



Universidad Católica
San Pablo

FACULTAD DE INGENIERÍA Y COMPUTACIÓN
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y
ELECTRÓNICA

Escuela Profesional de Ingeniería Electrónica y de
Telecomunicaciones

Tesis

**LOCALIZACIÓN ESPACIAL BASADA EN LA
POTENCIA DE RECEPCIÓN DE SEÑALES WI-FI
UTILIZANDO UN SMARTPHONE**

Autor: Jesus Araoz Coacalla

Asesor: Dr. Efrain Zenteno Bolaños

Documento presentado a la Escuela Profesional de Ingeniería Electrónica y de Telecomunicaciones como parte de los requisitos para obtener el título profesional de Ingeniero Electrónico y de Telecomunicaciones

Arequipa, septiembre de 2022

Trabajo de Titulación V.2

INFORME DE ORIGINALIDAD

17%

INDICE DE SIMILITUD

16%

FUENTES DE INTERNET

4%

PUBLICACIONES

9%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	webresources.ruckuswireless.com Fuente de Internet	6%
2	www.abacusnetworks.net Fuente de Internet	1%
3	repositorio.ucsp.edu.pe Fuente de Internet	1%
4	hdl.handle.net Fuente de Internet	1%
5	tel.archives-ouvertes.fr Fuente de Internet	<1%
6	www.coursehero.com Fuente de Internet	<1%
7	www.tandfonline.com Fuente de Internet	<1%
8	oa.upm.es Fuente de Internet	<1%
9	Submitted to University of Newcastle upon Tyne	<1%

”Seguir la evidencia a donde quiera que nos lleve”
Sócrates, 470 a.c

Índice general

Resumen	5
Abstract	7
1. Introducción	9
1.1. Motivación y Contexto	10
1.2. Planteamiento del problema	11
1.3. Objetivos	12
1.3.1. Objetivo general.	12
1.3.2. Objetivos específicos	12
1.4. Metodología	12
1.5. Consideraciones Complementarias	13
1.5.1. Recursos y Materiales	13
1.5.2. Cronograma de Trabajo	14
2. Marco Teórico	17
2.1. Introducción a la radiopropagación	17
2.1.1. Radioenlace	17
2.1.2. Potencia recibida	18
2.1.3. Pérdidas de propagación y modelamiento del canal	19
2.2. Estándar IEEE 802.11	21
2.2.1. Indicador de fuerza de la señal recibida	22
2.3. Estimación de la distancia	23
2.4. Enfoques de estimación de posición	24
2.4.1. Algoritmo de trilateración	25
2.4.2. Multilateración	26
2.5. Aprendizaje automático	27
2.5.1. Red neuronal artificial	28
2.6. Programación por bloques	30
2.6.1. MIT App Inventor	30
3. Estado del Arte	33
3.1. Introducción	33
3.2. Avances del indoor localization	33
3.3. Análisis y apreciaciones finales	39

4. Diseño de la solución	41
4.1. Selección de puntos de referencia	41
4.1.1. Ubicación de APs	41
4.2. Ubicación de coordenadas	42
4.2.1. Plano para método con aproximaciones geométricas	42
4.2.2. Plano para aprendizaje automático	44
4.3. Herramienta de recolección de datos	45
4.3.1. Validación de la aplicación propia	47
4.4. Campaña de mediciones y generación de la base de datos	49
4.4.1. Primera campaña de mediciones	49
4.4.2. Segunda campaña de mediciones	50
5. Resultados	53
5.1. Estimación del canal	53
5.1.1. Experimento 1: Cálculo de n y C	53
5.1.2. Experimento 2: Cálculo de n y C	58
5.2. Técnicas de estimación de la posición	61
5.2.1. Experimento 3: Trilateración en distintos escenarios	61
5.2.2. Experimento 4: Multilateración de 4 puntos	67
5.2.3. Experimento 5: Trilateración más aprendizaje automático	68
5.2.4. Experimento 6: Aprendizaje automático	70
5.3. Comparación parcial de los resultados	74
5.3.1. Método con aproximación geométrica	74
5.3.2. Método con aprendizaje automático	75
5.4. Costo computacional	75
5.4.1. Error versus número de entradas	76
5.4.2. Error versus número de neuronas	78
5.5. Comparación total de resultados	79
6. Discusión	81
7. Conclusiones y trabajos futuros	85
7.1. Conclusiones	85
7.2. Trabajos futuros	86
Reconocimientos	87
A. Anexo	89
A.1. Sección 1	89
A.1.1. Código de trilateración usando matrices	89
A.1.2. Lectura, promedio y varianza de los datos del AP3	89
A.1.3. Elaboración de las gráficas experimento 1	92
A.1.4. Estimador lineal y polinómico	92
A.1.5. Especificaciones técnicas del medidor láser de distancia e imagen.	94

Índice general

A.2. Cuadros de las figuras 5.7, 5.8 y 5.9	95
A.3. Cuadro con los 100 puntos de los cuadros 4.3 y 4.4	98
A.4. Cuadro explicativo del Cuadro 4.33	98
A.5. Cuadro de comparación de todos los enfoques respecto al SCG16 re- entrenado	100
A.6. Especificaciones de los modelos de AP Ruckus 500 y 600 respectivamente	100
Bibliografía	107
Nomenclatura	111

Índice de figuras

1.1. Número de artículos relacionados a localización en interiores, a lo largo de los años. Proporcionado por el motor de búsqueda de SCOPUS usando las palabras “indoor localization”	11
1.2. Esquema metodológico para el desarrollo de este trabajo	13
2.1. Radioenlace y propagación de las OEM	17
2.2. Proceso de medida para el RSSI descrito en el estándar 802.11	22
2.3. Esquema de los 4 enfoques de estimación de posición	24
2.4. Explicación gráfica del método de trilateración	26
2.5. Esquema de tipos de aprendizaje máquina y los objetivos de uso . . .	27
2.6. Neuronas artificiales	28
2.7. Red neuronal artificial	29
3.1. Esquema de técnicas y algoritmos de localización	35
4.1. Planta baja edificio Duhamel mejores estimaciones (en rojo) puntos 1, 2, 12. Las posiciones de los AP (en verde), y los puntos de referencia (en azul).	43
4.2. En amarillo se sitúan los puntos de referencia donde se realizaron las mediciones “off-line” de la potencia recibida (RSSI). Para evaluar los métodos de aprendizaje máquina	44
4.3. Inicio de pantalla y alerta de habilitación WiFi	45
4.4. Botón de activación de la app y búsqueda de redes disponibles	45
4.5. Bloque que construye la impresión en pantalla de las redes leídas y sus respectivas características	46
4.6. Bloque de obtención de los parámetros requeridos y de escritura de ficheros, donde se guardan los datos de las redes	47
4.7. Validación de App propia vs WiFi Analyzer	48
4.8. Figura que muestra una captura de pantalla con la aplicación propia, en funcionamiento	49
5.1. Comportamiento del RSSI para los distintos APs a distintas distancias. Para condiciones con línea de vista (LOS)	55
5.2. Mediciones de RSSI y curva estimada para diversos APs, a) AP1, b) AP3, c) AP4, d) AP5	57
5.3. 25 muestras por cada 0.5m para distintos escenarios, a) Tráfico alto, b) Tráfico bajo, c) Tráfico medio	58

5.4. Promedio y varianza de las 25 muestras para distintos escenarios, a) Tráfico alto, b) Tráfico bajo, c) Tráfico medio	59
5.5. Estimación de canal para diversos escenarios, a) Tráfico alto, b) Tráfico medio, c) Tráfico Bajo	60
5.6. Diagrama de la Red Neuronal	70
5.7. Gráfica que muestra el RMSE de validación, para distinto número de entradas en una red de 10 neuronas	77
5.8. Gráfica que muestra el RMSE para distinto número de neuronas en una red de 14 entradas	78
5.9. Gráfica que muestra el RMSE para distinto número de neuronas ahora con 16 entradas	79
A.1. Imagen del medidor láser de distancia	94

Índice de cuadros

1.1. Recursos y materiales	14
1.2. Cronograma de trabajo	15
2.1. Exponente de pérdidas (n) para diferentes escenarios	21
2.2. Asignación de canales y frecuencias centrales para la banda de 2.4 GHz	21
3.1. Comparación de costo, complejidad y precisión de los distintos sistemas basados en tiempo y en dirección	40
4.1. Ubicación y características de los AP de referencia	41
4.2. Coordenadas de ubicación de los APs y puntos a estimar	42
4.3. Estructura de la base de datos con 14 AP, 20 muestras por punto, para los 100 puntos seleccionados. Donde, R es el RSSI.	50
4.4. Estructura de etiquetas de la base de datos para ML 14 entradas. Donde, X e Y representan las coordenadas de cada punto de referencia, que deben repetirse el mismo número de veces que muestras haya por punto.	51
5.1. Lecturas RSSI versus distancia para los AP	54
5.2. Comparación de exponente de pérdidas (n), promedio y estimado . .	56
5.3. Coeficiente estimado en diversos escenarios	61
5.4. Posiciones (X, Y) y la estimación de su posición (X_e , Y_e) utilizando trilateración, se indica el error absoluto en condición de espacio libre con $n=2$, $C=-40\text{dBm}$	62
5.5. Trilateración y error de estimación en condición de espacio libre+10 dB en AP5 con $n=2$, $C=-40\text{dBm}$	62
5.6. Trilateración y estimación de error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$	63
5.7. Trilateración y estimación de error, estimación de curva +10dB con $n=2.21$, $C=-52.36\text{dBm}$	63
5.8. Trilateración y error, estimación de curva con $n=1.83$, $C=-48\text{dBm}$.	64
5.9. Trilateración y error, estimación de curva + 10dB con $n=1.83$, $C=-48\text{dBm}$	64
5.10. Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$	65
5.11. Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$	65
5.12. Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$	66
5.13. Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$	66

5.14. Trilateración y error de estimación en condición de espacio libre+10 dB con $n=2$, $C=-40$ dBm	66
5.15. Trilateración y error de estimación en condición de espacio libre+10 dB con $n=2$, $C=-40$ dBm	67
5.16. Multilateración y error, estimación de curva con $n=2.21$, $C=-52.36$ dBm	67
5.17. Multilateración y error, estimación de curva con $n=2.21$, $C=-52.36$ dBm	68
5.18. Red neuronal LVM + Trilateración	69
5.19. Red neuronal BR + Trilateración	69
5.20. Red neuronal SCG + Trilateración	69
5.21. Red de 10 neuronas y 14 entradas, algoritmo de Levenberg-Marquadt	71
5.22. Red de 10 neuronas y 14 entradas, algoritmo Regulación Bayesiana .	71
5.23. Red de 10 neuronas y 14 entradas, algoritmo de Gradiente Conjugado Escalado	72
5.24. Red de 10 neuronas y 16 entradas, algoritmo de Levenberg-Marquadt	73
5.25. Red de 10 neuronas y 16 entradas, algoritmo de Regulación Bayesiana	73
5.26. Red de 10 neuronas y 16 entradas, algoritmo de Gradiente Conjugado Escalado	74
5.27. Comparación de RMSE (m) 10 Neuronas vs 100 neuronas RN de 16 entradas para 3 diferentes algoritmos	74
5.28. Comparación RMSE de los enfoques que usan trilateración	75
5.29. Comparación de distintos algoritmos de redes neuronales (LVM, BR, SCG) con 14 y 16 entradas	75
5.30. Cálculo del costo computacional en FLOPS para una red neuronal de 16 entradas y 10 neuronas	76
5.31. Resultados de la comparación entre número de entradas y el error que produce en la estimación de posición, red de 10 neuronas	77
5.32. Porcentaje de mejora respecto a la reducción de error de estimación, en relación al enfoque de espacio libre	80
A.1. Funciones básicas del medidor láser de distancia HoldPeak	94
A.2. Resultados de la comparación entre número de entradas y el error que produce en la estimación de la posición, red de 10 neuronas	95
A.3. Resultados de la comparación entre número de neuronas y el error que produce en la estimación de la posición, red de 14 entradas	96
A.4. Resultados de la comparación entre número de neuronas y el error que produce en la estimación de la posición, red de 16 entradas	97
A.5. 100 puntos ML	98
A.6. Comparación de todos los enfoques incluido el mejor SCG reentrenado de 16 neuronas	99
A.7. Comparación de todos los enfoques al SCG reentrenado de 16 neuronas. La mejora se da en porcentajes	100

Resumen

En recientes años, la demanda por sistemas de localización para interiores ha ido en aumento. Esto con el fin de optimizar procesos en la industria, mejorar la toma de decisiones y desplegar la navegación en interiores. Consiguiendo así, ahorrar recursos, aumentar la calidad de los servicios, y así mejorar la calidad de vida del usuario final. Sin embargo, en nuestra región se observa un incipiente desarrollo de este tipo de sistemas. En este sentido, para impulsar el estudio en esta área, el presente trabajo desarrolla e implementa varios sistemas que estiman la localización en interiores. Estos sistemas están basados en la lectura del indicador de fuerza de señal recibida (RSSI por sus siglas en inglés) en un smartphone, dada la potencia emitida por los puntos de acceso (AP por sus siglas en inglés). Se ha llevado a cabo el estudio de investigación en las instalaciones de la universidad Católica San Pablo (Edificio Duhamel planta baja). Dado que, se ha requerido de una red WI-FI (Wireless Fidelity) con el mayor número posible de puntos de acceso, para el método probabilístico. Aunque, el sistema funciona en cualquier entorno que posea al menos tres puntos de acceso. Un número mayor permite mejorar la precisión de la localización. Se han utilizado dos diferentes enfoques, tales como: algoritmos determinísticos (trilateración) y probabilísticos (aprendizaje automático). Ambos enfoques han sido comparados para determinar cuál de estos muestra el mejor desempeño (precisión, complejidad, y escalabilidad). Como resultado se ha obtenido un error promedio de 15.4 metros al usar trilateración. Asimismo, se ha obtenido un error promedio de 2.95 metros en la estimación de la posición, al usar una red neuronal, entrenada con el algoritmo de gradiente conjugado escalado (SCG por sus siglas en inglés). Dichos resultados son similares a lo observado en el estado del arte.

Palabras clave:

Localización en Interiores, WiFi, RSSI, Fingerprinting, Trilateración, Red Neuronal Artificial.

Abstract

In recent years, demanding for indoor localization systems has increased. This is to optimize industrial processes, to enhance decision-making, and to deploy indoor navigation systems. Thus achieving, save resources, increase service quality and therefore improve life quality of end users. However, in our region it has been observed that there is an incipient developing in this kind of systems. This work develops and implements systems that estimate indoor localization. These systems are based on the received signal strength indicator (RSSI) on a smartphone, given the power emitted by access points (AP). Two different approaches were implemented, such as: deterministic algorithms (trilateration) and probabilistic ones (machine learning). Both approaches have been compared to determine which shows a better performance (accuracy, complexity, and scalability). As outcome, it has been obtained an average error of 15.4 meters by using trilateration. Likewise, it has been got 2.95 meter of average error in the estimation of position, by using a neural network with scaled conjugate gradient (SCG) algorithm. These results are similar to that observed in the state of the art. Given that it has been required the greatest number of access points for the probabilistic method. It has been considered to carry out the research study at the facilities of Católica San Pablo university (ground floor Duhamel building), since, it has a Wi-Fi (Wireless Fidelity) access point network deployed inside this. However, the system should be able to work in any environment that has at least three access points, but a larger number of these increase significantly the accuracy.

Keywords:

Indoor Localization, WiFi, RSSI, Fingerprinting, Trilateration, Artificial Neural Network.

1. Introducción

Dado el vertiginoso incremento y desarrollo de nuevas formas de comunicaciones, demandantes cada vez, de mayor interoperabilidad entre distintas tecnologías y plataformas. Tal es el caso de las comunicaciones máquina a máquina (M2M por sus siglas en inglés) o las comunicaciones máquina a humano. Así como, la entrada en operaciones de industria 4.0, término que fue utilizado por primera vez por el gobierno alemán. El cual describe una organización de los procesos de producción basada en la tecnología, y en dispositivos que se comunican entre ellos de forma autónoma a lo largo de la cadena de valor (Smit et. al. 2016) [Blanco et al., 2017]. Además, esto se encuentra en relación con el acelerado crecimiento del internet de las cosas (IoT por sus siglas en inglés). Una tecnología que parte del hecho de que cada objeto en la vida cotidiana está generando datos a cada instante. Por lo que, estos datos pueden ser digitalizados, compartidos y almacenados para su posterior procesamiento. Convirtiéndolos en información estadística, altamente valiosa para los estados, las industrias y las personas.

En las últimas décadas las comunicaciones han tendido a ser cada vez menos dependientes de medios cableados para su transmisión. Esto a causa de la gran portabilidad de los dispositivos, y de la cada vez más necesaria movilidad de los usuarios. Así, uno de los estándares de comunicaciones inalámbricas más conocidos y usados en el presente es el IEEE 802.11. Conocido comercialmente como WiFi, está por cumplir ya 25 años desde su lanzamiento al mercado mundial. Ha sido un verdadero cambio de paradigma y democratización de las telecomunicaciones. Pues, es de las tecnologías que mayor infraestructura desplegada posee.

Este estándar (IEEE 802.11) opera a frecuencias de 2.4 y 5 GHz, aunque su alcance y velocidades máximas teóricas son de algunas centenas de metros y la decena de Gigabits por segundo. En la práctica, la distancia configurada es de aproximadamente 30 metros, y las velocidades son generalmente un tercio de las máximas.

En este contexto de creciente desarrollo, por cada nueva tecnología que se despliega otras tantas tecnologías, herramientas y aplicaciones surgen alrededor, aprovechando las ventajas o mejoras que esta primera trae consigo. Una de esas aplicaciones son los servicios basados en localización (LBS por sus siglas en inglés). Los cuales usan el conocimiento de la posición de las personas, seres vivos u objetos, con el fin de brindar alguna clase de servicio, tanto para exteriores cuanto para interiores. Ayudando así, a la optimización de procesos industriales, mejorando la toma de decisiones, y a la geonavegación de los usuarios. Se consigue de esta forma, ahorrar recursos, aumentar la calidad de los servicios, y así mejorar la calidad de vida de los

usuarios finales. Algunos ejemplos de estos servicios en exteriores son el sistema de posicionamiento global (GPS por sus siglas en inglés), el tracking o seguimiento, el control de tráfico, el geofencing o geovallas virtuales, entre otros. Y para interiores son, el inventariado de productos en almacenes, que ayuda a una más eficiente toma de decisiones en la línea de suministros. El geomarketing, que muestra productos o servicios personalizados a los clientes en los centros comerciales. El posicionamiento, navegación y rastreo en edificios, hospitales o universidades, que ahorra tiempo a los usuarios.

En este trabajo se estudiarán e implementarán varios sistemas de localización para interiores basados en el estándar IEEE 802.11, utilizando técnicas determinísticas como la trilateración y probabilísticas como el aprendizaje automático (ML por sus siglas en inglés). Para lo cual, se procesarán los datos registrados del indicador de intensidad de señal recibida (RSSI), emitidos por puntos de acceso (AP) desplegado al interior de la universidad Católica San Pablo, esto usando un smartphone.

1.1. Motivación y Contexto

Ante la imperante idea que se ha ido constituyendo en la conciencia colectiva, sobre lo que debieran ser las comunicaciones del presente y futuro. Retratada en la frase “todos y todo conectado, siempre y en cualquier lugar”. Se debe afrontar el desafío de brindar a los usuarios aquello que demanden. Una de las formas de cumplir con las expectativas de conectividad móvil, calidad del servicio, eficacia y eficiencia, puede ser mediante los LBS para interiores basados en WiFi. Debido a que ya tienen desplegada toda la infraestructura requerida (puntos de acceso), lo que reduciría los costos. Pues, al necesitar solo el RSSI minimizaría la complejidad del sistema.

De otro lado, al conocer la posición aproximada de alguien o algo, es posible observar su comportamiento a lo largo del tiempo y espacio. Pudiendo ser esta información generada muy interesante de interpretar, para resolver diferentes tipos de problemas. Por ejemplo, conocer la preferencia de los clientes sobre ciertos negocios dentro de un mall, la disponibilidad de productos almacenados, el conocer las áreas más concurridas por la gente en un hospital, biblioteca o universidad. Aunque, esta tecnología es prometedora y ampliamente estudiada por el área de investigación, desarrollo e innovación (I+D+i) de compañías como Google o Microsoft, son pocas las empresas en nuestra región (América del Sur) que brindan soluciones comerciales. Por el contrario, en España, tal sería el caso de Situm Technologies, una empresa gallega que se ha posicionado como referente en soluciones globales para interiores, sin despliegue de infraestructura. Constituida con el objetivo de ser una especie de indoor Google Maps. Provee a muchas industrias, aeropuertos, estaciones de tren, puertos, estadios, eventos multitudinarios y empresas de marketing, soluciones basadas en localización al interior. Al unir distintos tipos de señales de radiofrecuencia como WiFi o Bluetooth a los sensores existentes en los smartphones, a través de algoritmos de inteligencia artificial (IA), mejora así la precisión de sus aplicaciones.

1.2. Planteamiento del problema

El problema que se ha identificado en este trabajo es la ausencia, dentro de nuestra región, de un sistema de localización en interiores de coste reducido y baja complejidad, que no necesite desplegar infraestructura o que utilice la ya existente, con una precisión que permita aplicaciones a nivel usuario.

