener un buen resultado.

Los Cuadros 5.4 y 5.5 indican la precisión local para ambos algoritmos. Es notorio que los valores mayores son cercanos a la posición física de los Beacons y el menor valor en ambos casos es en el centro del mapa, donde no existe una buena diferenciación de los valores de RSSI respecto a otros sectores.



(A) Usando WD



(B) Usando MD

FIGURA 5.7: Error de posicionamiento para k-NN ($k=5$). En ambos gráficos se muestran las 3 mejores y peores combinaciones de TxPower. Fuente: Elaboración propia.




FIGURA 5.8: Error de posicionamiento para SVM (con kernel polinomial de grado 2). Se muestran las 3 mejores y peores combinaciones de TxPower. Fuente: Elaboración propia.

CUADRO 5.4: Precisión local por sector en porcentaje (%), usando k-NN moda ($k = 5$). Las esquinas y costados son las posiciones de los Beacons. La configuración de intensidades es [4,1,2,1,1]. Fuente: Elaboración propia.

Be07				Be11
	81.31	71.43	84.62	
	30.10	70.69	84.11	
Be09	100.00	18.10	52.88	
	28.95	71.17	53.19	
	72.10	86.92	77.59	
Be08				Be10

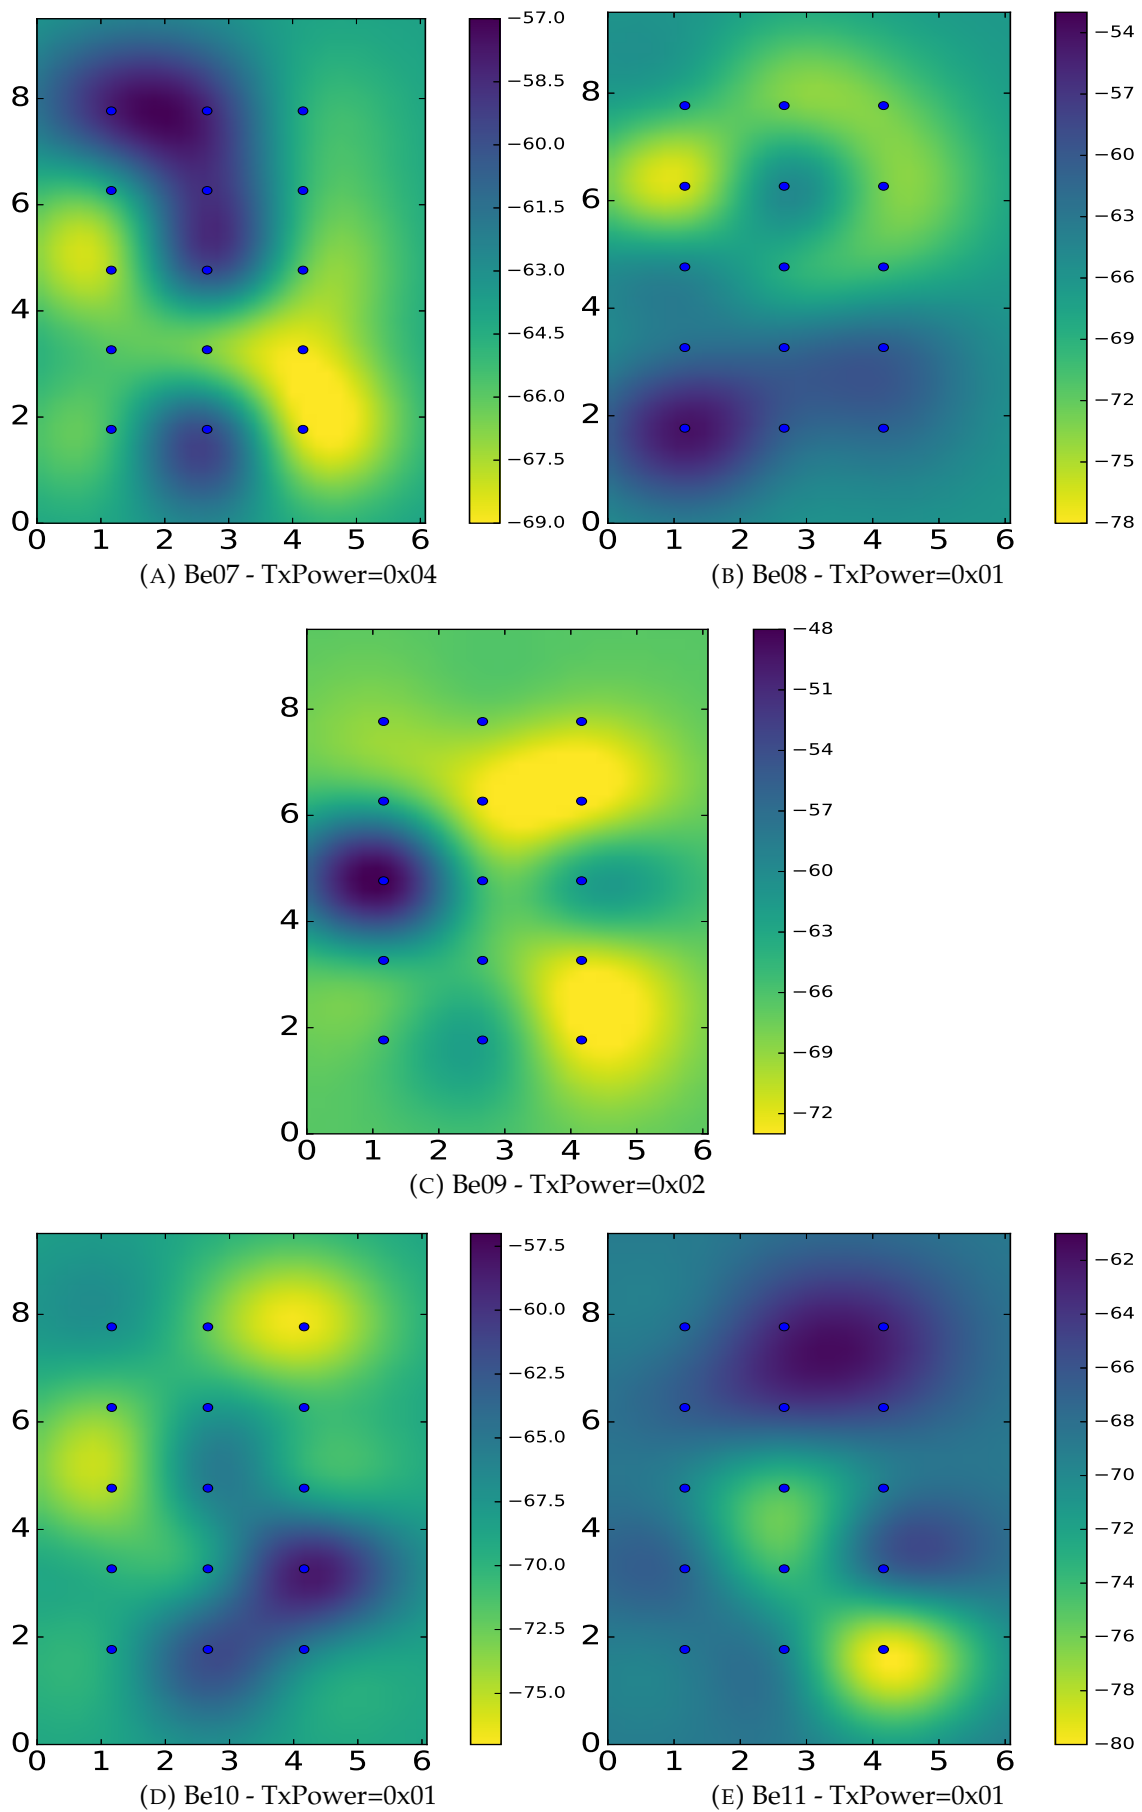


FIGURA 5.9: Valores RSSI usando la configuración de TxPower más relevante, para cada Beacon: [4,1,2,1,1]. Fuente: Elaboración propia.

CUADRO 5.5: Precisión local por sector en porcentaje (%), usando SVM (kernel polinomial $g = 2$). Las esquinas y costados son las posiciones de los Beacons. La configuración de intensidades es [4,1,2,1,1]. Fuente: Elaboración propia.