Para ilustrar este problema y su necesidad de estudio, se puede poner como ejemplo la llegada de IoT. Una tecnología en la que la densidad de dispositivos desplegados por kilómetro cuadrado, rondaría al menos el millón, como se observa en [Kuhlins et al., 2020]. Entonces, habrá gran necesidad de servicios LBS, tales dispositivos requerirán ser localizados, y a la vez brindarán la oportunidad de usarlos como fuentes de localización. Por lo que, se hace imperioso estudiar las formas óptimas de localización en interiores. Además, este gran interés se ve reflejado en el aumento constante de la cantidad de artículos relacionados al tema de esta tesis. Como se observa en la Figura 1.1., en la que se muestra el número de publicaciones sobre localización en interiores, desde los años noventa hasta el presente año, 2022. Esta gran atención reflejada en la abundante literatura científica, además del avance de otras tecnologías a las que se ha hecho referencia anteriormente, conducirá a próximos desarrollos, y por lo tanto al despliegue de aplicaciones comerciales. Con lo que, se vuelve necesario familiarizarnos con el tema, profundizar por medio de la investigación, y desarrollar soluciones en nuestra región. Con el fin de que la irrupción de tecnologías revolucionarias como, el IoT o la Industria 4.0, no nos dejen solo como consumidores de tecnología, sino como creadores.




Figura 1.1.: Número de artículos relacionados a localización en interiores, a lo largo de los años. Proporcionado por el motor de búsqueda de SCOPUS usando las palabras “indoor localization”

1.3. Objetivos

1.3.1. Objetivo general.

Diseñar e implementar un sistema de localización en interiores basado en la lectura de RSSI de la red WiFi utilizando un smartphone.

1.3.2. Objetivos específicos

1. Desarrollar una herramienta para la recolección de RSSI, utilizando un smartphone.
2. Realizar una campaña de mediciones, y crear una base de datos de la potencia medida para ubicaciones preseleccionadas.
3. Implementar dos aproximaciones (determinística y probabilística) para la estimación de la posición.
4. Validar los resultados obtenidos (estimar el error).
5. Comparar diversas aproximaciones para la estimación de la posición, utilizando las mediciones realizadas.

1.4. Metodología

Se utilizará una metodología basada en la recolección de datos y la implementación de varios sistemas basados en algoritmos determinísticos (trilateración) y probabilísticos (aprendizaje automático). La línea de investigación en la que se clasifica este trabajo es de procesamiento de señales y datos.

A continuación, se detalla la metodología:

1. En la primera etapa se desarrollará una aplicación para smartphone que haciendo uso de su receptor de WiFi lea y almacene los datos del RSSI.
2. En la segunda etapa se realizará la campaña de mediciones y se creará una base de datos que asociará cada RSSI a su respectivo AP.
3. En la tercera etapa se procederá a implementar varios sistemas que con los datos recolectados estime la posición.
4. En la cuarta etapa se validarán los resultados obtenidos por la estimación, comparándolos con las posiciones reales.
5. En la quinta etapa se compararán los resultados de los diversos enfoques utilizados en la estimación de la posición.

La Figura 1.2. muestra el esquema metodológico que se seguirá en el desarrollo del presente trabajo.

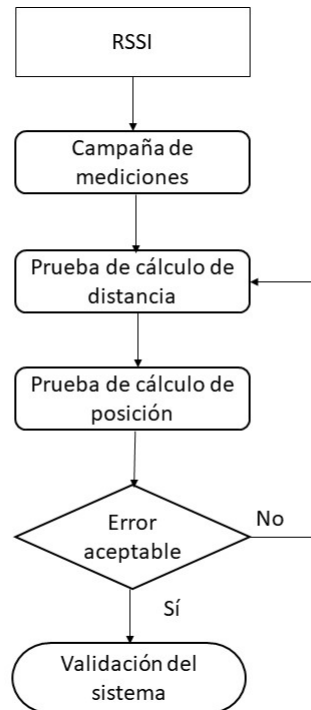


Figura 1.2.: Esquema metodológico para el desarrollo de este trabajo

1.5. Consideraciones Complementarias

1.5.1. Recursos y Materiales

El Cuadro 1.1. en la página siguiente lista los componentes, dispositivos y herramientas de software que serán utilizados en el desarrollo de la presente tesis.

Tipo	Material/recurso	Uso/descripción
Hardware	Computadora	Poder computacional en el procesamiento de la información y algoritmos de ML.
	Smartphone	Recolección y almacenamiento de la señal RSSI y aplicación final.
	Puntos de Acceso	Fuentes de la señal WiFi y puntos de referencia.
Software	Matlab	Entorno de desarrollo de algoritmos de ML.
	App Inventor	Entorno de programación gráfica para el desarrollo de aplicaciones Android, en este caso sirvió para crear la APK que recolecta RSSI.
	Android Studio	Entorno de desarrollo de aplicaciones Android.
Fuentes de información	Bases de datos en revistas indexadas, IEEE explorer, Google académico.	Estudio de la literatura, trabajos previos y fuentes actuales para profundizar el tema de investigación.

Cuadro 1.1.: Recursos y materiales

1.5.2. Cronograma de Trabajo

En el Cuadro 1.2. se muestra el cronograma de actividades que se seguirán en el desarrollo del presente trabajo. Como se observa, algunas tareas son trabajadas paralelamente.

1.5 Consideraciones Complementarias

Semestre	2018-II			2019-I							2019-II				
Mes	10	11	12	01	02	03	04	05	06	07	08	09	10	11	12
Recopilación de la información	X														
Construcción del planteamiento del problema	X	X	X												
Objetivos y justificación	X	X	X	X											
Metodología		X	X	X	X										
Marco teórico				X	X	X	X								
Propuesta de diseño					X	X	X								
Caracterización						X	X	X	X	X					
Análisis e interpretación de resultados								X	X	X	X				
Diseño								X	X	X	X	X			
Implementación y pruebas										X	X	X	X		
Rediseño y pruebas												X	X	X	
Análisis e interpretación de resultados								X	X	X	X	X	X	X	X

Cuadro 1.2.: Cronograma de trabajo

Organización del Presente Documento

Esta tesis estará organizada en siete capítulos (introducción, marco teórico, estado del arte, diseño de la solución, discusión, por último, conclusiones y trabajos futuros) a los cuales precede el resumen de este escrito. En el primer capítulo se presenta la introducción, contexto y motivación. Así como los objetivos, desde lo general a lo específico, además de la metodología empleada. En el segundo capítulo se presenta el marco teórico. En el tercer capítulo se presenta el estado del arte, donde se exponen los trabajos de investigación más relevantes y prometedores en nuestra línea de investigación, allí se muestran los avances, posibilidades y limitaciones. En el cuarto capítulo se desarrolló la propuesta de diseño de la solución, y en los tres últimos capítulos se presentan los resultados, las conclusiones, la discusión y sugerencias de trabajos futuros, respectivamente.

2. Marco Teórico

2.1. Introducción a la radiopropagación

Para el estudio teórico y riguroso de cómo las ondas se propagan por el espacio se suelen usar las ecuaciones de Maxwell; sin embargo, estas fórmulas en casos prácticos resultan muy complejas, por lo que es común utilizar modelos simplificados para la predicción de pérdidas de propagación, los cuales se basan en la óptica geométrica. Si estos modelos resultasen inadecuados o dejaran de ser válidos se recurre a los modelos empíricos, como se lee en [Rábanos et al., 2013].

Las características de propagación de las ondas van a depender del trayecto o del terreno por el que estas se propaguen y de las características físicas-eléctricas del entorno (obstáculos, gases atmosféricos, conductividad, etc.), así como de las características del transmisor (potencia, frecuencia, etc.) [Rábanos et al., 2013].

2.1.1. Radioenlace

Es la transferencia de energía electromagnética desde el transmisor hacia el medio de propagación, y la extracción de dicha energía por parte de receptor. Estas funciones son realizadas por las antenas radiadoras y receptoras respectivamente. Tal como se observa en la en la Figura 2.1.

Todo radioenlace está limitado por las características inherentes al medio de transmisión, debido a esto las señales experimentan variaciones aleatorias, lo que puede ocasionar la reducción de su nivel, desvanecimiento, así como por distintas clases ruido e interferencias provocadas por otras fuentes de ondas electromagnéticas (OEM). Por lo que es necesario caracterizar dichas variaciones a través de métodos estadísticos, que permitan conocer la naturaleza de los mismos y compensar su influencia [Rábanos et al., 2013].




Figura 2.1.: Radioenlace y propagación de las OEM

donde

λ : Es la longitud de onda (m)

q : Es la carga eléctrica de la partícula

K : Es el número de onda ($\frac{2\pi}{\lambda}$)

T_x : Representa al transmisor

R_x : Representa al receptor

\vec{E} : Vector campo eléctrico

\vec{B} : Vector campo magnético

Para finalizar este apartado, se añaden dos conceptos importantes en los radioenlaces:

- LoS (Line of sight): Indica que el trayecto en un radioenlace no presenta obstáculos.
- NLoS (Non Line of sight): Indica que el trayecto en un radioenlace presenta obstáculos.

2.1.2. Potencia recibida

Es la potencia disponible en una antena adaptada, teóricamente se sabe que la señal se propaga idealmente en el espacio libre siguiendo el modelo de la ecuación de Friis, ver la ecuación (2.1). Con esta ecuación sabemos que la potencia de la señal disminuye desde un transmisor a un receptor a medida que la distancia entre ellos aumente.

$$P_R = P_T G_T G_R \left(\frac{\lambda}{4\pi d}\right)^n \quad (2.1)$$

donde:

P_R : Es la potencia de recepción

P_T : Es la potencia de transmisión

λ : Es la longitud de onda (m)

d : Es la distancia entre transmisor y receptor

G_T : Es la ganancia del transmisor

G_R : Es la ganancia del receptor

n : Es el exponente de pérdidas

2.1.3. Pérdidas de propagación y modelamiento del canal

Son variaciones destructivas de la intensidad de la señal electromagnética propagada. Diversos son los fenómenos que pueden ocasionar pérdidas en el trayecto, debido a la naturaleza de las OEM.

Estos pueden ser:

1. Reflexión: La OEM choca con un obstáculo y parte de la señal se refleja dependiendo del ángulo de incidencia.
2. Refracción: La OEM choca con otro medio de transmisión y pasa del medio de transmisión en el que estaba transmitiéndose hacia el nuevo medio de transmisión, cambiando el ángulo de la trayectoria, la velocidad de propagación y la potencia.
3. Difracción: La OEM choca contra un obstáculo y penetra a través de una rendija, provocando distintos frentes de onda.
4. Multitrayecto: La OEM si se propaga inalámbricamente puede tomar distintos caminos desde el transmisor hasta el receptor, ocasionando interferencias constructivas o destructivas de la señal.

Ahora bien, continuando con la explicación se pasará a describir matemáticamente el modelamiento del canal.

Pasando la ecuación (2.1) a su forma logarítmica y asumiendo las ganancias de las antenas igual a 1, entonces obtenemos,

$$L_{fs} = 10n\log_{10}\left(\frac{\lambda}{4\pi d}\right) \quad (2.2)$$

donde:

L_{fs} : Es la pérdida en el espacio, pudiéndose definir como $P_R - P_T$

d : Es la distancia entre transmisor y receptor (AP y smartphone)

Ahora, reemplazando los valores de λ en la ecuación (2.2) y separando el logaritmo obtenemos,

$$L [dBm] = L_0 + 10n\log_{10}(d) \quad (2.3)$$

donde:

L_0 : Es la pérdida constante a 1 m

Luego, cambiando L por el $RSSI$ y L_0 por una constante C , obtenemos

$$RSSI [dBm] = -10n\log_{10}(d) + C \quad (2.4)$$

donde:

C : Es un valor constante de $RSSI$ a una distancia de referencia

Por último, si se obtienen los valores de $RSSI$ para distancias conocidas entonces es posible hallar n y C de la ecuación (2.4) dado que posee la forma lineal,

$$AX = b \quad (2.5)$$

entonces, usando matrices es posible resolver el sistema de ecuaciones como se muestra a continuación:

$$\begin{bmatrix} -10\log(d_1) & 1 \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ -10\log(d_i) & 1 \end{bmatrix} \begin{bmatrix} n \\ C \end{bmatrix} = \begin{bmatrix} RSSI_1 \\ \cdot \\ \cdot \\ \cdot \\ RSSI_i \end{bmatrix}$$

donde

$$A = \begin{bmatrix} -10\log(d_1) & 1 \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ -10\log(d_i) & 1 \end{bmatrix}$$

y

$$b = \begin{bmatrix} RSSI_1 \\ \cdot \\ \cdot \\ \cdot \\ RSSI_i \end{bmatrix}$$

luego,

$$X = \begin{bmatrix} n \\ C \end{bmatrix}$$

Aplicando el método de los mínimos cuadrados obtenemos

$$X = (A^T.A)^{-1}.A^T.b \quad (2.6)$$

Con lo hecho anteriormente es posible modelar el canal en cada escenario, hallando n y C .

Asimismo, según [Farahani, 2008a], en distintos escenarios se obtienen distintos valores de n (ver Cuadro 2.1.) que es conveniente saber para la posterior comparación de los resultados obtenidos en los experimentos del presente trabajo.

n	Escenarios
2.0	Espacio libre
1.6 a 1.8	En interiores, LOS
2.09	Salón de clases 15 x7.6 m con mesas y sillas
2 a 3	Dentro de empresas, NLOS
2.8	En interiores residenciales
2.7 a 4.3	En interiores, edificio de oficinas

Cuadro 2.1.: Exponente de pérdidas (n) para diferentes escenarios

2.2. Estándar IEEE 802.11

Este trabajo está basado en el estándar IEEE 802.11, comercialmente conocido como WiFi. La frecuencia a la que se trabajará será a 2.4 GHz que cuenta con 14 canales, los cuales poseen un ancho de banda de 22 MHz y una banda de guarda de 5 MHz. En el Cuadro 2.2. se muestra cómo se distribuyen estos canales según lo visto en [Electronicsnotes, 2019].

Canal	Frecuencia central (MHz)
1	2412
2	2417
3	2422
4	2427
5	2432
6	2437
7	2442
8	2447
9	2452
10	2457
11	2462
12	2467
13	2472
14	2484

Cuadro 2.2.: Asignación de canales y frecuencias centrales para la banda de 2.4 GHz

2.2.1. Indicador de fuerza de la señal recibida

El indicador de fuerza de señal recibida o RSSI es un parámetro opcional dentro de la trama de preámbulo, este indicador que tiene un valor de 0 a RSSI Max. Este parámetro es una medida de la subcapa física (PHY) de la energía observada en la antena utilizada para recibir la unidad de datos del protocolo actual (PPDU). El RSSI se medirá entre el inicio del delimitador de trama de inicio (SFD) y el final de la verificación de errores del encabezado PLCP (HEC), protocolo de convergencia de capa física. El RSSI está destinado a ser utilizado de una manera relativa. No se especifica la precisión absoluta de la lectura de RSSI [Farahani, 2008b].

El estándar IEEE 802.11 determina campos en la trama de preámbulo que contiene el RSSI, como se ve en la Figura 2.2. [Figuera et al., 2011].

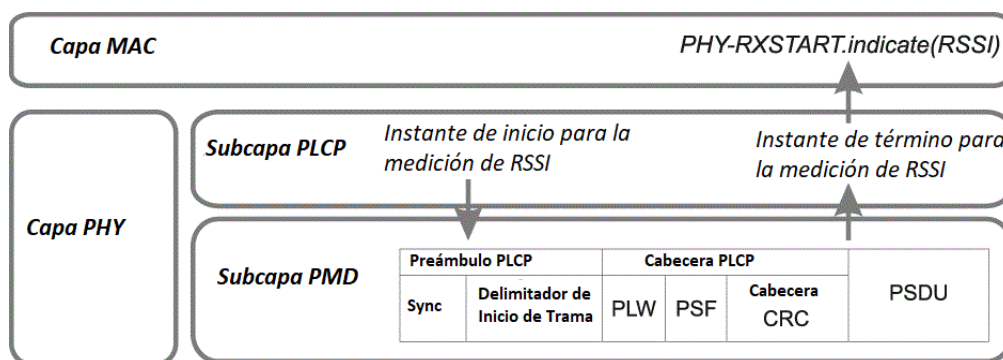


Figura 2.2.: Proceso de medida para el RSSI descrito en el estándar 802.11

El campo RSSI especifica un número entero que identifica la interfaz de red, si el valor de RSSI está disponible, este campo debe ser un valor negativo. El rango típico para los valores RSSI es de -90 hasta -20, valores por encima de -10 dBm son inusuales. Estos valores son medidos en una escala logarítmica, decibelios, referenciados a 1 milivatio (dBm), como se explica en el artículo [Figuera et al., 2011] donde se muestra una etapa de calibración, y además del reporte técnico [Inc, 2002] en el que se explica qué significa dBm y cómo convertir estos a Watts y viceversa.

Si el valor RSSI real no está disponible, pero la implementación tiene alguna otra estimación de la intensidad de la señal, este campo debe ser un valor en el rango de 0 a 100, donde un valor de 50 significa una calidad de enlace promedio y un valor de 100 significa un enlace perfecto, el ancho de canal usado en la red wifi guarda relación con el RSSI. Canales más anchos normalmente brindan valores más bajos de RSSI.

2.3. Estimación de la distancia

A partir de la ecuación (2.7), asumiendo pérdidas en el espacio libre con $n=2$, como menciona [Onkar et al., 2014], es posible estimar la distancia desde el AP al smartphone, no obstante, la señal RSSI es muy variable debido a pérdidas de propagación, multitrayecto y desvanecimiento.

$$L(d) = 10n \log_{10}\left(\frac{d}{d_0}\right) + 20 \log_{10}\left(\frac{4\pi d_0}{\lambda}\right) \quad (2.7)$$

donde:

L : Es la pérdida en el espacio libre.

d : Es el radio de la circunferencia (distancia entre AP y smartphone).

d_0 : Es la distancia de referencia (1m).

De la ecuación (2.7) obtenemos al igual que en la ecuación (2.4)

$$RSSI [dBm] = C + 10n \log_{10}(d) \quad (2.8)$$

despejando de la ecuación (2.8) d y renombrándola por d_e se tiene que,

$$d_e = 10^{\left(-\frac{RSSI+C}{10n}\right)} \quad (2.9)$$

donde:

d_e : Es la distancia estimada

Para calcular el error en cada estimación de la distancia

$$e = d_e - d \quad (2.10)$$

donde:

e : Es el error de estimación de la distancia.

Luego calculando RMSE error cuadrático medio, definido como

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2} \quad (2.11)$$

donde:

N : Es el número de puntos de acceso

Así es posible conseguir la distancia óptima, escogiendo la que menor RMSE presente [Tejada, 2018].

2.4. Enfoques de estimación de posición

En este trabajo se ha procedido a realizar 4 tipos de enfoques para estimar la posición como se observa en el siguiente esquema, ver Figura 2.3.

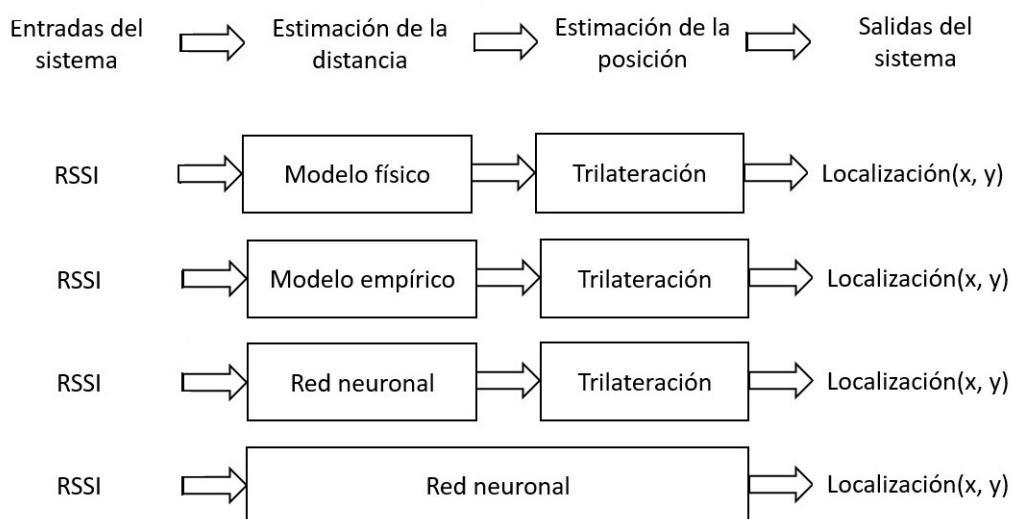


Figura 2.3.: Esquema de los 4 enfoques de estimación de posición

1. Modelo físico o semiempírico: Hace referencia al uso de la fórmula de propagación en el espacio libre ver Ecuación (2.7), asumiendo $n = 2$, para luego usar trilateración.
2. Modelo empírico: Hace referencia al uso de la Ecuación (2.7), pero considerando los valores hallados de n , a través de mediciones y del empleo de la Ecuación (2.6), luego se utiliza trilateración.
3. Red neuronal (RN): Hace referencia al uso de aprendizaje automático. En este caso una red neuronal, que se entrena con las potencias de un AP de referencia como entradas, y las distancias respectivas como etiquetas, luego se utiliza trilateración.
4. Red neuronal pura: Hace referencia al uso únicamente de aprendizaje automático. En este caso se entrena a la RN con 14 o 16 entradas, que vienen a ser APs de referencia, esto junto a las coordenadas (x, y) para cada punto tomado, como etiquetas. Una vez entrenada la red, las salidas son las coordenadas estimadas (x, y) de la posición.

2.4.1. Algoritmo de trilateración

Se ha optado como primer enfoque la trilateración que es un método de ubicación espacial en el cual es necesario tener 3 puntos de puntos de referencia. Primero se halla la distancia de cada uno de los puntos de referencia hacia el dispositivo móvil, cada línea imaginaria trazada del punto de referencia al móvil viene a ser como el radio de una circunferencia. Entonces, para hallar la localización de dicho dispositivo, se tendrá que encontrar el punto donde se intersecan estas 3 circunferencias formadas por cada distancia del punto de referencia al dispositivo. Esta técnica es simple pero eficaz. Poderosa, aunque totalmente dependiente de las distancias de los puntos de referencia al dispositivo móvil. Como se observa en los resultados de [Onkar et al., 2014].

Entonces, si cada distancia es representada como el radio de una circunferencia y conocemos las coordenadas de los puntos de referencia obtenemos las siguientes ecuaciones para dichos puntos,

$$(x - x_{r1})^2 + (y - y_{r1})^2 = r_1^2$$

$$(x - x_{r2})^2 + (y - y_{r2})^2 = r_2^2$$

$$(x - x_{r3})^2 + (y - y_{r3})^2 = r_3^2$$

donde:

x_{ri} : Es la coordenada x del centro de la circunferencia.

y_{ri} : Es la coordenada y del centro de la circunferencia.

r : Es el radio de la circunferencia.

Tras obtener un total de tres ecuaciones, una para cada AP de referencia, y la respectiva distancia de estos al smartphone se puede resolver el sistema de ecuaciones (minimizando el error cuadrático). Este sistema puede ser resuelto utilizando matrices como sugiere [Onkar et al., 2014, Boonsriwai and Apavatjrut, 2013], para ello se define

$$A = \begin{bmatrix} -2y_{r1} & 1 & -2x_{r1} & 1 \\ -2y_{r2} & 1 & -2x_{r2} & 1 \\ -2y_{r3} & 1 & -2x_{r2} & 1 \end{bmatrix}$$

$$B = \begin{bmatrix} -(x_{r1}^2 + y_{r1}^2 - d_{r1}) \\ -(x_{r2}^2 + y_{r2}^2 - d_{r2}) \\ -(x_{r3}^2 + y_{r3}^2 - d_{r3}) \end{bmatrix}$$

Donde la solución está dada por

$$O = (A^T . A)^{-1} . A^T . B \tag{2.12}$$

En la Figura 2.4. se ilustra la trilateración:

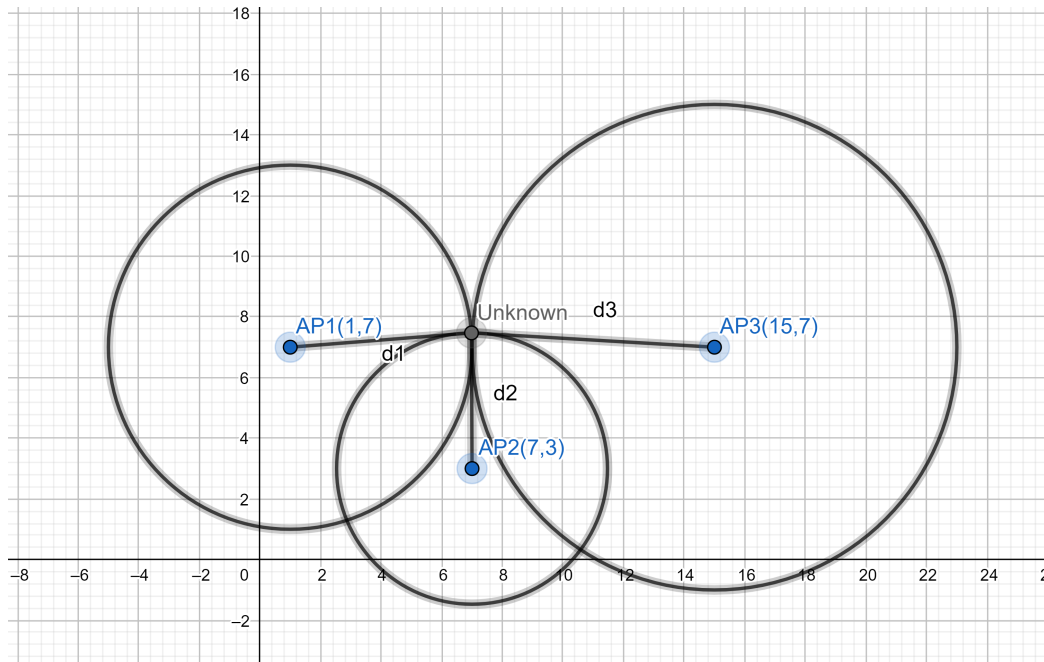


Figura 2.4.: Explicación gráfica del método de trilateración

Esta solución ha sido implementada en Matlab, ver Anexo A.

2.4.2. Multilateración

Utiliza el mismo principio de trilateración, pero con un número mayor de puntos de referencias o AP

$$A = \begin{bmatrix} -2y_{r1} & 1 & -2x_{r1} & 1 \\ -2y_{r2} & 1 & -2x_{r2} & 1 \\ -2y_{r3} & 1 & -2x_{r3} & 1 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ -2y_{ri} & 1 & -2x_{ri} & 1 \end{bmatrix}$$

$$B = \begin{bmatrix} -(x_{r1}^2 + y_{r1}^2 - d_{r1}) \\ -(x_{r2}^2 + y_{r2}^2 - d_{r2}) \\ -(x_{r3}^2 + y_{r3}^2 - d_{r3}) \\ \vdots \\ \vdots \\ \vdots \\ -(x_{r3i}^2 + y_{ri}^2 - d_{ri}) \end{bmatrix}$$

Donde la solución está dada por

$$O = (A^T . A)^{-1} . A^T . B \quad (2.13)$$

2.5. Aprendizaje automático

Es una técnica de análisis de datos que emula el aprendizaje que tienen las personas y los animales, es decir que aprenden de la experiencia. Estos tipos de algoritmos extrapolan funciones de los datos observados. Estas funciones pueden ser multidimensionales, además su rendimiento es adaptativo a la cantidad y calidad de muestras con las que se les entrene [Mathworks.Inc., 2019c].

Este enfoque debe ser usado cuando se tenga un problema complejo, que implique una gran cantidad de datos y muchas variables, mas no se tenga fórmulas o ecuaciones conocidas o las que se tengan requieran una implementación mucho más compleja que entrenar una máquina, también cuando los datos presentan mucha variabilidad o anomalías [Mathworks.Inc., 2019c].

El aprendizaje automático puede dividirse en dos grandes ramas que tienen distintos objetivos, como se muestra en el esquema de la Figura 2.5.

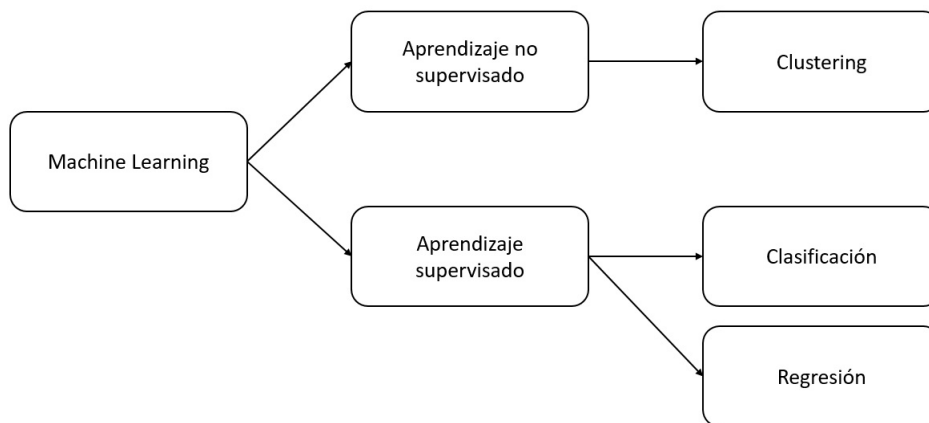


Figura 2.5.: Esquema de tipos de aprendizaje máquina y los objetivos de uso

2.5.1. Red neuronal artificial

Es un tipo de aprendizaje supervisado, dentro del campo del aprendizaje automático o machine learning. Una de las características de este enfoque que hace que se lo utilice en el presente proyecto es que las redes neuronales predicen respuestas continuas. Es decir, puede ser utilizado como una técnica de regresión [Mathworks.Inc., 2019c].

Este tipo de inteligencia artificial simula a las neuronas biológicas y a las redes que estas forman en el cerebro. En la Figura 2.6. se representa a una neurona artificial. Donde las entradas representan el axón, los pesos representan a las sinapsis, la unión entre los pesos y el sumatorio representan las dendritas, el sumatorio representan el cuerpo de la neurona, la función de activación representa el cuello del axón y las salidas representa otro axón

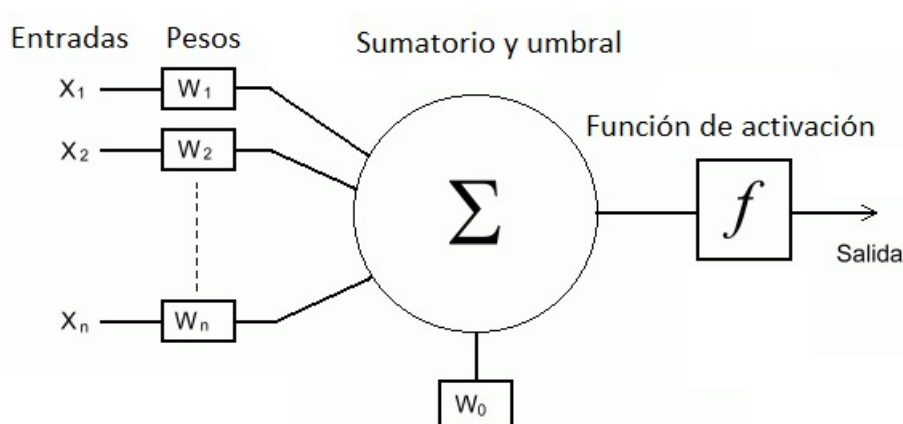


Figura 2.6.: Neurona artificial

En la Figura 2.7. se representa la estructura interna de una red neuronal artificial. Compuesta de una capa de entrada, una o múltiples capas ocultas, y una capa de salida.

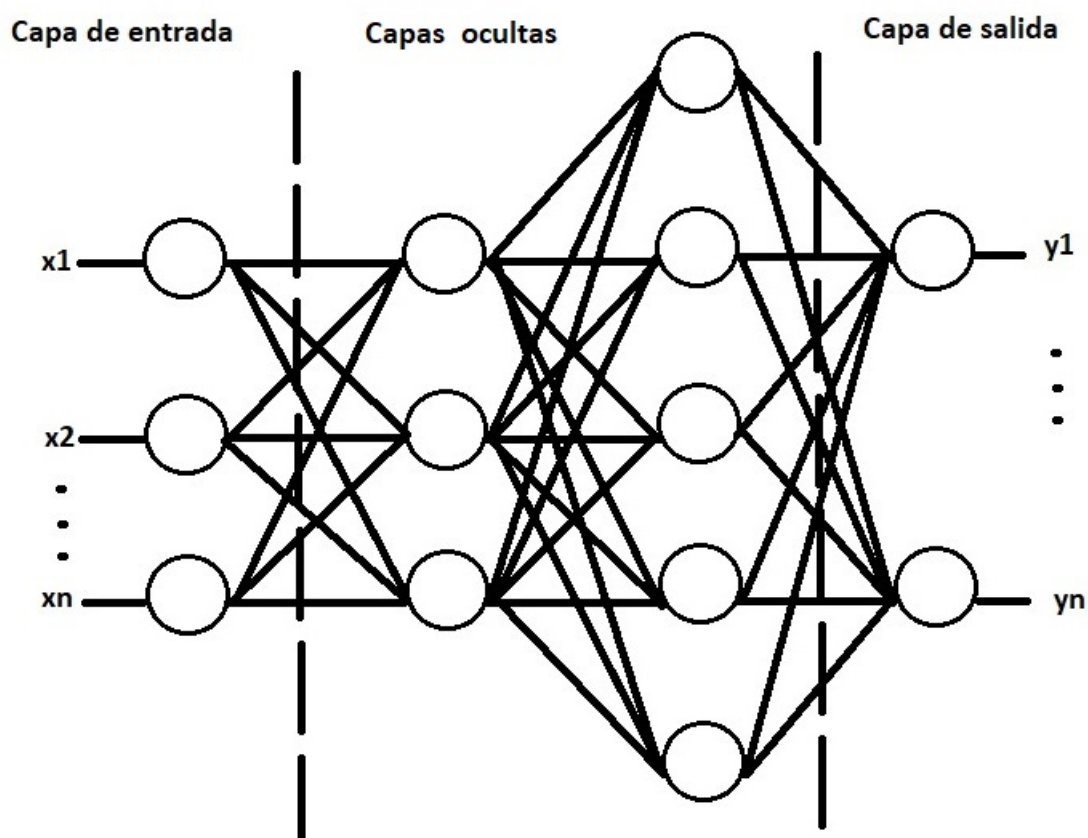


Figura 2.7.: Red neuronal artificial

Además, en el presente proyecto se han usado 3 tipos de algoritmos:

1. Levenberg-Marquadt (LVM): Este algoritmo usa más memoria, pero toma menos tiempo. El entrenamiento se detiene automáticamente cuando la generalización ya no mejora, como lo indica el error cuadrático medio de las muestras de validación [Mathworks.Inc., 2019b].
2. Regularización bayesiana (BR): Este algoritmo toma más tiempo, pero puede resultar en una generalización más adecuada para muestras de datos difíciles, pequeñas o ruidosas. El entrenamiento se detiene de acuerdo con la minimización adaptativa de los pesos (regularización)[Mathworks.Inc., 2019a].
3. Gradiente conjugado escalado (SCG): Este algoritmo usa menos memoria. El entrenamiento se detiene automáticamente cuando la generalización deja de mejorar, como lo indica el error cuadrático medio de más muestras de validación [Mathworks.Inc., 2019d] .

2.6. Programación por bloques

La programación por bloques es una forma gráfica, amigable, e intuitiva de programar para el usuario. En esta se usan bloques de código de distintos colores, lo cuales pueden ser armados como piezas de un rompecabezas para escribir un programa. Tan solo con arrastrarlos y soltarlos se empieza a escribir el programa. Este tipo de interfaces suelen poseer dos capas: Un editor de diseño y otra de bloques [Patton et al., 2019]. A continuación, se reseñará de modo breve, la historia de esta herramienta, y se describirán algunas características importantes. Asimismo, sus posibilidades y limitaciones.

2.6.1. MIT App Inventor

Este entorno de programación por bloques es una plataforma en línea, creada con propósitos educativos. Su desarrollo inició alrededor del año 2007 en Google Labs. Este trabajo fue desarrollado por el profesor del MIT Hal Abelson, inspirado en Scratch (otro entorno de programación por bloques), y ,en esos años, en el nuevo sistema operativo para dispositivos móviles, Android. Sin embargo, llegando el año 2011 Google canceló este proyecto a causa del cierre de Google Labs. Motivo por el cual, este proyecto fue trasladado al MIT, donde, el profesor Abelson, Mark Friedman, entre otros, siguieron desarrollándolo, hasta su lanzamiento alrededor del 2012 [Patton et al., 2019].

Este aplicativo web llamado App Inventor ya va por su segunda versión, y posee la funcionalidad de enlazar las aplicaciones creadas en el entorno web a un dispositivo móvil android o iOS. a través, de la aplicación MIT Companion App instalada en el dispositivo móvil. Lo cual permite una visualización y prueba en tiempo real, de aquello que se ha programado. Además, por su puesto, de poder descargar y compartir la aplicación creada, con toda la comunidad de desarrolladores App Inventor.

Este entorno de programación posee dos capas:

Editor de diseño, en esta capa es posible agregar componentes (sensores, relojes, etc.) con los que se trabajarán, y visualizar cómo se verá la aplicación, de cara al usuario final. Este tipo de modelado se llama WYSIWYG (por sus siglas en inglés), lo que ves es lo que tienes. Este editor de diseño ayuda al desarrollador a visualizar cómo aparecerá el aplicativo. Por lo que, es una herramienta potente de cara al prototipado de aplicaciones [Patton et al., 2019].

Editor de bloques, en esta capa es donde se realiza la lógica de programación.

2.6.1.1. Tipos de bloques

App Inventor posee dos tipos de bloques:

Bloques incorporados, son aquellos que permiten las operaciones de uso común en otros lenguajes de programación. Tales como, operadores lógicos, operadores matemáticos, operadores de control de flujo, cadenas, booleanos, números, listas [Patton et al., 2019].

Bloques de componentes de abstracción, son tres: Las propiedades (controlan el estado del componente), los métodos (operan entradas y devuelven resultados), y los eventos (responden a cambios de estado o externalidades). Estos se usan para contestar a eventos del propio sistema, interactuar con componentes físicos de dicho sistema, y visualizar comportamientos de los componentes utilizados. Lo cual permite que el desarrollador se centre en cómo resolver el problema que tienen en mente y no en cómo es que funcionan los componentes que va a utilizar. Es decir, es un tipo de encapsulado, o caja negra, en la que el desarrollador solo toma componentes que requiere. Por ejemplo, el GPS, pero no necesita conocer cómo enlazar este GPS al entorno o cómo sincronizar los relojes. Sino, que solo debe arrastrar el componente GPS, para luego usar sus funciones [Patton et al., 2019].

2.6.1.2. Limitaciones

A continuación, se mostrará una lista de algunas de las limitaciones que App Inventor posee:

- Dificultad en la reutilización del código elaborado.
- Falta de optimización en uso de recursos.
- Es más difícil mantener el orden en la programación, a medida que se requiere más complejidad.

2.6.1.3. Beneficios

A continuación, se mostrará una lista de algunas de las ventajas que App Inventor posee:

- Facilidad y rapidez en el aprendizaje del entorno.
- Facilidad y rapidez para el prototipado de aplicaciones.
- Visualización en tiempo real de lo que se está programando en el dispositivo móvil.

3. Estado del Arte

3.1. Introducción

La localización para interiores basada en redes inalámbricas, y en particular en el estándar IEEE 802.11 es la línea de investigación en la que centraremos este trabajo. Aunque, no es el único enfoque que da solución al problema de localización en interiores, veremos porqué en la actualidad sigue siendo tan estudiado e implementado, y cómo ha ido desarrollándose a lo largo de las últimas dos décadas.

Antes de comenzar a explicar y analizar los principales estudios sobre localización en interiores que usan redes inalámbricas. Se expondrán algunos conceptos básicos, así como ciertos indicadores o criterios de rendimiento. Sin los cuales las posteriores críticas o apreciaciones carecerían de sustento.

Por ejemplo, la revisión de la literatura muestra varios tipos de expresiones utilizadas, a veces en forma de sinónimos, para referirse a la ubicación espacial. Entre ellas tenemos: Localización, localización de posición, geolocalización, y detección de localización [Farid et al., 2013].

La localización hace referencia al proceso de obtener la información de localización del cliente móvil con respecto a una serie de puntos de referencias en un espacio predefinido. Un sistema de posición, es un sistema orientado de tal manera, que estima la posición de un objeto [Farid et al., 2013].

3.2. Avances del indoor localization

LBS: Tipos y características

Según [Farid et al., 2013], los servicios basados en localización están compuestos de cinco elementos básicos, que son clasificados como:

- Aplicación de software.
- Red de comunicación.
- Proveedor de contenido.
- Dispositivo de posicionamiento.
- Usuario final con un dispositivo móvil.

Existen varios sistemas de navegación para interiores basados en: satélite, inercia (INS), sonido, óptica, ondas electromagnéticas, magnetismo terrestre. Para estos sistemas encontramos algunos criterios de rendimiento como son la precisión, la tasa de actualización de ubicación, la cobertura, la adaptabilidad, la escalabilidad y el equilibrio entre costo-complejidad [Farid et al., 2013].

A continuación, se muestran las ventajas y desventajas del uso de ondas electromagnéticas (OEM). En este caso del estándar IEEE 802.11. Con el propósito de justificar por qué esta tecnología ha sido seleccionada [Liu et al., 2007], [Farid et al., 2013].

Ventajas:

- Estandarización de la señal y facilidad de obtener la posición sin uso de hardware o software extra en el dispositivo móvil.
- Es un sistema que no requiere línea de vista (NLOS).
- Cuenta ya con infraestructura desplegada.
- Escalabilidad en infraestructura y número de dispositivos subscriptores.
- Robustez del sistema.
- Son sistemas de costo entre medio y bajo.
- Puede trabajar en dos o tres dimensiones.
- Puede trabajar con distintas técnicas y algoritmos.
- Funciona en sistemas híbridos, es decir combinando distintos tipos de mediciones.
- Posee una precisión que varía entre 0.2 a 10 metros, amplia gama de aplicaciones.
- Su complejidad varía entre baja y moderada.

Desventajas

- Cuando se requiere mayor precisión, se requiere de una mayor densidad de recolección de los datos RSSI.
- Multitrayecto debido a la presencia de objetos.
- La intensidad de la señal recolectada es afectada, de forma significativa, por el desvanecimiento.
- Posibles interferencias con otras aplicaciones a 2.4 GHz.
- La complejidad aumenta a medida que se requiere mayor precisión.
- Aplicaciones de máxima precisión requieren de sistemas híbridos.