Be07				Be11
	85.00	80.70	99.07	
	11.50	69.17	76.64	
Be09	70.43	19.83	51.97	
	20.18	68.38	27.66	
	52.33	87.85	91.38	
Be08				Be10

Estos resultados confirman que la configuración de las TxPower de cada Beacon impactan en el resultados de los algoritmos de clasificación, SVM y k-NN. Sin embargo, no se tiene evidencia concluyente que el ambiente y arquitectura del área experimental tenga algún comportamiento relacionado a las TxPower trabajadas, por lo que es aconsejable realizar inicialmente un estudio del ambiente a estudiar.

5.6. Análisis empírico de intensidad de transmisión asimétrica

Finalmente se estudia la propagación de la precisión según la configuración y algoritmo utilizado, así como su error medio.

Los Cuadros 5.6 y 5.7 muestran como k-NN (MD) reporta un resultado ligeramente mejor que k-NN (WD) y SVM, los mejores resultados se indican en negrita. Estos resultados muestran que k-NN (MD) con una configuración asimétrica de intensidades exhibe un error medio menor, aproximadamente $0.07m$ más bajo que el obtenido por SVM.

CUADRO 5.6: Error acumulado de posicionamiento con distintos TxPower para k-NN ($k = 5$) usando WD y MD; y SVM (kernel polinomial $g = 2$). Fuente: Elaboración propia.

Algoritmo - Configuración Tx	Error acumulado de posicionamiento				
	0 m	≤1 m	≤2 m	≤3 m	≤4 m
k-NN (WD) - [3,3,3,3,3]	33.27 %	57.22 %	77.53 %	88.15 %	95.12 %
k-NN (WD) - [4,1,2,1,1]	36.15 %	64.47 %	82.92 %	94.03 %	98.70 %
k-NN (MD) - [3,3,3,3,3]	65.00 %	65.00 %	74.57 %	81.36 %	89.26 %
k-NN (MD) - [4,1,2,1,1]	77.89 %	77.89 %	86.74 %	92.52 %	99.68 %
SVM - [6,6,6,6,6]	61.70 %	61.70 %	72.81 %	77.22 %	88.40 %
SVM - [4,1,2,1,1]	75.57 %	75.57 %	84.92 %	90.33 %	99.12 %

CUADRO 5.7: Error medio para k-NN ($k = 5$) usando distancia WD y MD; y SVM (kernel polinomial $g = 2$) para distintas TxPower. Fuente: Elaboración propia.

Algoritmo - Configuración Tx	Error Medio (m)
k-NN (WD) - [3,3,3,3,3]	1.16
k-NN (WD) - [4,1,2,1,1]	0.57
k-NN (MD) - [3,3,3,3,3]	1.11
k-NN (MD) - [4,1,2,1,1]	0.51
SVM - [6,6,6,6,6]	1.17
SVM - [4,1,2,1,1]	0.58

Este caso ha coincidido en que la mejor configuración de TxPower es la misma para k-NN y SVM, esto no se cumple siempre. Del Cuadro 5.8, las combinaciones obtenidas son distintas entre técnicas; además, si un Beacon tiene mejores resultados al ser configurado con una TxPower no todas las combinaciones manteniendo esta TxPower fija son las mejores, ya que depende de todos los otros valores en conjunto de los Beacons.

CUADRO 5.8: Precisión para k-NN usando MD ($k = 5$) (derecha) y SVM (kernel polinomial $g = 2$) (izquierda). Mejores y peores configuraciones asimétricas de intensidades, y la mejor configuración simétrica de intensidades (en letra *cursiva*). Fuente: Elaboración propia.