Técnicas y algoritmos de localización

En las investigaciones revisadas se observan dos formas de desarrollar sistemas de localización. Aquellos que despliegan nueva infraestructura, y aquellos que usan la infraestructura existente. Dentro de estos dos enfoques se identifican tres técnicas de localización [Farid et al., 2013], [Wu et al., 2013], [Liu et al., 2007].

1. Proximidad o detección de proximidad
2. Triangulación.
3. Análisis de escenario.

A continuación, en la Figura 3.1., se muestra un esquema que resume las técnicas y algoritmos de localización. Luego, se procederá a definir y explicar cada término.

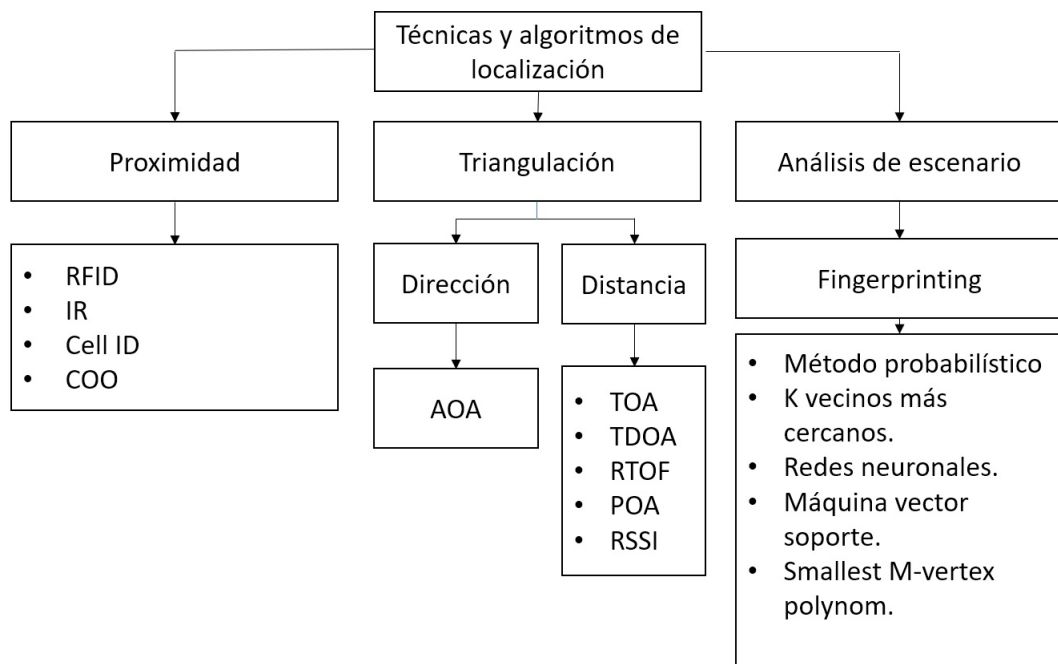


Figure 3.1.: Esquema de técnicas y algoritmos de localización

Proximidad Es un algoritmo que entrega la ubicación relativa de un dispositivo, basado en una densa red de antenas de posición conocida. Funciona de la siguiente manera, cuando el dispositivo móvil es detectado por una sola antena, se considera que este se encuentra ubicado en el sitio de la antena, cuando es detectado por más de una antena, la antena que proporcione la mayor potencia recibida indicará que se localiza en esa posición. Es un método simple, con rango limitado y está implementado en sistemas que utilizan:

- Identificación por radiofrecuencia (RFID).
- Infrarrojo (IR).
- Identificación de celda (Cell-ID).
- Celda de origen (COO).

Nótese que tanto el cell-ID como COO son tecnologías integradas a la red de telefonía móvil que utilizan la información que las estaciones base (BS) les proporcionan.

Triangulación Esta técnica usa las propiedades geométricas de los triángulos para estimar la posición de un objeto. Puede dividirse en sistemas basados en dirección y sistemas basados en distancia como se indica en [Farid et al., 2013], o puede dividirse en lateralización y angulación como refiere [Liu et al., 2007]. Ambos pares de términos indican lo mismo, por lo que pueden usarse indistintamente; sin embargo, para evitar equívocos, a partir de ahora, en el trabajo presente se utilizarán las terminologías: sistemas basados en dirección y sistemas basados en distancia. A continuación, se detallarán ambos tipos de sistemas de triangulación.

Sistemas basados en dirección Localizan un objeto calculando los ángulos relativos de múltiples puntos de referencia. En este tipo de triangulación tenemos al método basado en ángulo de llegada (AOA).

Método basado en ángulo o dirección de llegada (AOA o DOA):

En el AOA se trazan varias líneas en un ángulo determinado, desde las estaciones base de emisión hacia el dispositivo objetivo, las cuales se intersecarán en el punto objetivo. Cada estación base forma un radio circular entre ella misma y el objetivo móvil. Este método necesita de al menos dos puntos de referencia conocidos y dos ángulos medidos para estimar la ubicación, es decir usa una relación geométrica para encontrar la ubicación. Esta estimación usa una antena direccional o arreglos de antenas. Las ventajas que ofrece en distancias pequeñas son, el posicionamiento 2-D necesita solamente 2 focos, para el 3-D al menos 3 focos, y no necesita sincronización [Zafari et al., 2019].

Las desventajas incluyen, uso de bastante hardware complejo, degradación en la precisión de estimación si el objetivo se aleja de los focos de emisión, asimismo es afectado por multitrayecto y propagación de señales sin línea de vista (NLOS) [Liu et al., 2007] .

Sistemas basados en distancia Son los que utilizan el tiempo de llegada y propiedades de la señal, como la fase. Miden la distancia entre el emisor de señal y el dispositivo móvil receptor, para estimar así la posición [Farid et al., 2013], [Liu et al., 2007]. En este tipo de triangulación se tienen cinco métodos basados en tiempo.

Métodos basados en tiempo:

- Tiempo de llegada (TOA).
- Diferencia de tiempo de llegada (TDOA).
- Tiempo de vuelo de ida y vuelta (RTOF),
- Indicador de potencia de señal recibida (RSSI).
- Fase de la señal recibida (POA).

A continuación, se explicarán brevemente cada uno de los métodos anteriores.

TOA

Mide el tiempo que se demora la señal, desde el emisor hasta el dispositivo móvil. Luego, conociendo la velocidad de propagación de la señal ($3 \times 10^8 \frac{m}{s}$) se halla la distancia. En este método son necesarios al menos tres puntos de referencia establecidos. Además, se requiere sincronización precisa (emisor y receptor) y etiquetado de la señal de transmisión con un sello de tiempo, lo que aumenta el costo del sistema. Los factores que más disminuyen la precisión de este método son el ancho de banda de la señal y una tasa de muestreo baja. Aunque, estas distorsiones pueden ser compensadas con un ancho de banda mayor y técnicas de super-resolución [Zafari et al., 2019], [Farid et al., 2013], [Gu et al., 2019].

TDOA

Determina la posición relativa de un dispositivo móvil, al examinar la diferencia de tiempo de llegada de la señal desde el emisor a por lo menos tres de los dispositivos móviles, los cuales deben estar sincronizados compartiendo esta información [Farid et al., 2013].

RTOF

Mide el tiempo de propagación de la señal enviada y retornada al dispositivo móvil desde el emisor. Una vez llegada la señal al receptor, este responde al emisor, produciendo un retardo de entre 50 y 150 ms medido por dos relojes locales. Este retardo es responsable de la precisión en la triangulación. Resuelve hasta cierto punto el problema de sincronización del TOA, funcionando mejor en alcances largos y medios [Liu et al., 2007].

RSSI

Mide la potencia de la señal recibida por el dispositivo móvil y calcula la atenuación que sufre esta señal al alejarse del emisor, con el modelo de pérdidas en el espacio libre. Con la atenuación sufrida es posible determinar la distancia entre transmisor y receptor [Chintalapudi et al., 2010]. El reto aquí es encontrar un modelo de radiopropagación que mejor refleje el comportamiento del medio en que se despliega el sistema, además de lo inestable de la señal RSSI, por lo que es recomendable trabajar con el promedio de esta señal [Boonsriwai and Apavatjirut, 2013].

POA

Usa la fase de la portadora de la señal recibida para estimar la distancia entre transmisor y receptor. En este método el receptor asume que las señales recibidas son de forma sinusoidal pura, con igual frecuencia y compensación de fase cero. Para encontrar las fases de dichas señales en un punto específico se necesita un retardo de tránsito finito. Dicho retardo entre transmisor y receptor se define como una fracción de la longitud de onda de la señal. Asumiendo que los nodos transmisores están ubicados dentro de un espacio cúbico imaginario, entonces la distancia puede ser estimada del siguiente modo $D_i = \frac{c\phi_i}{2\pi f}$. Donde c es la velocidad de la luz, $0 < \phi_i < 2\pi$ la fracción de la longitud de onda y f la frecuencia de la señal $S_i(t) = \sin(2\pi f + \phi_i)$ [Liu et al., 2007]. Esto es válido solo si la longitud de onda de la señal transmitida es más larga que la diagonal del espacio cúbico delimitado por los nodos transmisores. Este enfoque requiere de línea de vista (LOS) para tener una precisión alta. Por lo que en interiores, donde hay mayor cantidad de obstáculos, presentará mayor error en la estimación de la posición. Aunque, al ser usado junto a métodos como RSS, TOA, TDOA mejora la precisión general de localización [Zafari et al., 2019], [Li et al., 2021].

Análisis de escenario Se refiere a algoritmos que primero recolectan características del escenario (fingerprints) donde se propaga la señal de RF, y luego estiman la localización del objeto asociando una medida nueva con la medida de potencia más parecida a las guardadas.

La primera fase del fingerprinting se denomina offline, esta es la recolección de coordenadas de localización etiquetadas y sus respectivos RSSI para los APs más próximos. La segunda, online, estima la posición de una nueva ubicación con referencia a los RSSI guardados [Liu et al., 2007]. Generalmente la mayoría de investigaciones en estos últimos veinte años se han dividido en dos categorías, basadas en fingerprinting y basadas en modelo o aproximación geométrica [Wu et al., 2013].

Existen al menos cinco algoritmos de posicionamiento para fingerprinting basados en aprendizaje automático (machine learnig) que se usan para estimar las posiciones [Liu et al., 2007]:

- Método probabilístico.
- Los K vecinos más cercanos.
- Redes neuronales.
- Máquinas de vector soporte (SVM)
- Smallest M-vertex polygon (SMP)

3.3. Análisis y apreciaciones finales

Luego de expuesta la literatura relevante en la investigación, se procederá a justificar la elección de una primera aproximación para resolver el problema de localización en espacios cerrados, planteado en la sec. 1.2. No solo en vistas del criterio de un sistema de baja complejidad y bajo costo, sino que esta decisión se desprende de los resultados revisados en estudios anteriores.

Primero, como concluye [Liu et al., 2012], no obstante la implementación de un sistema de localización en interiores que utilice un smartphone es aún novedosa, esta es crítica pues su implementación y mejora, llevará a surgimiento de nuevas e innovadoras aplicaciones basadas en localización, con la consecuente mejora en la calidad de vida de las personas.

Segundo, como se colige de [He and Chan, 2016], la localización basada en WiFi fingerprinting tradicional, ha acaparado la atención en la mayor parte de las investigaciones recientes y en las implementaciones a nivel industrial. Así también, nuevas técnicas avanzadas surgen dentro del WiFi fingerprinting, como la información de estado de canal (CSI), la experiencia de localización, la combinación de más sistemas con fingerprinting, haciendo uso de los sensores que poseen los smartphones, con el fin de obtener la máxima precisión. Aunque, algunas de estas mejoras de precisión conllevan un costo computacional mayor, pueden ser afrontadas por smartphones actuales, que han aumentado su potencia computacional en años recientes. Por lo que la aproximación en cuanto a la técnica de fingerprinting que se usará, es la que solo hará uso del RSSI.

Tercero, luego de revisar los resultados de las revisiones e implementaciones de WiFi fingerprinting y triangulación en, [Onkar et al., 2014], [Liu and Yang, 2011], [Liu et al., 2012], [Gómez and Pedraza, 2018], [Gu et al., 2019],[Obeidat et al., 2021] y [Boonsriwai and Apavatjirut, 2013]. Se ha observado que la precisión de estos sistemas varía entre 1 y 6 metros, siendo muy dependientes del buen funcionamiento de los APs en la etapa online y la cuidadosa recolección de datos en la etapa offline. Asimismo, se vio que combinando fingerprinting y trilateración es posible obtener alta precisión en la localización en 3 dimensiones de entre 1 y 4 metros. También, observando los resultados de [Liu et al., 2007], [Gerez et al., 2020], el enfoque de aprendizaje automático es el que mejor relación entre precisión, costo y complejidad presenta. Como se observa en el Cuadro 3.1.

Técnica	Precisión	Costo	Complejidad
RSSI	De Media a Alta	Medio	De Baja a Media
AOA	De Media a Alta	Alto	Alta
TOA	Alta	Alto	Alta
TDOA	Alta	Alto	Alta
RTOF	Alta	Alto	Alta
POA	De Media a Alta	De Medio a Alto	Alta

Table 3.1.: Comparación de costo, complejidad y precisión de los distintos sistemas basados en tiempo y en dirección

4. Diseño de la solución

En este capítulo se detalla el diseño de los sistemas de localización espacial implementados (determinísticos y probabilísticos). Para lo cual, primero se ha preseleccionado los puntos de referencia en un plano escalado. Luego, se han ubicado físicamente esos puntos. Además, se ha diseñado y validado una aplicación Android, con el fin de recolectar el RSSI. Por último, se han llevado a cabo dos campañas de mediciones. Una para el enfoque determinístico, y otra para el enfoque probabilístico. Esto con la finalidad de crear una base de datos.

La totalidad del diseño será validado dependiendo del error que se obtenga (RMSE). Es decir, aquel enfoque que genere un error menor a 10 metros. Se ha escogido este criterio, pues 10 metros es el error obtenido por el GPS, cuando es usado en interiores.

4.1. Selección de puntos de referencia

4.1.1. Ubicación de APs

Para esta parte del proyecto se han seleccionado los APs ubicados en la planta baja de la universidad Católica San Pablo, campus San Lázaro. La información de ubicación relativa así como la dirección MAC, modelo de equipo, marca de cada dispositivo fue solicitada al equipo de soporte de la universidad, quienes brindaron la información que se muestra en el Cuadro 4.1.

Además, se han añadido 2 APs más, que son repetidores como se muestran en el Cuadro 4.1., siendo estos AP 4.1 y AP 5.1.

AP	Ubicaciones	MAC	Potencia máxima Tx	Modelo
1	Pasillo Aula N-03	38:FF:36:09:EA:E8	26 dBm	Ruckus R500
2	Pasillo Aula N-09	38:FF:36:0C:9B:68	26 dBm	Ruckus R500
3	Frente Aula D-05	38:FF:36:09:DB:78	26 dBm	Ruckus R500
4	Columna D01	F0:3E:90:35:02:78	28 dBm	Ruckus R600
4.1	Puerta Aula D01	F0:3E:90:75:02:78	-	-
5	Auditorio JPII	F0:3E:90:35:1C:28	28 dBm	Ruckus R600
5.1	Entrada JPII	38:FF36:49:db:78	-	-
6	Sala de datos	38:FF:36:06:1B:58	26 dBm	Ruckus T300

Cuadro 4.1.: Ubicación y características de los AP de referencia

Luego de obtenida esta información se procedió a colocar en una tabla las coordenadas de los AP en la escala del mapa de ubicación de la planta baja y seleccionar puntos de las ubicaciones a estimar en la planta baja del edificio Duhamel, como se muestra en el Cuadro 4.2 y la Figura 4.1. respectivamente. Cabe decir que, las coordenadas se han escalado según la relación: $R = 11S$, donde R : Es la distancia real del plano (m) y S : Es la distancia escalada (cm).

Ahora, en el Cuadro 4.2. que viene a continuación se muestran las coordenadas escaladas de los AP preseleccionados, y los puntos seleccionados a estimar. Cabe mencionar, que a priori, se consideraron 12 puntos; sin embargo, luego de terminada la toma de datos, se observó que solo 6 de ellos presentaban al menos 3 AP visibles. Por lo que en el cuadro solo se considerarán 6 puntos a estimar.

AP- Coordenadas	X	Y	Puntos -Coordenadas	X	Y
AP3	3.3	3.7	Punto 1	2.6	2
AP 4	6	7.1	Punto 2	3	2.6
AP 4.1	5.5	6	Punto 3	3.7	3.7
AP 5	2.7	1	Punto 6	3	2.6
AP 5.1	2.4	1.9	Punto 7	5.5	5.9
-	-	-	Punto 12	3.5	1.9

Cuadro 4.2.: Coordenadas de ubicación de los APs y puntos a estimar

4.2. Ubicación de coordenadas

4.2.1. Plano para método con aproximaciones geométricas

En esta sección se solicitó un plano de la planta baja de la UCSP, campus San Lázaro. En el plano del edificio Duhamel, los círculos verdes indican los AP de referencia y las estrellas azules son los puntos a estimar. Las estrellas rojas son las 3 mejores estimaciones usando triangulación. Para ver más comparaciones revisar las tablas de la sección de resultados.

En la Figuras 4.1. se muestra la sección del plano obtenido.

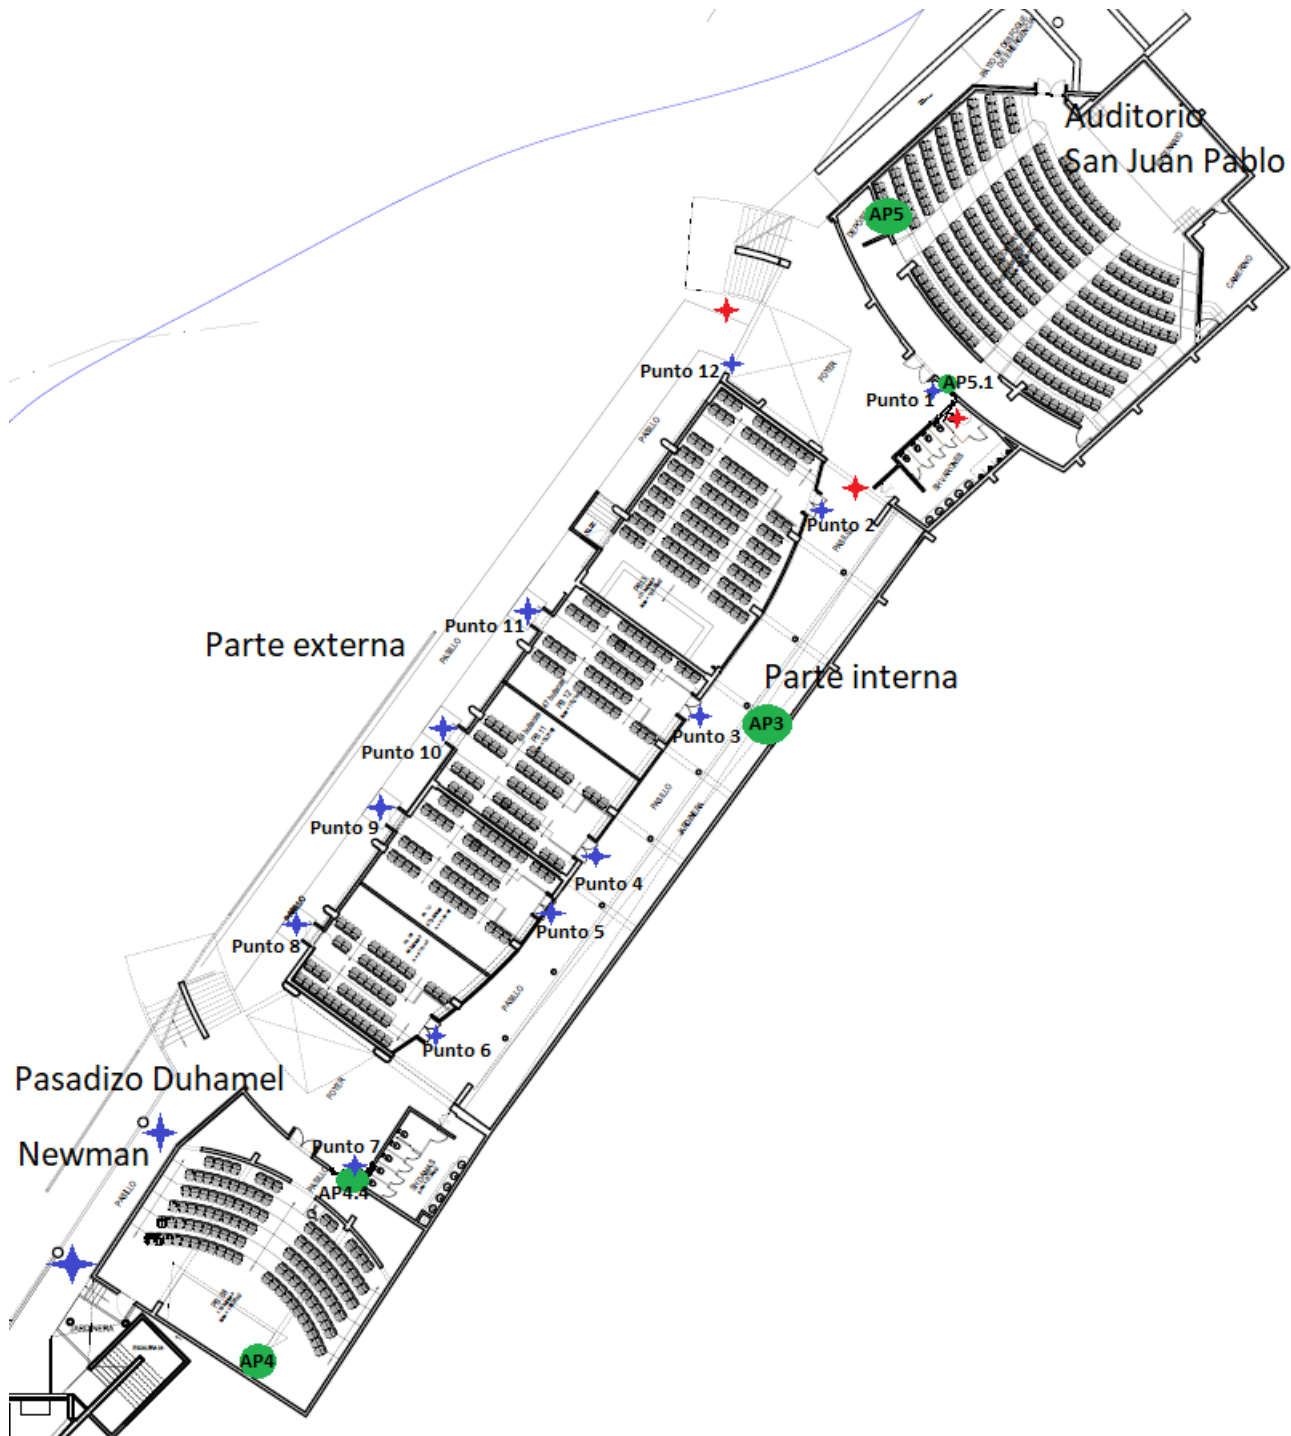


Figura 4.1.: Planta baja edificio Duhamel mejores estimaciones (en rojo) puntos 1, 2, 12. Las posiciones de los AP (en verde), y los puntos de referencia (en azul).

4.2.2. Plano para aprendizaje automático




Figura 4.2.: En amarillo se sitúan los puntos de referencia donde se realizaron las mediciones “off-line” de la potencia recibida (RSSI). Para evaluar los métodos de aprendizaje máquina

En el plano de la planta baja del edificio Duhamel se trazó una grilla con 100 puntos, como se muestra en la Figura 4.2. Esto se hizo para obtener una base de datos de cara implementar el enfoque de aprendizaje automático.

4.3. Herramienta de recolección de datos

Una vez establecidos los AP de referencia se procedió a desarrollar la aplicación de recolección de RSSI. Esta se llevó a cabo en un lenguaje de programación por bloques en la plataforma App Inventor. La aplicación lee y almacena en un fichero la potencia RSSI, la dirección MAC y el nombre SSID de la señal, cada vez que se coloca el nombre del archivo que se quiera crear y se presiona el botón “Mostrar RSSI-WiFi disponibles”, dentro de la aplicación.

El desarrollo de la aplicación ha conestado de 4 grupos de bloques como se detalla a continuación:

El bloque de inicialización y alerta, se muestra en la Figura 4.3. Aquí se inicializa la pantalla de la aplicación, para luego llamar a la función 'Taifun', que viene a ser una librería para usar bloques de 'WiFi' en App Inventor. Esto forma parte de la anidación de una función de alerta que verifica y muestra por pantalla, si el WiFi está habilitado o no.

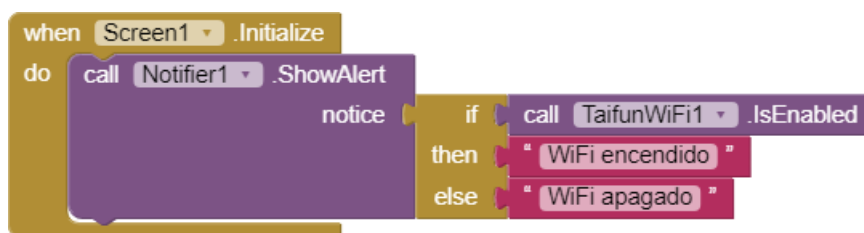


Figura 4.3.: Inicio de pantalla y alerta de habilitación WiFi

En la Figura 4.4. se aprecia el bloque de activación de la app, que funciona como condición, en el que, cuando se presione 'Mostrar RSSI-WiFi disponibles' llamará a la función Taifun para buscar y leer todas las redes disponibles. A continuación, saldrá por pantalla el texto, 'buscando redes disponibles'.



Figura 4.4.: Botón de activación de la app y búsqueda de redes disponibles

El bloque de impresión en pantalla de los resultados requeridos, se muestra en la Figura 4.5. este es un proceso para mostrar por pantalla el SSID, el RSSI y la MAC asociados a su respectiva red, actualizándose cada vez que se presione el botón de 'Mostrar RSSI-WiFi disponibles'.




Figura 4.5.: Bloque que construye la impresión en pantalla de las redes leídas y sus respectivas características

El bloque de obtención de parámetros requeridos, en la Figura 4.6., muestra la llamada a la función 'Taifun'. Cuando las redes están disponibles, obtiene la lista de SSID, RSSI, BSSID y el mejor SSID. Luego, crea ficheros '.CSV' con el nombre que se le pone antes de capturar los datos, almacena el SSID, MAC y RSSI en el smartphone, cada vez que se presione 'Mostrar RSSI-WiFi disponibles' y coloque nombre del archivo se añadirá la nueva información al mismo fichero.

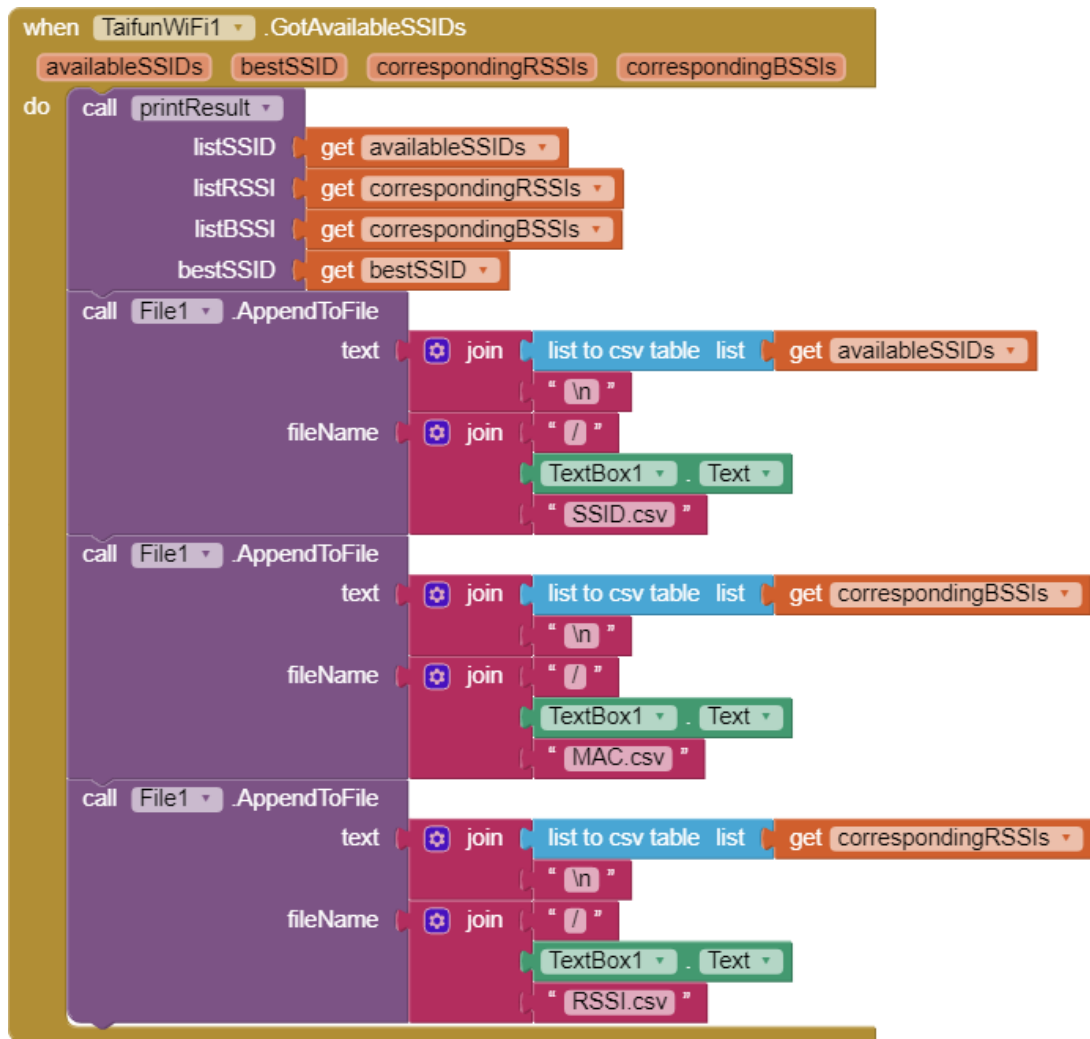


Figura 4.6.: Bloque de obtención de los parámetros requeridos y de escritura de ficheros, donde se guardan los datos de las redes

4.3.1. Validación de la aplicación propia

Para instalar la aplicación se utilizó un smartphone de la marca motorola modelo XT1032 con Android versión 5.1, con 2 GB de memoria RAM y 8GB de almacenamiento. Para comprobar que la aplicación funcionaba correctamente, se compararon los valores de esta con los de la aplicación “WiFi Analyzer” (una app especializada en la gestión de redes inalámbricas), que se encuentra disponible en la tienda Playstore. En la Figura 4.7. se puede apreciar la validación de la aplicación propia versus WiFi Analyzer. Para esto se capturaron 20 muestras de RSSI cada 0.5 m del AP, hasta completar 4 m. Luego, se obtuvo el promedio de dichas muestras en

cada punto y se las graficó. La aplicación propia en el eje X vs WiFi Analyzer, en el eje Y. Dando como resultado una línea casi recta. Como se puede ver en la Figura 4.7. existe una casi total concordancia entre las mediciones realizadas con ambas aplicaciones. Validando, por tanto, las mediciones de RSSI que serán realizadas por la aplicación propia.




Figura 4.7.: Validación de App propia vs WiFi Analyzer

En la Figura 4.8. se puede observar el funcionamiento de la aplicación.

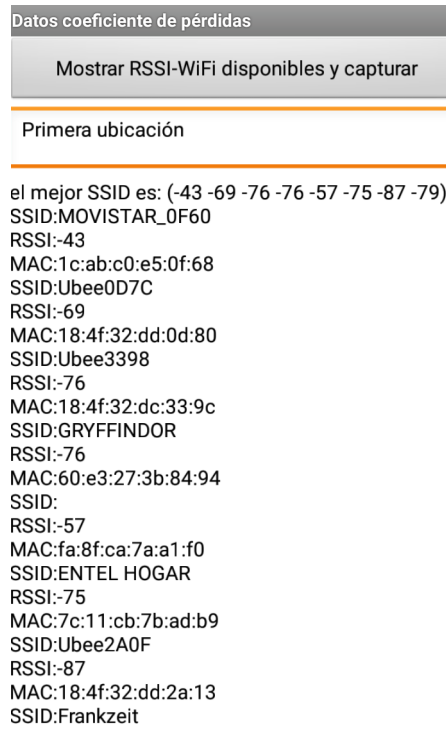


Figura 4.8.: Figura que muestra una captura de pantalla con la aplicación propia, en funcionamiento

4.4. Campaña de mediciones y generación de la base de datos

4.4.1. Primera campaña de mediciones

Al momento de realizar la recolección de muestras para la base de datos 1, se encontró en los datos almacenados muchas más redes que las pre-establecidas. Desde AP redundantes, AP de otros pisos, hasta transmisiones de smartphones e impresoras. Por tanto, se procedió a eliminar las mediciones de dichos dispositivos (utilizando la dirección MAC como discriminante)

En el edificio Newman solo se encontró 2 APs de referencia, por lo que a pesar de que a priori se pensaba realizar los experimentos allí, esta posibilidad se tornó inviable.

En esta campaña de mediciones se marcaron 12 puntos, cómo se muestra en la Figura 4.1. (plano para aproximación geométrica), y está orientada al enfoque de trilateración. Aquí se tomaron de entre 2 a 6 muestras por punto. Los APs de referencia tomados para este experimento se detallan en el Cuadro 4.2. Además, tanto los materiales usados en los experimentos como sus especificaciones técnicas, se listan en el anexo B.

4.4.2. Segunda campaña de mediciones

Para la creación de la segunda base de datos se ha conformado una grilla de densidad igual a 100 puntos. En cada punto se han tomado 20 muestras. Donde, cada muestra crea un fichero que asocia, el nombre de red, la dirección MAC, y el RSSI. Primero, se marcó una 'X' en cada punto establecido, luego en ausencia de gente se procedió a realizar la campaña de mediciones, al promedia las 21:15 horas, hasta las 23 horas. El periodo de tiempo utilizado para localizar las coordenadas en el edificio Duhamen fue, desde las 18:00 hasta las 21:00 horas.

Con la campaña de mediciones hecha, se han creado 2 base de datos. Una con 14 entradas, y otra con 16. Las 2 bases de datos tienen la forma de las siguientes matrices 14x2000 y 16x2000 para las entradas. Para las etiquetas la forma es de 2x2000, estas vienen a ser las coordenadas de los 100 puntos, ver el Cuadro 4.3. y el Cuadro 4.4.

APs	Punto 1	Punto 2	...	Punto 100
38:ff:36:06:13:98	$R_{1,1} \dots R_{1,20}$	$R_{1,21} \dots x_{1,40}$...	$R_{1,1981} \dots R_{1,2000}$
38:ff:36:06:1b:58	$R_{2,1} \dots R_{2,20}$	$R_{2,21} \dots x_{2,40}$...	$R_{2,1981} \dots R_{2,2000}$
38:ff:36:09:db:78	$R_{3,1} \dots R_{3,20}$	$R_{3,21} \dots x_{3,40}$...	$R_{3,1981} \dots R_{3,2000}$
38:ff:36:0c:71:08	$R_{4,1} \dots R_{4,20}$	$R_{4,21} \dots x_{4,40}$...	$R_{4,1981} \dots R_{4,2000}$
38:ff:36:46:13:98	$R_{5,1} \dots R_{5,20}$	$R_{5,21} \dots x_{5,40}$...	$R_{5,1981} \dots R_{5,2000}$
38:ff:36:46:1b:58	$R_{6,1} \dots R_{6,20}$	$R_{6,21} \dots x_{6,40}$...	$R_{6,1981} \dots R_{6,2000}$
38:ff:36:49:db:78	$R_{7,1} \dots R_{7,20}$	$R_{7,21} \dots x_{7,40}$...	$R_{7,1981} \dots R_{7,2000}$
38:ff:36:4c:71:08	$R_{8,1} \dots R_{8,20}$	$R_{8,21} \dots x_{8,40}$...	$R_{8,1981} \dots R_{8,2000}$
74:3e:2b:01:40:08	$R_{9,1} \dots R_{9,20}$	$R_{9,21} \dots x_{9,40}$...	$R_{9,1981} \dots R_{9,2000}$
74:3e:2b:01:6b:d8	$R_{10,1} \dots R_{10,20}$	$R_{10,21} \dots x_{10,40}$...	$R_{10,1981} \dots R_{10,2000}$
74:3e:2b:41:40:08	$R_{11,1} \dots R_{11,20}$	$R_{11,21} \dots x_{11,40}$...	$R_{11,1981} \dots R_{11,2000}$
74:3e:2b:41:6b:d8	$R_{12,1} \dots R_{12,20}$	$R_{12,21} \dots x_{12,40}$...	$R_{12,1981} \dots R_{12,2000}$
f0:3e:90:35:02:78	$R_{13,1} \dots R_{13,20}$	$R_{13,21} \dots x_{13,40}$...	$R_{13,1981} \dots R_{13,2000}$
f0:3e:90:75:02:78	$R_{14,1} \dots R_{14,20}$	$R_{14,21} \dots x_{14,40}$...	$R_{14,1981} \dots R_{14,2000}$

Cuadro 4.3.: Estructura de la base de datos con 14 AP, 20 muestras por punto, para los 100 puntos seleccionados. Donde, R es el RSSI.

4.4 Campaña de mediciones y generación de la base de datos

Coordenadas	Punto 1	Punto 2	...	Punto 100
X	$x_{1,1} \cdot \cdot \cdot x_{1,20}$	$x_{1,21} \cdot \cdot \cdot x_{1,40}$...	$x_{1,1981} \cdot \cdot \cdot x_{1,2000}$
Y	$y_{2,1} \cdot \cdot \cdot y_{2,20}$	$y_{2,21} \cdot \cdot \cdot y_{2,40}$...	$y_{2,1981} \cdot \cdot \cdot y_{2,2000}$

Cuadro 4.4.: Estructura de etiquetas de la base de datos para ML 14 entradas.

Donde, X e Y representan las coordenadas de cada punto de referencia, que deben repetirse el mismo número de veces que muestras haya por punto.

5. Resultados

En este capítulo se presentarán los resultados de las mediciones y de los cálculos realizados en varias etapas del presente trabajo.

En particular, se mostrarán, en una primera sección, los resultados de la estimación del canal. Utilizando el modelo $Y = -10n \log_{10}(\frac{0,125}{4\pi X}) + C$.

En estos resultados se muestran los valores estimados de n y C , que se alcanzan en los distintos experimentos. Estos valores sirven para calcular las distancias entre T_x y R_x .

En una segunda sección se listan los resultados de la estimación de la posición utilizando técnicas de: trilateración y aprendizaje automático.

En la tercera sección de este capítulo se comparan los resultados obtenidos, utilizando el error (RMSE) como métrica de evaluación.

Finalmente, el capítulo concluye con un análisis del costo computacional de las técnicas de aprendizaje automático (redes neuronales) y una discusión general de los diversos métodos empleados.

5.1. Estimación del canal

5.1.1. Experimento 1: Cálculo de n y C

Para este experimento se procedió en primer lugar a ubicar los APs 1, 2, 3, 4, 5. Luego, se empezó a almacenar las lecturas de RSSI a cada metro de distancia en un rango de entre 1 y 15 metros, dependiendo de las facilidades de medición. Para asegurar que la distancia predefinida para la prueba fuera la correcta se utilizó un medidor láser de distancia de la marca HoldPeak, modelo HP-5060. El cual trabaja en un rango de 0.3 a 60 metros con 0.15 mm de error por cada metro, ver Anexo B.

- En los AP 3, 4 y 5 se tomó una muestra por metro.
- En AP1 se tomaron cuatro por metro, se halló el promedio de las mismas.
- En AP2 no se tomaron muestras, pues la zona era muy transitada.
- En AP6 no se tomaron muestras, pues no se lo pudo ubicar.

A continuación, en el Cuadro 5.1. se muestra las mediciones para cada AP. Además, las entradas con el símbolo de guion '-', indican que la medición no fue posible de realizar. Esto puede deberse a que en el espacio físico se encontraba una pared, o se perdía de vista.

Distancia (m)	AP1 (dBm)	AP3 (dBm)	AP4 (dBm)	AP5 (dBm)
1	-35.3	-30	-28	-29
2	-34	-38	-31	-36
3	-35	-35	-30	-44
4	-42	-47	-34	-45
5	-42	-	-36	-47
6	-42	-	-39	-48
7	-42	-	-	-48
8	-42	-	-	-48
9	-47	-	-	-49
10	-52	-	-	-52
11	-52	-	-	-50
12	-52	-	-	-49
13	-52	-	-	-
14	-52	-	-	-
15	-52	-	-	-

Cuadro 5.1.: Lecturas RSSI versus distancia para los AP

En la Figura 5.1. se muestra la gráfica del comportamiento del RSSI en los diferentes APs de referencia. Cabe mencionar que el AP más difícil de medir fue AP1 debido a lo inestable de la señal, que daba como resultado datos atípicos, o constantes a lo largo de varios metros.