SVM		k-NN	
Configuración Tx	Precisión	Configuración Tx	Precisión
[1-2-4-5-3]	35.70 %	[1-5-4-5-3]	43.23 %
[1-5-4-5-3]	35.91 %	[1-2-4-5-3]	44.48 %
[1-5-5-5-3]	36.28 %	[1-5-4-5-5]	44.53 %
[1-5-5-2-3]	36.69 %	[1-3-4-5-3]	44.54 %
[1-2-4-2-3]	36.73 %	[1-3-4-2-3]	44.58 %
[1-3-5-5-1]	51.13 %	[1-4-4-4-3]	54.70 %
[2-2-2-2-2]	52.68 %	[5-5-5-5-5]	56.70 %
[5-5-5-5-5]	50.41 %	[2-2-2-2-2]	61.50 %
[1-1-1-1-1]	57.74 %	[1-1-1-1-1]	62.10 %
[3-3-3-3-3]	57.90 %	[6-6-6-6-6]	63.80 %
[4-4-4-4-4]	60.70 %	[4-4-4-4-4]	64.70 %
[6-6-6-6-6]	61.70 %	[3-3-3-3-3]	65.00 %
[1-1-3-4-1]	64.82 %	[4-4-2-4-4]	69.20 %
[4-4-4-6-1]	70.83 %	[4-1-1-1-1]	69.90 %
[4-1-2-3-2]	73.86 %	[3-1-2-1-1]	75.96 %
[4-1-4-1-1]	74.29 %	[4-1-2-3-4]	76.87 %
[4-1-2-6-1]	75.36 %	[4-1-2-6-1]	77.23 %
[4-1-2-3-1]	75.36 %	[4-1-2-1-4]	77.45 %
[4-1-2-1-1]	75.57 %	[4-1-2-1-1]	77.89 %

5.7. Multipath Fading y su efecto en localización

Según el Cuadro 5.8 la configuración [1,1,1,1,1] es la 4ta mejor, respecto a las configuraciones simétricas. Además la mejor configuración en general ([4,1,2,1,1]) tienen TxPower= 0x01 en 3 de los 5 Beacons, lo que brinda un

primer indicador a los perfiles que se deben analizar.

Las Figuras 5.6b y 5.6e presentan el fenómeno Multipath Fading, cambiando a la configuración uniforme [1,1,1,1,1] con un TxPower 0x04 en Be07, la precisión mejora de un 62.1 % a un 69.9 %, [4,1,1,1,1] con k-NN. De la Figura 5.9 comparando el RSSI de Be07 y Be08 con TxPower= 0x04 y TxPower= 0x01 respectivamente, se observa que en la parte inferior de Be08 existen valores altos y definidos de RSSI, mitigando el fenómeno MultiPath Fading causado por Be07.

Considerando ahora la configuración simétrica [4,4,4,4,4], la segunda mejor en esta categoría, si se altera por una configuración como [4,4,2,4,4], la precisión aumenta de 64.7 % a 69.2 %, mejorando aproximadamente 5 %. En cambio si la configuración se configura como [1,4,4,4,3] la precisión cae a un 54.7 %.

Este análisis es importante, pues permite enfocar la optimización de la localización en base a una correcta configuración de TxPower de los Beacons. El uso de una base de datos de valores RSSI a distintas TxPower en un espacio es vital para obtener resultados favorables, de hecho, diversos trabajos recientes se enfocan en la creación de estas bases de datos [31]. Como la búsqueda de la combinación óptima se basa en una búsqueda exhaustiva, el enfoque para resolver este problema se basa en distintos algoritmos de optimización combinatoria, por ejemplo, algoritmos genéticos.

Capítulo 6

Conclusiones y Trabajo a Futuro

6.1. Conclusiones

En la presente Tesis se ha logrado realizar un análisis en profundidad de las características a configurar para un mecanismo de localización en interior basado en Bluetooth.

Debido a las diversas dificultades que presenta este tipo de tecnología, tanto en la emisión como recepción de señal, se reconocen los criterios a tomar en cuenta para configurar un entorno, tales como: (a) el comportamiento del RSSI según el entorno, (b) la distribución de Beacons y sectorización del área, (c) la técnica algorítmica a utilizar, (d) el dispositivo receptor, (e) la configuración de la intensidad de transmisión de cada Beacon individualmente.

De los criterios encontrados, según los resultados obtenidos en esta Tesis, se puede decir que:

- Un área con fronteras, $0.5m$, y a una distancia entre 0.5 a $1.5m$ del emisor da mejores resultados, ya que permite una buena diferenciación de RSSI entre distintos sectores.
- Usar un receptor como la Antena BLE4.0 da mejores resultados que usar un Smartphone, mejorando la precisión significativamente.
- La topología y distribución de los Beacons es un factor importante y afecta la precisión de clasificación según el área.

- La técnica de fingerprinting, usando 5-NN, con un criterio MD da los mejores resultados.
- Una configuración asimétrica de las TxPower para cada Beacon mejora notablemente la precisión del algoritmo.

El estudio de la configuración asimétrica de TxPower ayuda tanto a una mejor clasificación al hacer uso de los algoritmos, como a mitigar el fenómeno Multipath Fading, que puede llevar a generar percepciones erróneas del comportamiento del RSSI.

Además el siguiente trabajo ha contribuido al conocimiento científico-experimental con diversos trabajos publicados en revistas y congresos internacionales [32, 33, 34].

6.2. Trabajo a Futuro

A continuación se listan algunos enfoques propuestos, que pueden desarrollarse a raíz del tema de la presente Tesis.

6.2.1. Benchmark para mejorar la precisión con Algoritmos Clasificadores

Un estudio intensivo sobre qué técnica algorítmica es mejor para incrementar la precisión de clasificación de la localización, es viable, al expandir e incluir otros algoritmos de aprendizaje más agresivos y complejos a este problema, explorando técnicas mejores a k-NN y SVM.

6.2.2. Desarrollo de software de calibración automática

Como se explicó en el trabajo, tanto métodos de posicionamiento por trilateración, con Rappaport, o como fingerprinting, usando algún método de clasificación, requieren una fase de calibración y aprendizaje previo que

depende de cada zona estudiada y/o distribución de Beacons. Se propone desarrollar un sistema sea móvil o de escritorio que permita manejar este proceso de forma autónoma, para la mejor experiencia del usuario.

6.2.3. Métodos híbridos de posicionamiento en interiores usando Wi-Fi y Bluetooth

Dado que existen muchos estudios de posicionamiento en interior usando Wi-Fi y Bluetooth, se propone estudiar métodos que implementen ambas tecnologías, por ejemplo, utilizar la señal Wi-Fi para zonas grandes, como determinar una habitación en particular en toda una casa, y refinar la posición aproximada de esa habitación utilizando Beacons Bluetooth.

6.2.4. Evaluación óptima de Configuración Asimétrica de Intensidades

Ya que la búsqueda intensa, que se realiza para todas las configuraciones de Intensidades en un entorno pequeño, demanda mucho tiempo, la complejidad del problema al extenderse a áreas mayores, al ser combinatorio, se vuelve imposible de resolver. Por lo tanto, se propone evaluar métodos de optimización combinatoria que busque optimizar esta búsqueda, como la aplicación de algoritmos genéticos.

6.3. Competencias adquiridas

A continuación se exponen las competencias adquiridas con la finalización de esta Tesis. Estas competencias involucran distintas áreas de aprendizaje que formaron parte de la currícula actual de la Escuela y están relacionadas a los objetivos alcanzados.

- Se adquirió la capacidad para el desarrollo de aplicativos móviles utilizando el lenguaje de programación de Android, con lo que se creó una

aplicación que permite filtrar los valores RSSI de los Beacons y obtener estadísticas básicas para su análisis.

- Se adquirió conocimientos de técnicas de Inteligencia Artificial como algoritmos de Machine Learning que realizan clasificación.
- Para el post procesamiento de datos capturados se adquirió la capacidad de programar en lenguajes interpretados como Matlab y Python.
- Para la captura de datos de la Raspberry Pi 2, se adquirió capacidades de manejo de Sistemas Operativos y protocolos de hardware.
- Con el objetivo de analizar e interpretar los resultados se adquirió las capacidades estadísticas necesarias.

Bibliografía

- [1] “Android developers, “bluetooth low energy.”” <http://developer.android.com/intl/es/guide/topics/connectivity/bluetooth-le.html>. Accessed: 2016-05-10.
- [2] “Apple inc., ios: Understanding ibeacon,”” <https://support.apple.com/en-us/HT202880>. Accessed: 2016-05-10.
- [3] R. Faragher and R. Harle, “Location fingerprinting with bluetooth low energy beacons,” *Selected Areas in Communications, IEEE Journal on*, vol. 33, no. 11, pp. 2418–2428, 2015.
- [4] C. Perera, S. Aghaee, R. Faragher, R. Harle, and A. Blackwell, “A contextual investigation of location in the home using bluetooth low energy beacons,” *arXiv preprint arXiv:1703.04150*, 2017.
- [5] L. Pei, M. Zhang, D. Zou, R. Chen, and Y. Chen, “A survey of crowd sensing opportunistic signals for indoor localization,” *Mobile Information Systems*, 2016.
- [6] A. S. Paul and E. A. Wan, “Rssi-based indoor localization and tracking using sigma-point kalman smoothers,” *Selected Topics in Signal Processing, IEEE Journal of*, vol. 3, no. 5, pp. 860–873, 2009.
- [7] J. Martínez-Gómez, M. M. del Horno, M. Castillo-Cara, V. M. B. Luján, L. O. Barbosa, and I. García-Varea, “Spatial statistical analysis for the design of indoor particle-filter-based localization mechanisms,” *International Journal of Distributed Sensor Networks*, vol. 12, no. 8, 2016.