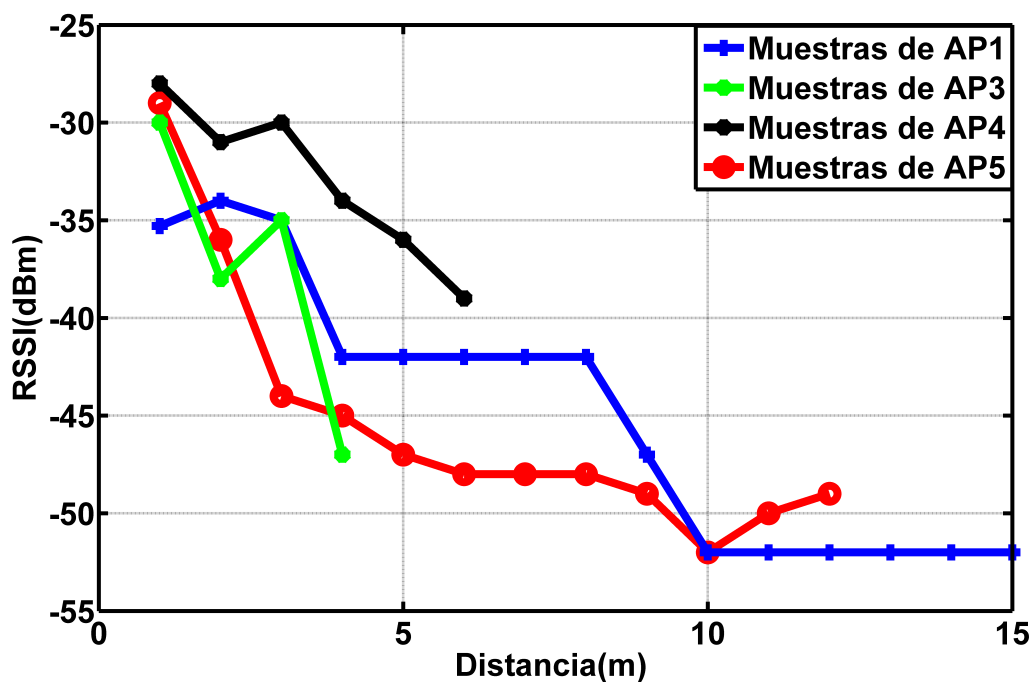


Figura 5.1.: Comportamiento del RSSI para los distintos APs a distintas distancias. Para condiciones con línea de vista (LOS)

Las condiciones en las que se tomaron las muestras de los APs fueron:

- AP1, zona muy transitada inestabilidad de la señal y línea de vista con el AP2, es el pasadizo en el edificio Newman.
- AP3, zona no transitada dentro del aula D-01, no se tomaron más muestras pues había obstáculos que no permitían la medición de la distancia, imposibilitando la LOS.
- AP4, zona medianamente transitada, debajo del AP hay vegetación, es un pasadizo en condiciones de LOS.
- AP5, zona no transitada dentro del auditorio Juan Pablo II. Lugar amplio, la señal se comportaba como en espacio libre, además de no tener casi interferencias.

Luego, con los datos del Cuadro 5.1. se calcularon los exponentes de pérdida y se elaboró una tabla, ver Cuadro 5.2. Donde, se compara el exponente de pérdidas promedio hallado para cada muestra, versus el exponente de pérdida hallado con la función de estimación como se muestra en la Figura 5.2.

A continuación, se explica cómo se obtuvo el n promedio y $el n$ estimado:

- n promedio: Para cada muestra, conociendo la distancia y asumiendo condición de espacio libre, utilizando la ecuación (2.3) se ha hallado su respectivo coeficiente para cada distancia. Luego de obtenido el coeficiente n de cada muestra se las promedió, esto fue hecho para todos los AP.

- n estimado: Se ajustó una curva (utilizando el método de minimización de error cuadrático) con los datos y definiendo la función $Y = F(X)$ entonces $Y = -10n \log_{10}\left(\frac{0,125}{4\pi X}\right) + C$.

Al comparar ambos resultados de coeficientes de pérdidas de se observa que el coeficiente “ n ” varía para cada AP y para cada método situándose en un rango de 1.33 a 1.66 para el método del promedio y en un rango de 1.29 a 2.29 para la estimación logarítmica, ver Cuadro 5.2.

Punto	n promedio	n estimado	C (dB)	RMSE	Condición
AP1	1.64	1.83	-48.56	2.97	LOS
AP3	1.59	2.29	-52.66	4.79	LOS
AP4	1.33	1.29	-39.85	1.95	LOS
AP5	1.66	1.90	-50.82	2.13	LOS
Promedio	1.55	1.83	-47.97	2.96	

Cuadro 5.2.: Comparación de exponente de pérdidas (n), promedio y estimado


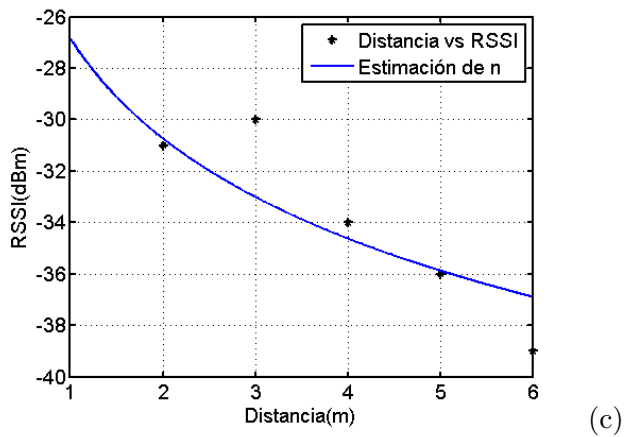
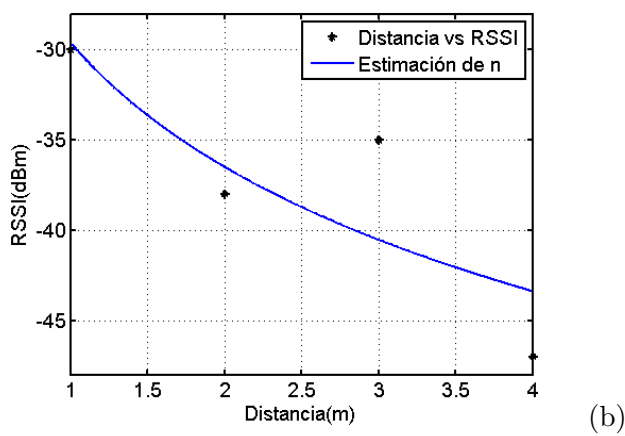
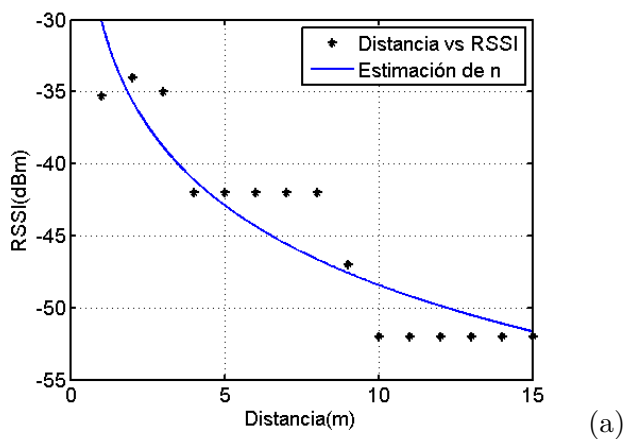


Figura 5.2.: Mediciones de RSSI y curva estimada para diversos APs, a) AP1, b) AP3, c) AP4, d) AP5

5.1.2. Experimento 2: Cálculo de n y C

En el segundo experimento se escogió solo al AP3 y se procedió en las siguientes condiciones:

- Primero, se han tomado 3 escenarios en la zona del AP3, tráfico alto, tráfico medio, tráfico bajo.
- Luego, para cada escenario, se tomaron 25 muestras cada 0.5 metros en un total de 6 metros. Haciendo un total de 300 muestras. Las cuales se observan en la Figura 5.3. para los tres escenarios indicados.
- Para finalizar, se procesaron las muestras calculando el promedio y la varianza de las muestras para cada distancia.

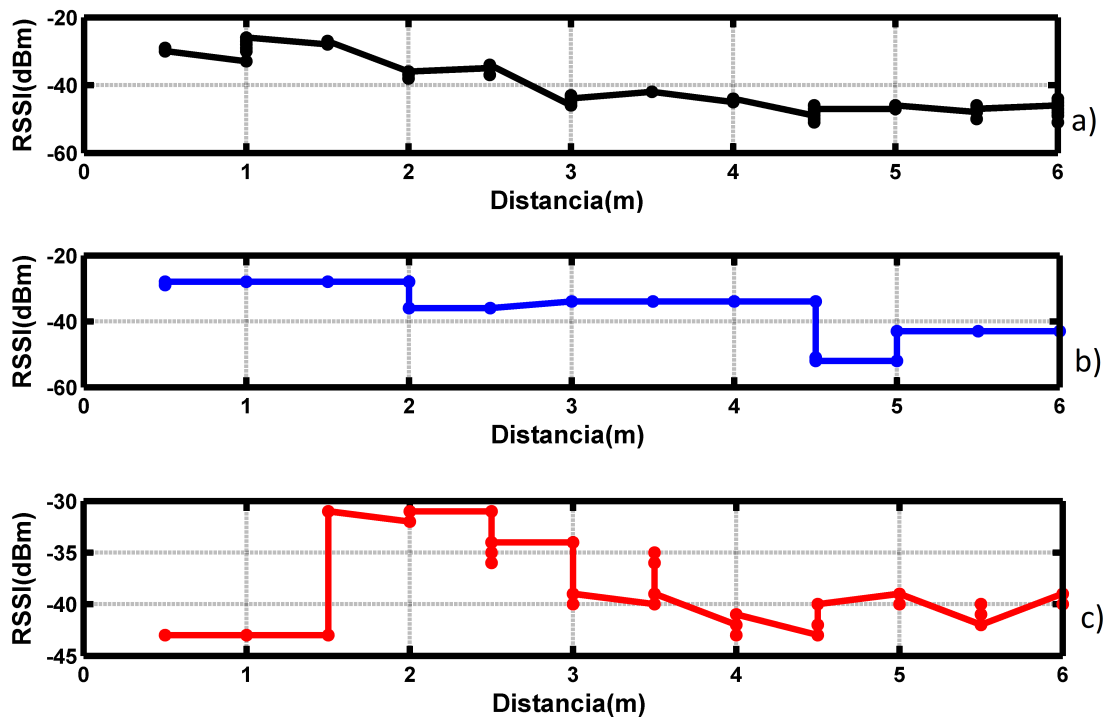


Figura 5.3.: 25 muestras por cada 0.5m para distintos escenarios, a) Tráfico alto, b) Tráfico bajo, c) Tráfico medio

Se graficó también el promedio de las muestras, como se puede observar en la Figura 5.4., junto a la variación en cada punto. Se puede ver que, el escenario de tráfico bajo presenta variaciones muy altas a una distancia de 3 metros y, el escenario de tráfico medio presenta variaciones muy altas a una distancia de 1.5 metros.


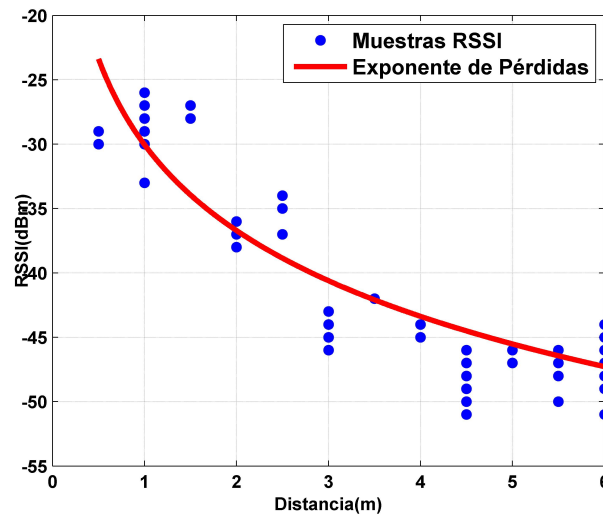
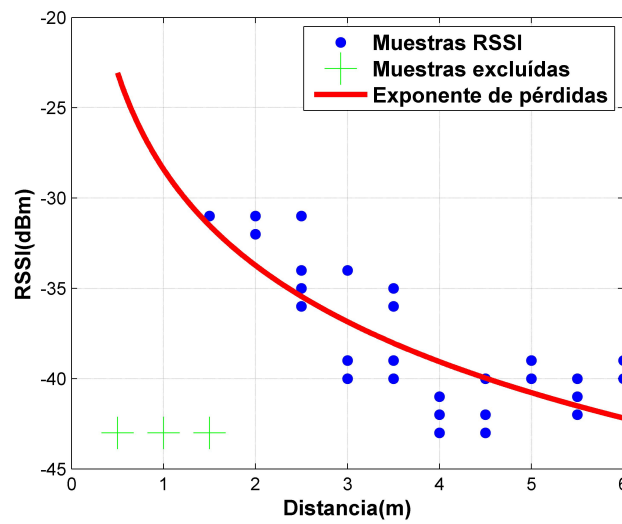


Figura 5.4.: Promedio y varianza de las 25 muestras para distintos escenarios, a) Tráfico alto, b) Tráfico bajo, c) Tráfico medio

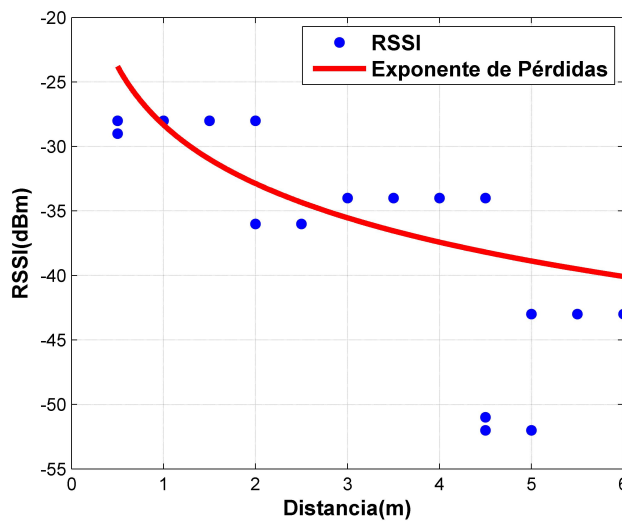
De los datos obtenidos a partir de las muestras se ha generado la estimación del canal. Utilizando el proceso que se ha indicado previamente (Sección 5.1.). En la Figura 5.5. se puede observar dichas estimaciones de canal, para cada escenario.



(a)



(b)



(c)

Figura 5.5.: Estimación de canal para diversos escenarios, a) Tráfico alto, b) Tráfico medio, c) Tráfico Bajo

El Cuadro 5.3. resume los resultados de las estimaciones del coeficiente n y C , para los escenarios de tráfico alto, medio, y bajo.

Escenario	n	C (dB)	RMSE
Tráfico bajo	1.51	-43.55	3.58
Tráfico medio	1.59	-45.46	2.35
Tráfico alto	2.21	-52.36	3.36

Cuadro 5.3.: Coeficiente estimado en diversos escenarios

Podemos ver que a pesar que la distancia no ha cambiado, los valores fluctúan cuando tenemos mayor o menor cantidad de personas circulando en un ambiente. Esto se puede apreciar también en los distintos valores estimados de n y C para las mismas distancias. Esto, sin lugar a dudas, pone un reto para la estimación de la distancia en todos los sistemas de posicionamiento, que utilizan modelos de canal de este tipo.

Asimismo, el menor error obtenido es en el escenario de tráfico medio. Luego de este experimento se puede ver que las condiciones del ambiente, y en particular el de la cantidad de personas circulando (tráfico) afectan los resultados obtenidos. Por lo que, deben ser tomados en consideración para mejorar las estimaciones.

Cabe aclarar que, en el escenario de ' Tráfico medio ', se ha excluido los datos de 0.5m, 1m y 1.5m con -43dBm. De cara a realizar la estimación de canal, ya que estos datos impedían la regresión. Como se observa en las muestras de color verde, en la Figura 5.5.

5.2. Técnicas de estimación de la posición

5.2.1. Experimento 3: Trilateración en distintos escenarios

Se seleccionaron puntos en el edificio Duhamel, se recolectó el RSSI en dichos puntos y se procedió comparar los resultados de trilateración para 3 tipos diferentes de estimación de canal, espacio libre, espacio libre más 10 dB en AP en condición NLOS, estimación de regresión logarítmica y estimación de regresión logarítmica más 10 dB en APs en condición NLOS, obteniendo los resultados que se muestran en el Cuadro 5.4. y en el Cuadro 5.5.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	-96.69	162.91	-125.29	140.91
Punto 1	28.6	22	-127.71	204.27	-156.31	182.27
Punto 2	33	28.6	-32.67	95.04	-65.67	66.44
Punto 2	33	28.6	-32.89	95.15	-65.89	66.55
Punto 3	40.7	40.7	-30.91	95.59	-71.61	54.89
Punto 7	60.5	64.9	138.16	-41.91	77.66	-106.81
Punto 7	60.5	64.9	138.16	-41.91	77.66	-106.81
Punto 12	38.5	20.9	64.57	-35.20	26.07	-56.10
Punto 12	38.5	20.9	60.39	-7.37	21.89	-28.27
RMSE					86.77	100.94

Cuadro 5.4.: Posiciones (X, Y) y la estimación de su posición (Xe, Ye) utilizando trilateración, se indica el error absoluto en condición de espacio libre con $n=2$, $C=-40dBm$

El Cuadro 5.5. muestra los resultados del mismo experimento, pero adicionando 10 dB al router AP 5.1 y Ap3 en el Punto 12 y 10dB al AP3 en el Punto 7, porque se conoce que hay presencia de obstáculos. Y comparando el Cuadro 5.4. y el Cuadro 5.5. se observa una reducción del error absoluto, en el Cuadro 5.5. respecto al Cuadro 5.4. Sin embargo, esta magnitud de error no cumple, aún, con los objetivos fijados en el presente trabajo.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y(m)
Punto 1	28.6	22	25.74	24.97	-2.86	2.97
Punto 1	28.6	22	26.73	30.47	-1.87	8.47
Punto 2	33	28.6	28.71	25.74	-4.29	-2.86
Punto 2	33	28.6	25.60	25.85	-4.4	-2.75
Punto 3	40.7	40.7	30.58	26.4	-10.12	-14.3
Punto 7	60.5	64.9	89.21	29.26	28.71	-35.64
Punto 7	60.5	64.9	89.21	29.26	28.71	-35.64
Punto 12	38.5	20.9	39.71	13.53	1.21	-7.37
Punto 12	38.5	20.9	39.27	16.39	0.77	-4.51
RMSE					14.20	17.99

Cuadro 5.5.: Trilateración y error de estimación en condición de espacio libre+10 dB en AP5 con $n=2$, $C=-40dBm$

El Cuadro 5.6. muestra los resultados en el cálculo de la posición luego de modelar el canal con una regresión logarítmica. Hallando el exponente de pérdidas, $n=2.21$ (indicando condición NLOS en interiores), y $C=-52.36dB$. La estimación mejora en comparación con el modelo de canal descrito en el Cuadro 5.4. Sin embargo, tener

conocimiento del canal (obstáculos) es una mejor aproximación para la posición (note que el error es menor en el Cuadro 5.5.).

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	39.93	26.29	11.33	4.29
Punto 1	28.6	22	38.5	27.5	9.90	5.50
Punto 2	33	28.6	42.9	24.75	9.90	-3.85
Punto 2	33	28.6	43.45	27.94	10.45	-0.66
Punto 3	40.7	40.7	43.45	24.75	2.75	-15.95
Punto 7	60.5	64.9	111.32	8.47	50.82	-56.43
Punto 7	60.5	64.9	111.32	8.47	50.82	-56.43
Punto 12	38.5	20.9	50.16	21.01	11.66	0.11
Punto 12	38.5	20.9	49.39	21.78	10.89	0.88
RMSE					25.42	27.26

Cuadro 5.6.: Trilateración y estimación de error, estimación de curva con $n=2.21$, $C=-52.36$ dBm

El Cuadro 5.7. muestra los resultados luego de aumentar 10 dB a los APs NLOS. Para compensar, pérdidas por paredes. Con el mismo modelamiento del Cuadro 5.5., es decir $n=2.21$ y $C=-52.36$. Aunque, a priori, esta compensación debía disminuir el error, se observa que este aumenta. No necesariamente que no exista línea de vista no indica una atenuación importante en el canal. Esto se refleja en que el error no disminuye comparado con el Cuadro 5.5. Esto puede deberse a la naturaleza de multitrayecto de las señales en NLOS.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	47.19	22.66	18.59	0.66
Punto 1	28.6	22	47.08	22.92	18.48	0.88
Punto 2	33	28.6	47.19	22.77	14.19	-5.83
Punto 2	33	28.6	47.30	22.77	14.30	-5.83
Punto 3	40.7	40.7	47.19	22.77	6.49	-17.93
Punto 7	60.5	64.9	111.32	-8.36	50.82	-73.26
Punto 7	60.5	64.9	111.32	-8.36	50.82	-73.26
Punto 12	38.5	20.9	50.93	20.68	12.43	-0.22
Punto 12	38.5	20.9	58.96	16.94	20.46	-3.96
RMSE					27.63	35.18

Cuadro 5.7.: Trilateración y estimación de error, estimación de curva +10dB con $n=2.21$, $C=-52.36$ dBm

El Cuadro 5.8. muestra el resultado para los mismos puntos anteriores, pero a partir del canal estimado en el experimento 1. Donde, el coeficiente de pérdidas $n = 1,83$ y

la constante $C = -47,97dBm$ han sido obtenidas promediando las n y C del Cuadro 5.2. Esto con el fin de ir comparando distintos modelos de canal y así encontrar el modelo con mejor desempeño.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	-20.35	55.99	-48.95	33.99
Punto 1	28.6	22	-39.27	66.11	-67.87	44.11
Punto 2	33	28.6	14.74	38.94	-18.26	10.34
Punto 2	33	28.6	14.63	38.94	-18.37	10.34
Punto 3	40.7	40.7	14.96	38.94	-25.74	-1.76
Punto 7	60.5	64.9	126.5	-21.34	66	-86.24
Punto 7	60.5	64.9	126.5	-21.34	66	-86.24
Punto 12	38.5	20.9	31.9	10.67	-6.6	-10.23
Punto 12	38.5	20.9	58.96	17.05	20.46	-3.85
RMSE					44.43	45.10

Cuadro 5.8.: Trilateración y error, estimación de curva con $n=1.83$, $C=-48dBm$

El Cuadro 5.9. muestra los resultados con los mismo n y C del Cuadro 5.8., pero esta vez se aumenta 10dB a los APs NLOS. Asumiendo que en las condiciones NLOS habrá mayores pérdidas (debido a la presencia de obstáculos). En este caso, se corrobora que al compensar con 10dB los APs NLOS, el error disminuye respecto al Cuadro 5.8. Podemos apreciar que el error disminuye cuando se considera mayor atenuación en NLOs. Sin embargo, el error observado aún es significativo para aplicaciones de LBS (en interiores).