- [8] S. Shuo, S. Hao, and S. Yang, "Design of an experimental indoor position system based on rssi," in *Information Science and Engineering (ICISE), 2010 2nd International Conference on*, pp. 1989–1992, IEEE, 2010.
- [9] S. Feldmann, K. Kyamakya, A. Zapater, and Z. Lue, "An indoor bluetooth-based positioning system: Concept, implementation and experimental evaluation.," in *International Conference on Wireless Networks*, pp. 109–113, 2003.
- [10] S. Pagano, S. Peirani, and M. Valle, "Indoor ranging and localisation algorithm based on received signal strength indicator using statistic parameters for wireless sensor networks," *Wireless Sensor Systems, IET*, vol. 5, no. 5, pp. 243–249, 2015.
- [11] K. Onishi, "Indoor position detection using ble signals based on voronoi diagram," in *Intelligent Software Methodologies, Tools and Techniques*, pp. 18–29, Springer, 2015.
- [12] L. Pei, R. Chen, J. Liu, T. Tenhunen, H. Kuusniemi, and Y. Chen, "Inquiry-based bluetooth indoor positioning via rssi probability distributions," in *Advances in Satellite and Space Communications (SPACOMM), 2010 Second International Conference on*, pp. 151–156, IEEE, 2010.
- [13] F. Palumbo, P. Barsocchi, S. Chessa, and J. C. Augusto, "A stigmergic approach to indoor localization using bluetooth low energy beacons," in *Advanced Video and Signal Based Surveillance (AVSS), 2015 12th IEEE International Conference on*, pp. 1–6, IEEE, 2015.
- [14] M. Sugano, T. Kawazoe, Y. Ohta, and M. Murata, "Indoor localization system using rssi measurement of wireless sensor network based on zigbee standard," *Target*, vol. 538, p. 050, 2006.
- [15] M. S. Bargh and R. de Groote, "Indoor localization based on response rate of bluetooth inquiries," in *Proceedings of the first ACM international workshop*

on *Mobile entity localization and tracking in GPS-less environments*, pp. 49–54, ACM, 2008.

- [16] R. Faragher and R. Harle, “An analysis of the accuracy of bluetooth low energy for indoor positioning applications,” in *Proceedings of the 27th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS+’14)*, 2014.
- [17] P. Kriz, F. Maly, and T. Kozel, “Improving indoor localization using bluetooth low energy beacons,” *Mobile Information Systems*, vol. 2016, 2016.
- [18] J. Paek, J. Ko, and H. Shin, “A measurement study of ble ibeacon and geometric adjustment scheme for indoor location-based mobile applications,” *Mobile Information Systems*, vol. 2016, 2016.
- [19] X.-Y. Lin, T.-W. Ho, C.-C. Fang, Z.-S. Yen, B.-J. Yang, and F. Lai, “A mobile indoor positioning system based on ibeacon technology,” in *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pp. 4970–4973, IEEE, 2015.
- [20] T. Chowdhury, M. Rahman, S.-A. Parvez, A. Alam, A. Basher, A. Alam, and S. Rizwan, “A multi-step approach for rssi-based distance estimation using smartphones,” in *Networking Systems and Security (NSysS), 2015 International Conference on*, pp. 1–5, IEEE, 2015.
- [21] T. S. Rappaport, “Wireless communications—principles and practice, (the book end),” *Microwave Journal*, vol. 45, no. 12, pp. 128–129, 2002.
- [22] “Find k-nearest neighbors using data - matlab knnsearch.” <https://www.mathworks.com/help/stats/knnsearch.html?requestedDomain=www.mathworks.com>. Accessed: 2016-05-10.
- [23] “Libsvm, “libsvm – a library for support vector machines.”” <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>. Accessed: 2016-05-10.

- [24] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *Journal of machine learning research*, vol. 3, no. Mar, pp. 1157–1182, 2003.
- [25] T. Rivas, M. Paz, J. Martin, J. M. Matías, J. Garcia, and J. Taboada, "Explaining and predicting workplace accidents using data-mining techniques," *Reliability Engineering & System Safety*, vol. 96, no. 7, pp. 739–747, 2011.
- [26] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, *et al.*, "Scikit-learn: Machine learning in python," *Journal of Machine Learning Research*, vol. 12, no. Oct, pp. 2825–2830, 2011.
- [27] P. Geurts, D. Ernst, and L. Wehenkel, "Extremely randomized trees," *Machine learning*, vol. 63, no. 1, pp. 3–42, 2006.
- [28] J. Brownlee, "Ensemble methods. in machine learning mastery with python," in *Machine Learning Mastery Pty Ltd.: Vermont Victoria*, pp. 91–95, Australia, 2016.
- [29] J. Li, K. Cheng, S. Wang, F. Morstatter, R. P. Trevino, J. Tang, and H. Liu, "Feature selection: A data perspective," *arXiv preprint arXiv:1601.07996*, 2016.
- [30] A. Rahim, R. Dimitrova, and A. Finger, "Techniques for bluetooth performance improvement."
- [31] L. Chen, B. Li, K. Zhao, C. Rizos, and Z. Zheng, "An improved algorithm to generate a wi-fi fingerprint database for indoor positioning," *Sensors*, vol. 13, no. 8, pp. 11085–11096, 2013.
- [32] M. Castillo-Cara, J. Lovón-Melgarejo, G. Bravo-Rocca, L. Orozco-Barbosa, and I. García-Varea, "An analysis of multiple criteria and setups for bluetooth smartphone-based indoor localization mechanism," *Journal of Sensors*, vol. 2017, 2017.

- [33] M. Castillo-Cara, J. Lovón-Melgarejo, G. Bravo-Rocca, L. Orozco-Barbosa, and I. García-Varea, "An empirical study of the transmission power setting for bluetooth-based indoor localization mechanisms," *Sensors*, vol. 17, no. 6, 2017.
- [34] J. Lovón-Melgarejo, M. Castillo-Cara, G. Bravo-Rocca, L. Orozco-Barbosa, and I. García-Varea, "Supervised learning algorithms for indoor localization fingerprinting using ble4.0 beacons," in *4th IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pp. 1–6, IEEE, 2017.

Apéndice A

Jaalee Beacons

Los Beacons son dispositivos de bajo consumo de energía que emiten paquetes de información de corta duración en un rango pequeño de distancia. Existen diversas marcas de fabricantes, para este trabajo se utilizó Jaalee iB004-N Plus.

En la Figura A.1 se muestran las principales características para los distintos tipos de modelo que ofrece Jaalee Beacons.

Model	Measures (mm)	Shape	Range (m)	Lifetime (at 1 second)	Battery Type
iB001-N	28 x 8	round	25	5 months	CR2032
iB001-N mini	28 x 6	round	25	12 months	CR2016
iB003-N	42 x 13	square	70	34 months	CR2450
iB004-N	40 x 40 x 13.6	square	70	34 months	CR2450
iB004-N plus	40 x 40 x 16	square	100	59 months	CR2477
iB005-N	18.5 x 14 x 6	USB	40	N/A	N/A

FIGURA A.1: Características de los Beacons Jaalee. Fuente: Jaalee web

Los Beacons posee 3 estados principales:

- **Advertising.** El estado principal, donde el Beacon emite señales periódicas con un paquete de información.
- **Sleeping.** Cuando el Beacon se encuentra desactivado, por ejemplo, para ahorrar energía.

- **Connection.** Estado donde se permite una comunicación por ambas partes.