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	43.89	23.76	15.29	1.76
Punto 1	28.6	22	43.34	24.86	14.74	2.86
Punto 2	33	28.6	44.99	23.76	11.99	-4.84
Punto 2	33	28.6	44.99	23.76	11.99	-4.84
Punto 3	40.7	40.7	45.32	23.87	4.62	-16.83
Punto7	60.5	64.9	75.13	15.40	14.63	-49.5
Punto 7	60.5	64.9	75.13	15.40	14.63	-49.5
Punto 12	38.5	20.9	69.63	8.69	31.13	-12.21
Punto 12	38.5	20.9	62.92	14.96	24.42	-5.94
RMSE					17.28	24.55

Cuadro 5.9.: Trilateración y error, estimación de curva + 10dB con $n=1.83$, $C=-48dBm$

A continuación, se quiere evaluar los mejores desempeños de la técnica de trilateración utilizando las mediciones que mostraron menor error (contaban con LOS).

Estas serán utilizadas para determinar el error que se puede alcanzar en la estimación de la posición, utilizando trilateración en buenas condiciones. Los puntos 1, 2 y 7, son los que mejores estimaciones presentan. Por lo que, se tomaron más muestras por punto para comparar cómo varía la estimación en esos mismos puntos.

Solo se estimará la localización con:

- $n=2.21$ y $C=-52.36$ dBm
- Espacio libre + 10 dB en los AP en condición NLOS

Ahora se mostrarán los resultados de los puntos del experimento 2. En 4 puntos se capturaron entre 1 y 6 muestras por punto. Luego, se comparó cuánto variaban, utilizando $n=2.21$ y $n = 2$ (espacio libre +10 dB), ya que según los resultados anteriores son los que mejores resultados han obtenido. Es decir, se usarán las estimaciones de canal que menores errores han generado, y esto en los 3 puntos que mejores condiciones tienen (por la cercanía a los AP).

En el Cuadro 5.10. obtiene el RMSE de la estimación de la posición para el Punto 1 (ver Figura 4.1.) con $n=2.21$ y $C=-52.36$ dBm.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	33.9	29.48	5.39	7.48
Punto 1	28.6	22	31.68	28.82	3.08	6.82
Punto 1	28.6	22	24.09	29.59	-4.51	7.59
Punto 1	28.6	22	24.09	29.59	-4.51	7.59
Punto 1	28.6	22	29.7	31.46	1.1	9.46
RMSE					4.01	7.84

Cuadro 5.10.: Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36$ dBm

En el Cuadro 5.11. obtiene el RMSE de la estimación de la posición para el Punto 2 (ver Figura 4.1.), con $n=2.21$ y $C=-52.36$ dBm

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 2	33	28.6	28.82	31.9	-4.18	3.3

Cuadro 5.11.: Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36$ dBm

En el Cuadro 5.12. se obtiene el RMSE de la estimación de la posición para el Punto 6 (ver Figura 4.1.), con $n=2.21$ y $C=-52.36$ dBm.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 6	55	60.5	108.02	-5.06	53.02	-65.56
Punto 6	55	60.5	108.9	-5.50	53.9	-66
Punto 6	55	60.5	107.91	-5.06	52.91	-65.56
Punto 6	55	60.5	108.9	-5.61	53.9	-65.11
Punto 6	55	60.5	108.9	-5.61	53.9	-65.11
Punto 6	55	60.5	119.24	-14.41	64.24	-74.91
RMSE					55.46	67.46

Cuadro 5.12.: Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$

En el Cuadro 5.13. se obtiene el RMSE de la estimación de la posición para el Punto 7 (ver Figura 4.1.), con $n=2.21$ y $C=-52.36\text{dBm}$.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 7	60.5	64.9	116.49	-11.99	55.99	-76.89
Punto 7	60.5	64.9	115.39	-11.22	54.89	-76.12
Punto 7	60.5	64.9	117.15	-12.1	56.65	-77
Punto 7	60.5	64.9	117.15	-12.1	56.65	-77
Punto 7	60.5	64.9	114.95	-11.99	54.45	-76.89
Punto 7	60.5	64.9	117.04	-12.1	56.54	-77
RMSE					55.85	76.82

Cuadro 5.13.: Trilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$

En los Cuadros 5.14. y 5.15. se muestran los resultados con estimación en espacio libre más 10 dB en los APs NLOS.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	37.95	27.39	9.35	5.39
Punto 1	28.6	22	37.95	33.77	9.35	11.77
Punto 1	28.6	22	4.62	38.28	-23.98	16.28
Punto 1	28.6	22	4.62	38.28	-23.98	16.28
Punto 1	28.6	22	22	44	-6.6	22
RMSE					16.54	15.37

Cuadro 5.14.: Trilateración y error de estimación en condición de espacio libre+10 dB con $n=2$, $C=-40\text{dBm}$

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 2	33	28.6	41.91	24.97	8.91	-3.63

Cuadro 5.15.: Trilateración y error de estimación en condición de espacio libre+10 dB con $n=2$, $C=-40$ dBm

Como se puede observar en los cuadros anteriores, los errores obtenidos mejoran dependiendo de la estimación de canal, así como de las compensaciones que se hagan a los AP NLOS. Se observa también, que la posición del dispositivo móvil, respecto a los AP mejora las estimaciones. Es decir, a mayor cercanía mejores estimaciones. La mejora está relacionada con la condición LOS.

5.2.2. Experimento 4: Multilateración de 4 puntos

La multilateración solo fue posible en puntos en los que se podía registrar una lectura de RRSI de al menos 4 APs de referencia. En nuestros experimentos estos solo fueron 2. El punto 6 y punto 7.

En el Cuadro 5.16. obtiene el RMSE de la estimación de la posición para multilateración en el Punto 6 (ver Figura 4.1.) con $n=2.21$ y $C=-52.36$ dBm.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 6	55	60.5	-	-	-	-
Punto 6	55	60.5	76.67	27.39	21.67	-33.11
Punto 6	55	60.5	76.23	27.39	21.23	-33.11
Punto 6	55	60.5	76.56	27.5	21.56	-33
Punto 6	55	60.5	76.56	27.5	21.56	-33
Punto 6	55	60.5	-	-	-	-
RMSE					21.51	33.05

Cuadro 5.16.: Multilateración y error, estimación de curva con $n=2.21$, $C=-52.36$ dBm

En el Cuadro 5.17. obtiene el RMSE de la estimación de la posición para multilateración en el Punto 7 (ver Figura 4.1) con $n=2.21$ y $C=-52.36$ dBm.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 7	55	64.9	81.51	23.87	26.51	-41.03
Punto 7	55	64.9	80.52	24.53	25.52	-40.37
Punto 7	55	64.9	83.6	22.66	28.6	-42.24
Punto 7	55	64.9	83.6	22.66	28.6	-42.24
Punto 7	55	64.9	80.52	21.01	25.52	-43.89
Punto 7	55	64.9	84.59	21.23	29.59	-43.67
RMSE					27.44	42.26

Cuadro 5.17.: Multilateración y error, estimación de curva con $n=2.21$, $C=-52.36\text{dBm}$

Evidentemente, según el Cuadro 5.16. y el Cuadro 5.17, la multilateración para nuestro escenario presenta errores que no permiten aplicaciones de LBS en interiores. Como se vio antes, los resultados son afectados por el modelo de canal utilizado, y las condiciones del ambiente (LOS, NLOS, etc.).

5.2.3. Experimento 5: Trilateración más aprendizaje automático

En este experimento lo que se busca es que a través de una red neuronal, la máquina aprenda los RSSI para ciertas distancias, y luego estime las distancias cuando se le pongan lecturas nuevas de RSSI. Es decir, se utiliza una red neuronal para estimar la distancia, y luego con esta estimación se procede a usar trilateración para encontrar la posición.

Primero, se creó una base de datos de la distancia versus RSSI, con una densidad de 0.5 m para una distancia de 37 m. Luego, con esta base de datos se procedió a entrenar a una red de 10 neurona y una capa oculta. Se utilizaron tres algoritmos: Lavenberg-Marquadt, regulación bayesiana y gradiente escalado conjugado.

Una vez entrenada la máquina, introduciendo el RSSI se estima la distancia y se aplica trilateración.

En el Cuadro 5.18. se observan los resultados de la estimación de la posición con el enfoque de aprendizaje automático con el algoritmo Levenberg Marquadt, para la estimación de la distancia y luego el uso de trilateración.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	20.9	40.7	-7.7	18.7
Punto 2	33	28.6	-30.58	54.12	-63.58	25.52
Punto 3	40.7	40.7	-20.35	57.42	-61.05	16.72
Punto 6	55	60.5	48.29	34.32	-6.71	-26.18
Punto 12	38.5	20.9	88.22	5.28	49.72	-15.62
RMSE(m)					45.49	21.02

Cuadro 5.18.: Red neuronal LVM + Trilateración

En el Cuadro 5.19. se observan los resultados de la estimación de la posición con el enfoque de aprendizaje automático con el algoritmo Regulación Bayesiana, para la estimación de la distancia. Luego, el uso de trilateración.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	9.35	42.57	-19.25	20.57
Punto 2	33	28.6	-35.2	56.87	-68.2	28.27
Punto 3	40.7	40.7	-18.04	56.21	-58.74	15.51
Punto 6	55	60.5	53.9	31.13	-1.1	-29.37
Punto 12	38.5	20.9	74.8	7.7	36.3	-13.2
RMSE(m)					44.25	22.36

Cuadro 5.19.: Red neuronal BR + Trilateración

En el Cuadro 5.20. se observan los resultados de la estimación de la posición con el enfoque de aprendizaje automático con el algoritmo Gradiente Conjugado Escalado, para la estimación de la distancia. Luego, el uso de trilateración.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 1	28.6	22	17.71	36.96	-10.89	14.96
Punto 2	33	28.6	-35.2	56.87	-68.2	28.27
Punto 3	40.7	40.7	-24.53	60.5	-65.23	19.8
Punto 6	55	60.5	56.98	73.37	1.98	12.87
Punto 12	38.5	20.9	78.65	6.6	40.15	-14.3
RMSE(m)					46.13	18.89

Cuadro 5.20.: Red neuronal SCG + Trilateración

Se ve que los resultados no mejoran significativamente con respecto a estimar la distancia con un modelo de canal. Es más, si este modelo mixto de canal y aprendizaje automático incluye conocimiento de las condiciones como NLOS, el error que aumenta.

5.2.4. Experimento 6: Aprendizaje automático

En este experimento se busca reemplazar la estimación de la distancia y de la posición como dos pasos separados, por un único paso que será realizado por una red neuronal. Es decir, la red neuronal estimará la posición en su salida y sus entradas serán las lecturas de RSSI de diferentes APs. Esta aproximación se conoce como "fingerprinting" en la literatura.

En este caso, se entrena una red neuronal poniendo como entradas 20 muestras de RSSI de un mismo punto. Esto para los 100 puntos de plano Duhamel (ver Figura 4.3.), y para todos los APs disponibles. Luego, como etiquetas de la máquina se colocan las coordenadas de cada uno de los 100 puntos en que se tomaron las muestras, como se ve en el Cuadro A2 del Anexo A.

5.2.4.1. Entrenamiento de la Red neuronal

En esta sección se evaluarán redes neuronales con 14 entradas y 16 entradas que tienen 10 y 100 neuronas en la capa oculta y dos neuronas en la capa de salida que proporcionan la estimación de la posición (X_e , Y_e).

En la Figura 5.6. se puede ver el esquema de la red neuronal de 14 entradas que se entrenó con la base de datos de la segunda campaña de mediciones, y 2 salidas, que vienen a ser las coordenadas (x , y).




Figura 5.6.: Diagrama de la Red Neuronal

Se ha entrenado esta red con 3 tipos diferentes de algoritmos, Levenberg, Regularización bayesiana y gradiente escalado conjugado.

5.2.4.2. Red neuronal de 14 entradas

Esta primera red neuronal fue entrenada con 14 entradas (cada uno con una muestra de RSSI de un AP distinto). Luego, para probar el desempeño de la red se tomaron

10 puntos de una segunda base de datos de las mismas dimensiones (100 puntos), pero esta vez en un escenario de tráfico medio. Se han usado 3 tipos de algoritmos de aprendizaje para comparar sus desempeños.

El Cuadro 5.21. muestra la estimación de la posición y el RMSE para los 10 puntos, usando el algoritmo Levenberg-Marquadt.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 8	23.1	51.7	13.97	36.52	-9.13	-15.18
Punto 18	19.8	47.3	-9.57	14.08	-29.37	-33.22
Punto 28	16.5	44	4.18	31.79	-12.32	-12.21
Punto 38	14.3	38.5	1.65	28.05	-12.65	-10.45
Punto 48	12.1	25.2	13.53	40.26	1.43	5.06
Punto 58	8.25	30.8	-7.15	16.5	-15.4	-14.3
Punto 68	5.5	27.5	-9.79	10.67	-15.29	-16.83
Punto 78	2.75	23.1	-7.04	11.11	-9.79	-11.99
Punto 88	0	19.25	2.42	29.26	2.42	10.01
Punto 98	-3.3	15.4	5.39	33.22	8.69	17.82
RMSE(m)					13.81	16.33

Cuadro 5.21.: Red de 10 neuronas y 14 entradas, algoritmo de Levenberg-Marquadt

El Cuadro 5.22. muestra la estimación de la posición y el RMSE para los 10 puntos, usando el algoritmo de Regulación bayesiana.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 8	23.1	51.7	18.92	50.38	-4.18	-1.32
Punto 18	19.8	47.3	49.39	47.3	29.59	0
Punto 28	16.5	44	-8.69	38.5	-25.19	-5.5
Punto 38	14.3	38.5	9.79	35.75	-4.51	-2.75
Punto 48	12.1	25.2	11.11	34.98	-0.99	-0.22
Punto 58	8.25	30.8	14.41	38.61	6.16	7.81
Punto 68	5.5	27.5	9.9	32.12	4.4	4.62
Punto 78	2.75	23.1	4.62	25.41	1.87	2.31
Punto 88	0	19.25	4.07	30.25	4.07	11
Punto 98	-3.3	15.4	0.99	27.39	4.29	11.99
RMSE(m)					12.82	6.26

Cuadro 5.22.: Red de 10 neuronas y 14 entradas, algoritmo Regulación Bayesiana

El Cuadro 5.23. muestra la estimación de la posición y el RMSE para los 10 puntos, usando el algoritmo de Gradiente Conjugado Escalado.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 8	23.1	51.7	18.92	41.69	-4.18	-10.01
Punto 18	19.8	47.3	17.49	42.57	-2.31	-4.73
Punto 28	16.5	44	19.36	43.67	2.86	-0.33
Punto 38	14.3	38.5	4.84	27.17	-9.46	-11.33
Punto 48	12.1	25.2	9.46	32.67	-2.64	-2.53
Punto 58	8.25	30.8	7.04	30.03	-1.21	-0.77
Punto 68	5.5	27.5	2.64	24.09	-2.86	-3.41
Punto 78	2.75	23.1	-5.39	20.02	-8.14	-3.08
Punto 88	0	19.25	0.66	21.89	0.66	2.64
Punto 98	-3.3	15.4	0.77	22.22	4.07	6.82
RMSE(m)					4.69	5.77

Cuadro 5.23.: Red de 10 neuronas y 14 entradas, algoritmo de Gradiente Conjugado Escalado

Como se puede observar de los cuadros anteriores, el mejor desempeño lo presenta el algoritmo SCG. Con un error significativamente menor que los otros algoritmos de aprendizaje automático, y de los enfoques de trilateración usados. Con lo que podemos afirmar que la aproximación de fingerprinting muestra, hasta este momento, las mejores estimaciones de posición para aplicaciones LBS.

5.2.4.3. Red neuronal de 16 entradas

Esta segunda red neuronal fue entrenada con 16 entradas, 10 neuronas y 3 diferentes algoritmos para ver cuál de estos presentaba el mejor desempeño con respecto a la red de 14 entradas. El mejor desempeño lo ha presentado el algoritmo LVM, este mejoró con respecto a la RN de 14 entradas. En este primer experimento con 16 entradas la precisión no mejoró como se esperaba; sin embargo, más adelante en la Figura 5.1. se mostrará, que al volver a entrenar la red se obtuvo una mejora significativa.

El Cuadro 5.24. muestra la estimación de la posición y el RMSE para los 10 puntos, usando el algoritmo Levenberg-Marquadt.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 8	23.1	51.7	14.74	37.07	-8.36	-14.63
Punto 18	19.8	47.3	-0.693	51.37	-20.493	4.07
Punto 28	16.5	44	15.84	53.46	-0.66	9.46
Punto 38	14.3	38.5	3.41	32.89	-10.89	-5.61
Punto 48	12.1	25.2	6.49	33.44	-5.61	-1.76
Punto 58	8.25	30.8	1.43	32.67	-6.82	1.87
Punto 68	5.5	27.5	5.94	36.96	0.44	9.46
Punto 78	2.75	23.1	-2.86	14.85	-5.61	-8.25
Punto 88	0	19.25	-11.99	15.4	-11.99	-3.85
Punto 98	-3.3	15.4	-13.2	20.35	-9.9	4.95
RMSE(m)					9.79	7.45

Cuadro 5.24.: Red de 10 neuronas y 16 entradas, algoritmo de Levenberg-Marquadt

El Cuadro 5.25. muestra la estimación de la posición y el RMSE para los 10 puntos, usando el algoritmo de Regulación bayesiana.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 8	23.1	51.7	12.76	43.67	-10.34	-8.03
Punto 18	19.8	47.3	26.84	60.94	7.04	13.64
Punto 28	16.5	44	32.89	68.42	16.39	24.42
Punto 38	14.3	38.5	9.79	35.53	-4.51	-2.97
Punto 48	12.1	25.2	10.34	31.13	-1.76	-4.07
Punto 58	8.25	30.8	17.16	32.89	8.91	2.09
Punto 68	5.5	27.5	26.84	47.85	21.34	20.35
Punto 78	2.75	23.1	4.07	30.58	1.32	7.48
Punto 88	0	19.25	-4.62	16.61	-4.62	-2.64
Punto 98	-3.3	15.4	-7.37	10.45	-4.07	-4.95
RMSE(m)					10.11	11.74

Cuadro 5.25.: Red de 10 neuronas y 16 entradas, algoritmo de Regulación Bayesiana

El Cuadro 5.26. muestra la estimación de la posición y el RMSE para los 10 puntos, usando el algoritmo de Gradiente Conjugado Escalado.

Coordenada	X	Y	Xe	Ye	Error X (m)	Error Y (m)
Punto 8	23.1	51.7	12.54	34.87	-10.56	-16.83
Punto 18	19.8	47.3	21.78	39.38	1.98	-7.92
Punto 28	16.5	44	17.82	35.31	1.32	-8.69
Punto 38	14.3	38.5	49.39	33.88	35.09	-4.62
Punto 48	12.1	25.2	8.03	37.07	-4.07	1.87
Punto 58	8.25	30.8	5.61	35.53	-2.64	4.73
Punto 68	5.5	27.5	8.91	38.72	3.41	11.22
Punto 78	2.75	23.1	1.43	22.9	-1.32	-0.11
Punto 88	0	19.25	-2.97	18.81	-2.97	-0.44
Punto 98	-3.3	15.4	-5.39	14.63	-2.09	-0.77
RMSE(m)					11.83	7.72

Cuadro 5.26.: Red de 10 neuronas y 16 entradas, algoritmo de Gradiente Conjugado Escalado

Se probó esta misma RN de 16 entradas con 100 neuronas, pero los resultados empeoraban al comparar el RMSE (m), para los 3 algoritmos utilizados, como se muestra en Cuadro 5.27. Por lo que, se extrapola que en la red de 14 entradas tampoco mejorará la precisión debido al sobreajuste, con lo cual no se han implementado tales redes neuronales.

#Neuronas	LVM	RB	SCG
10	[9.79 , 7.45]	[10.11 , 11.74]	[11.83 , 7.71]
100	[19.26 , 19.43]	[56.64 , 51.94]	[12.44 , 14.99]

Cuadro 5.27.: Comparación de RMSE (m) 10 Neuronas vs 100 neuronas RN de 16 entradas para 3 diferentes algoritmos

5.3. Comparación parcial de los resultados

5.3.1. Método con aproximación geométrica

Puntos comparados: 1, 2, 3, 7, 12 de la campaña de mediciones 1, ver Cuadro 5.4. Donde lo escenarios son:

Espacio libre: $n = 2$ y $C = -40dB$.

Espacio libre +10dB: Se sumó 10dB en APs NLOS.

Espacio libre + 10 con 6 muestras: Se aumentó el número de muestras de RSSI a 6.

Ajuste 1: $n = 1,83$ y $C = -48dB$.

Ajuste 1 +10dB: Se sumó 10dB en APs NLOS.

Ajuste 2: $n = 2.21$ y $C = -52,3dB$.

Ajuste 2+10dB: Se sumó 10dB en APs NLOS.

Ajuste 2 con 6 muestras: Se aumento el número de muestras de RSSI a 6.

Multilateración: $n = 2.21$ y $C = -52,3dB$, con 4 APs en los Puntos 6 y 7.