El paquete de información que emiten los Beacons periódicamente consiste de:

- UUID (16 bytes)
- Major Code (2 bytes)
- Minor Code (2 bytes)
- Otros (p.e Nivel de batería)

El UUID es el identificador principal de cada dispositivo, los códigos Major y Minor son valores para determinar zonas. Supongamos que se poseen 3 Beacons con UUID 'x' en una tienda. Se colocan 2 Beacons en la primera planta y 1 Beacon en la segunda. Con el UUID 'x' se puede identificar a los Beacons como pertenecientes a esas tiendas, con el código Major se identifica a qué planta pertenece cada Beacon, y con el código Minor se identifica a cada Beacon individualmente.

Es difícil trabajar con este tipo de dispositivos, ya que la señal que envían es muy inestable, principalmente por su fuente de energía que es una pila, aunque puede llegar a durar hasta 1 o 2 años dependiendo del tipo de uso.

Estos dispositivos trabajan en un rango de frecuencias de 2400-2483.5 MHz, un voltaje de 1.8-3.6 V y un alcance teórico de 100 metros — y práctico de 75 metros aproximadamente.

Los valores de lectura de RSSI no solo dependen del Beacon sino también del dispositivo usado, en este caso, el dispositivo móvil. Pues las configuraciones de antenas entre modelos varía entre dispositivos, por ejemplo, Estimote de Google desarrolla exclusivamente para iOS, y por ello trabajar sobre estos

dispositivos da resultados más precisos.

El Cuadro A.1 muestra el RSSI base, es decir a 1 metro, para los distintos TxPower, y en el Cuadro A.2 los intervalos de espera de envío de señal de este proveedor.

CUADRO A.1: RSSI base según TxPower a 1 metro. Fuente: Jaalee web.

Jaalee TxPower	Dbm
0x08	-82
0x07	-75
0x06	-65
0x04	-57
0x02	-23
0x01	-6

CUADRO A.2: Intervalos entre transmisión según cada TxPower. Fuente: Jaalee web

Jaalee TxPower	Intervalo de Transmisión	Duración de batería
0x01	0.1 s	0.3 años
0x02	0.2 s	0.6 años
0x05	0.5 s	1.4 años
0x0a	1.0 s	2.7 años
0x19	2.5 s	6.3 años
0x32	5.0 s	11.4 años
0x64	10.0 s	19.4 años

Apéndice B

Áreas experimentales

En este apéndice se describirá las zonas sobre las cuales se experimentó, para tener en cuenta el medio y obstáculos principales de cada uno.

B.1. Pasillo 1

El pasillo del i³A, frente al laboratorio SIMD, tiene las siguientes características:

- Una pared lateral es 100 % de vidrio en toda su longitud.
- La altura del pasillo es uniforme.
- El tráfico de personas es muy frecuente en el momento de la toma de medidas.

B.2. Pasillo 2

El pasillo de la entrada principal del i³A posee estas características:

- Lateralmente se encuentra una escalera de vidrio.
- En la otra pared lateral se encuentra oficinas que poseen ventanas principalmente.



FIGURA B.1: Pasillo 1 del i³A Fuente: Elaboración propia.



FIGURA B.2: Pasillo 2 del i³A Fuente: Elaboración propia.

B.3. Área experimental 1

Para los experimentos bajo fingerprinting se utilizó inicialmente una porción de la primera sala del laboratorio ReTiCS, exactamente una porción de $3 \times 4 \text{ m}^2$, como se muestra en la Figura 4.7, discretizado en espacios de 1 m^2 .

Las Figuras B.3 y B.4 muestran que los bordes del área tienen presencia de estantes, habitaciones con puertas abiertas y lateralmente ventanas, además de un espacio congestionado de mesas, escritorios y alta presencia de routers en los techos.

B.4. Área experimental 2

Se utilizó la misma Área experimental 1, pero un área mayor, como se muestra en la Figura 4.11, se discretizaron 15 espacios de 1 m^2 en un área de 9.3×6.3 , dejando 0.5 metros de espacio entre ellas. Además se deja entre 0.5 y 1.5 metros de distancia entre el inicio de las zonas discretizadas y las paredes y Beacons utilizados en las medidas.



FIGURA B.3: Área experimental 1 del i³A. Fuente: Elaboración propia.



FIGURA B.4: Área experimental 2 del i³A. Fuente: Elaboración propia.