ML+trilateración: Red neuronal (SCG) aproxima la distancia y de ahí se usa trilateración.

Escenarios	X RMSE	Y RMSE
Espacio libre	86.77m	100.94m
Espacio libre +10dB	14.20m	17.99m
Espacio libre + 10dB con 6 muestras	15.98m	14.11m
Ajuste1	44.43m	45.10m
Ajuste 1 +10dB	17.28m	24.55m
Ajuste 2	25.42m	27.26m
Ajuste2 +10dB	27.47m	35.80m
Ajuste2 +10 dB con 6 muestras	45.51m	59.17m
Multilateración	24.48m	37.65m
ML+trilateración	46.18m	18.89m

Cuadro 5.28.: Comparación RMSE de los enfoques que usan trilateración

5.3.2. Método con aprendizaje automático

En el Cuadro 5.29 se puede observar el RMSE en 10 puntos para los 3 distintos algoritmos para 14 y 16 entradas.

Algoritmo	#de Entradas	X RMSE	Y RMSE
LVM	14	13.81m	16.33m
BR	14	12.82m	6.26m
SCG	14	4.69m	5.77m
LVM	16	9.79m	7.45m
BR	16	10.11m	11.74m
SCG	16	11.83m	7.72m

Cuadro 5.29.: Comparación de distintos algoritmos de redes neuronales (LVM, BR, SCG) con 14 y 16 entradas

5.4. Costo computacional

En el Cuadro 5.30. se presenta el coste computacional en términos de FLOPS (Floating Point Operations Per Second). Esta medida de operaciones de punto flotante

por segundo es el número de operaciones por segundo. En este caso presenta la cantidad de multiplicaciones, sumas y las veces que la función de activación fue requerida en la red neuronal.

Esta medición del rendimiento se ha obtenido para una red de 16 entradas con 10 neuronas. Esta configuración de la red se ha escogido debido a que obtuvo el menor RMSE promedio como se observa en Figura 5.7.

Como se observa en el Cuadro 5.30., alrededor de 720 operaciones de punto flotante son necesarios para la estimación de la posición en esta red neuronal. Ahora bien, en la actualidad los smartphones de gama media tienen una capacidad superior a 600 MFLOPS y los de alta gama poseen GPUs que llegan hasta los TFLOPS. Como se indica en el estudio realizado en [Ignatov et al., 2018], así que con smartphones modernos es posible realizar aprendizaje automático para redes sencillas y para redes pesadas como las de aprendizaje profundo están los smartphones de altas prestaciones. En el caso de este trabajo la red presenta bajo costo computacional para los estándares actuales.

Por otro lado, en aplicaciones de LBS la velocidad de actualización de la posición depende de la aplicación requerida. Pero, esta encuentra limitación en la velocidad de adquisición del RSSI de las señales recibidas. Pruebas experimentales durante este trabajo muestran que es posible actualizar estas mediciones (RSSI) cada un segundo.

	Multiplicación	Suma	Función de activación	FLOPS
Capa de entrada	256	240	16	512
Capa oculta	100	90	10	200
Capa de salida	4	2	2	8
Total	360	332	28	720

Cuadro 5.30.: Cálculo del costo computacional en FLOPS para una red neuronal de 16 entradas y 10 neuronas

5.4.1. Error versus número de entradas

En la Figura 5.7. se obtuvo el RMSE para diversos números de entradas (AP), entre 3 y 16. En 10 puntos, P8, P18, P28, P38, P48, P58, P68, P78, P88, P98 (ver Figura 4.3.). El experimento se realizó con 10 neuronas, obteniéndose un error promedio de estimación de 2.95 metros. Para mayor detalle ver el Cuadro 5.31.




Figura 5.7.: Gráfica que muestra el RMSE de validación, para distinto número de entradas en una red de 10 neuronas

Cuadro 5.31. muestra la mejora obtenida en un nuevo entrenamiento y comparación con diferente número de entradas.

#Entradas	RMSE X(m)	RMSE Y(m)	RMSE promedio
3	7.19	10.76	8.975
4	18.29	21.17	19.73
5	8.66	13.35	11.01
6	18.41	23.05	20.73
7	10.57	14.40	12.48
8	10.88	16.19	13.53
9	9.79	14.64	12.21
10	8.87	12.91	10.89
11	8.71	12.37	10.54
12	9.19	13.23	11.21
13	8.69	9.37	9.03
14	6.74	7.89	7.31
15	2.49	4.94	3.71
16	2.17	3.73	2.95

Cuadro 5.31.: Resultados de la comparación entre número de entradas y el error que produce en la estimación de posición, red de 10 neuronas

5.4.2. Error versus número de neuronas

En la Figura 5.8. se observa el RMSE para diverso número de neuronas, de 1 hasta 100 neuronas, aumentándose 5 neuronas en cada prueba, en 10 puntos distintos P8, P18, P28, P38, P48, P58, P68, P78, P88, P98 (ver Figura 4.3.). En este experimento se utilizaron 14 entradas, para mayor detalle ver el Cuadro A.3 del Anexo.

Donde la línea de color azul representa al RMSE de la coordenada X, la línea de color rojo representa al RMSE de la coordenada Y. Por último, la línea de color verde representa el promedio de los errores en ambas coordenadas.




Figura 5.8.: Gráfica que muestra el RMSE para distinto número de neuronas en una red de 14 entradas

Como se ha observado en la gráfica de la Figura 5.8., el aumento de neuronas no parece indicar una disminución en el error de estimación. Además, todos los errores son mayores a 5 metros. Asimismo, solo hay una tendencia observable en el rango de 1 a 15 neuronas (error casi constante), y en el rango de 80 a 100 neuronas (aumento de error). Esto puede estar relacionado con el número de entradas de la red. Es decir, que el número de neuronas a usar en una red neuronal podría estar supeditado al número de entradas o características.

En la Figura 5.9. se muestra el RMSE para diversos números de neuronas de 1 hasta 100 neuronas, aumentándose 5 neuronas en cada prueba. El experimento se hizo en 10 puntos de prueba P8, P18, P28, P38, P48, P58, P68, P78, P88, P98 (ver Figura 4.3.), pero esta vez con 16 entradas, para mayor detalle ver el Cuadro A.4 del Anexo.




Figura 5.9.: Gráfica que muestra el RMSE para distinto número de neuronas ahora con 16 entradas

En la gráfica de la Figura 5.9. se observa una tendencia a que un número de neuronas mayor al número de entradas de la red neuronal aumenta el error de estimación. Es decir, parece haber una tendencia proporcional entre el error y el número de neuronas.

Por tanto, pareciera que con 14 entradas no hay una tendencia clara, y con 16 entradas, sí habría una tendencia proporcional entre el error de estimación y el número de neuronas.

5.5. Comparación total de resultados

En esta sección se compararán todos los enfoques, incluido el algoritmo SCG reentrenado, y se obtendrá el RMSE promedio entre la estimación de las coordenadas X e Y para todos los enfoques. Como se observa en el Cuadro 5.32. el enfoque de menor error es de una red neuronal de 16 entradas, con algoritmo de gradiente conjugado escalado, pues muestra un error promedio de estimación de 2.95 metros. Asimismo, se tomará como variable de control a la aproximación de espacio libre, y respecto

a ella, se evaluará el desempeño de todas las demás aproximaciones. Es decir, el porcentaje que aparezca en el Cuadro 5.32. significará cuánto mejoran las distintas aproximaciones utilizadas, en cuanto a reducción de error de estimación, Respecto a la aproximación de Espacio libre. Obteniendo así, una métrica que permita comparar y evaluar el desempeño de los diferentes enfoques utilizados. Para conocer con mayor detalle de dónde se obtienen el RMSE promedio del Cuadro 5.32. revisar el Anexo, sección A.5, Cuadro A.6.

Escenarios	RMSE promedio	Porcentaje de mejora
Espacio libre +10dB	16.09m	82.85 %
Espacio libre + 10dB con 6 muestras	15.04 m	83.97 %
Ajustel	44.76m	52.30 %
Ajuste 1 +10dB	20.91m	77.72 %
Ajuste 2	26.34 m	71.94 %
Ajuste2 +10dB	31.64 m	66.29 %
Ajuste2 +10 dB con 6 muestras	52.34 m	44.23 %
Multilateración	31.06 m	66.90 %
ML+trilateración	32.54 m	65.33 %
LVM14	15.07 m	83.94 %
BR14	9.54 m	89.83 %
SCG14	5.23 m	94.42 %
LVM16	8.62 m	90.81 %
BR16	10.92m	88.35 %
SCG16	9.78m	89.58 %
SCG16 Reentrenado	2.95m	96.85 %

Cuadro 5.32.: Porcentaje de mejora respecto a la reducción de error de estimación, en relación al enfoque de espacio libre

Como se puede observar en el Cuadro 5.32. la mayor mejora usando trilateración es el primer enfoque, llamado Espacio libre + 10 dB con 6 muestras. En este se ha obtenido una mejora respecto a la variable de control, de al rededor 83.97%. No obstante, no es representativo pues solo fue en los Puntos 1 y 2 de experimento de trilateración. Además, en condición de LOS. Por otro lado, el mejor enfoque de red neuronal se dio al utilizar el algoritmo de gradiente conjugado escalado, llegando a tener una mejora del 96.85 % respecto al enfoque de control. Esta mejora es significativa y representativa pues se tomaron 10 puntos de la segunda base de datos que sirvió para testear la red reentrenada, SCG con 16 entradas.

6. Discusión

La tecnología beamforming de los AP en las lecturas de RSSI del experimento 1 puede haber generado el efecto de tener cifras constantes a lo largo de varios metros alejados del AP. No obstante, se sabe que el desvanecimiento y los obstáculos influyen en los resultados. Ahora, no está claro cuál de estos factores ha tenido mayor impacto.

Se trató de mitigar el efecto del desvanecimiento, aumentando el número de muestras por punto. Primero a 4 muestras, luego entre 20 y 25 muestras. Luego, utilizando el promedio del RSSI. Aun así, la señal RSSI mostraba datos con alta variabilidad. Sin embargo, mirando los resultados de la Figura 5.4. se observa una tendencia a que con un mayor número de muestras, el promedio de estas tienden a comportarse de forma logarítmica, en función de la distancia al AP.

A lo largo de los Experimentos 1 y 2, de estimación de canal, los coeficientes de pérdidas n , concuerdan con los valores teóricos encontrados en la literatura, Como se observa en [Farahani, 2008b].

Con lo que comprobamos que valores de n :

- $n = [1,6 - 1,8]$ son para escenarios en interiores en condición de LOS.
- $2 < n < 3$ son para escenarios en interiores que tienen a estar en condición de NLOS

Según los resultados vistos en las tablas de los experimentos de trilateración con las estimaciones de canal hechas con curvas ajustadas, estas no necesitan aumentarles 10 dB a los NLOS ya que induce a un mayor error en las estimaciones, como se observa el Ajuste2+10dB en el Cuadro 5.28.

Usar un enfoque de ajuste de curva para estimar el canal puede resultar en mejores prestaciones de precisión que un enfoque usando solo la fórmula de espacio libre, asumiendo $n = 2$ y $C = 40$. Sin embargo, el enfoque de espacio libre +10dB es superior a todos los demás enfoques que usan trilateración. Aun así, la precisión es insuficiente para aplicaciones comerciales.

En los experimentos de estimación de canal, que se han llevado a cabo para hallar el valor de C a 1m distancia. Según la literatura, los valores de RSSI a esa distancia deberían rondar los -30 dBm; sin embargo, si se tomara ese valor, el modelamiento no se ajustaría. Ya que, como se puede observar en los Cuadros 5.2 y 5.3., los valores de C oscilan entre -50 dBm y -40 dBm.

En el experimento de los escenarios de tráfico moderado, medio y bajo, se comprueba la alta variabilidad de las lecturas RSSI. Estas variaciones pueden explicarse debido al desvanecimiento por multitrayecto.

Los enfoques de trilateración parecen tener una precisión aceptable cuando se tiene línea de vista entre AP y smartphone, lo mismo pasa en la estimación del canal con n y C .

Combinar redes neuronales y trilateración presentó una baja precisión. Debido a que la máquina aprendió cómo se degradaba la señal en un espacio libre de obstáculos. Sin embargo, en el lugar de las pruebas, dos de los AP no tenía línea de vista, pues se ubicaban dentro de salones. Esto nos indica que, se debe entrenar para las mismas condiciones que se esperan en operación. Esto es de particular importancia cuando hay escenarios diversos (LOS, NLOS, diversas condiciones de tráfico, etc.). Por tanto, la red neuronal debe ser entrenada en las condiciones que posibiliten su operación real.

Al parecer usar fingerprinting se vuelve la opción de mejores prestaciones y de mayor robustez. Aunque, su escalabilidad se ve comprometida cuando se requiere alta precisión (elear la cantidad de mediciones o lecturas de distintos APs).

El aprendizaje automático es el enfoque ideal cuando se trabaja con RSSI, debido a la variabilidad y anomalía de los datos.

En la gráfica de la Figura 5.7. se observa cómo el RMSE promedio disminuye a medida que se aumenta el número de entradas. Además, se puede notar cómo a partir de 7 entradas, el sistema comienza a estabilizarse y a reducir gradualmente el error.

En la gráfica de la Figura 5.8. se observar cómo al usar 14 entradas de las 16 disponibles, el RMSE promedio muestra una variabilidad de aproximadamente 10 metros, con una ligera tendencia a aumentar a medida que aumenta el número de neuronas en los rangos de 1 a 15 neuronas y de 80a 100 neuronas.

En la gráfica de la Figura 5.9. se observa con mayor claridad cómo aumenta el RMSE promedio a medida que se aumenta el número de neuronas, esto haciendo uso de las 16 entradas disponibles. Esto indica que a partir de superar cierto número de neuronas se ha sobreajustado o sobreentrenado la red.

Según lo observado en las gráficas de las Figuras 5.6., 5.7. y 5.8., la variable que mayor impacto tiene en reducir el RMSE de la estimación, es el número de entradas. Por tanto, el criterio de elección del número de entradas de entrenamiento es el del mayor posible, ya que todo lo que brinde información ayudará a mejorar las prestaciones de la red neuronal.

Se han utilizado algoritmos convencionales de entrenamiento para evaluar el desempeño de la red neuronal. Modificar estos algoritmos está fuera del ámbito de esta tesis. Sin embargo, es posible mejorar la precisión de estimación, pues en cada entrenamiento se brinda los datos de la convergencia de entrenamiento y con estos es posible corregir muestras en los datos que puedan ser anómalos o generen mucho error. Esto se puede llevar a cabo mirando el histograma de errores. Otra forma de mejorar la precisión en la estimación es reentrenar la red, aunque las mejoras en este caso no son significativas.

El entrenamiento de una red neuronal, no obstante, posea las mismas entradas y etiquetas, usando el mismo algoritmo de entrenamiento da resultados diferentes. Si se entrena en dos momentos distintos, esto debido a que los valores iniciales de los pesos de entrenamiento son diferentes en cada iteración. Por lo que, hay que asegurar la convergencia en el entrenamiento, sabiendo que este tiene un componente de aleatoriedad en la inicialización de los pesos.

Hay que dejar que la señal se estabilice antes de tomar las muestras, así como tomar un promedio de al menos 20 muestras de RSSI por punto medido. Esto debido a que las pérdidas por desvanecimiento, pueden hacer que la lectura de RSSI no sea detectable por el smartphone, o varíe de forma significativa. En una zona que se sabe, hay cobertura. Con lo cual, aumentado el número de muestras se compensan estas variaciones. Además, se han escogido 20 muestras porque es un número mínimo que permite compensar las variaciones, y a la vez hace que el trabajo de almacenamiento de lecturas RSSI sea escalable, y tome menos tiempo.

7. Conclusiones y trabajos futuros

7.1. Conclusiones

1. Se ha implementado con éxito una herramienta capaz de medir el RSSI utilizando un smartphone. Esta herramienta ha sido utilizada para realizar una campaña de mediciones en puntos preseleccionados del edificio Duhamel (planta baja) de la UCSP.
2. Se ha implementado un sistema para estimar la localización en interiores utilizando diversas aproximaciones para el modelado de canal (estimar la distancia) y para estimar la localización (trilateración y aprendizaje automático).
3. Se ha implementado la trilateración resolviendo el sistema de ecuaciones por medio de matrices que minimizan el error cuadrático medio. Dando resultados precisos en casos ideales. La implementación fue realizada utilizando el software Matlab.
4. Se ha comprobado que la trilateración funciona, pero está limitada a la precisión de la distancia estimada, y esta a su vez a la estimación del canal. Dando resultados bastante aceptables en casos de LOS, como en los Puntos 1, 2, y 12. Con un nivel de error promedio menor a 5 metros, como se muestra en el Cuadro 5.5. Pero, totalmente inviables cuando no hay línea de vista (NLOS), como en los Puntos 3 y 7. Con un nivel de error promedio que supera las decenas de metros, como se muestra en los Cuadros 5.4., 5.5., 5.6., 5.7., 5.8., y 5.9.
5. Se ha comprobado que la red neuronal artificial es el mejor método probabilístico para este problema, dada la variabilidad causada por el desvanecimiento en las señales WiFi.
6. Se ha obtenido que el algoritmo de gradiente conjugado escalado es el que menor error (RMSE) presenta en la solución de este problema, además usa menos recursos computacionales. Como se observa en la Figura 5.7. la red reentrenada con 16 entradas muestra un RMSE promedio de 2.95 metros. Representando una mejora del 96.85% respecto a un enfoque de trilateración que usa la estimación de canal como Espacio libre, como se aprecia en el Cuadro 5.32. Del mismo modo, representa una mejora del 81.67% (ver Cuadro A.7.), respecto al mejor método de estimación en trilateración, del experimento llamado Espacio libre + 10dB.

7. Respecto a la estimación de canal, se ha comprobado que cuando se toman datos de diversas distancias, cada 0.5 metros. A medida que el número de muestras de RSSI aumentan los datos tienden a parecer aproximaciones logarítmicas, en condiciones de tráfico alto. Como se observa en la Figura 5.5. (a).
8. Respecto a la estimación de canal, tomar la potencia a 1 m de referencia, como indica la literatura, no es necesario. Si se tiene un número considerable de datos, lo mejor es hallar la curva con los datos en un estimador logarítmico.
9. Se ha determinado que la estimación de la distancia del smartphone al punto de acceso es el reto más grande al momento de utilizar el RSSI y trilateración. Debido al multitrayecto y desvanecimiento.
10. En trilateración es más importante saber qué estimación de canal usar dependiendo de dónde se encuentre el smartphone, frente a aumentar mucho el número de muestras para calcular la posición.
11. Los puntos de acceso de referencia que no sean representativos del área de trabajo deben filtrarse si se usa un enfoque de trilateración, ya que, más puntos de referencia no siempre es mejor. Sino, la fiabilidad de la lectura. Es decir, que presente menos ruido, o menos pérdidas por desvanecimiento.
12. Al trabajar con redes neuronales, tener un mayor número de entradas que representen mayor información, mejora la precisión de estimación. En otras palabras, tener el mayor número de características de nuestro escenario resulta en menor error. Por lo que, el número de entradas es la variable que mayor impacto tiene en el error de la red neuronal.
13. Finalmente, los resultados indican que trabajar con el RSSI presenta resultados aceptables de precisión a medida que se aumenta la complejidad del sistema.

7.2. Trabajos futuros

- Si se quiere seguir la línea de investigación en trilateración con RSSI se sugiere crear un sistema inteligente o dinámico que identifique lugares con LOS y NLOS, esto usando aprendizaje automático, para que así encuentre en cada caso una estimación del canal en tiempo real de n y C , así se tendrían resultados más precisos.
- Además, con la llegada de Android 9.0 y el protocolo IEEE 802.11mc que implementa un campo en que se especifica el tiempo de ida y vuelta WiFi (RTT) del paquete de datos enviado, ha mostrado resultados de posicionamiento, de en torno a 1 y 2 metros de precisión usando trilateración, por lo que se recomienda seguir como se lee en [Developers, 2019], desarrollando métodos de posicionamiento con RTT.

Reconocimientos

Al Dios uno y trino, a mi familia, a mi asesor Efraín Zenteno Bolaños y a todos los que aliviaron la carga al desarrollar este proyecto con pequeños actos de generosidad.

A. Anexo

A.1. Sección 1

A.1.1. Código de trilateración usando matrices

```
syms x y;
d1=3.6;
d2=8.06;
d3=16.28;
ap1=(x-1)^2 + (y-7)^2
ap1x=expand(ap1)-d1^2;
ap2=(x-7)^2 + (y-3)^2;
ap2x=expand(ap2)-d2^2;
ap3=(x-15)^2 + (y-7)^2;
ap3x=expand(ap3)-d3^2;
M=vpa([coeffs(ap1x);coeffs(ap2x);coeffs(ap3x)],3);
A=M(:,2:end)
B=-1*M(:,1)
R=pinv(A)*B;
xr=R(3,1)
yr=R(1,1)
plot(xr,yr , 'o')
grid on
```

A.1.2. Lectura, promedio y varianza de los datos del AP3

```
[num,txt,row]=xlsread('FINALTRATADA_MODERADO.xlsx');
[num1,txt1,row1]=xlsread('FINALTRATADA_NO TRÁFICO.xlsx');
```

```
[num2,txt2,row2]=xlsread('FINAL TRATADA_NORMAL.xlsx');
Distancia=cell2mat(row(:,1));
RSSI_fulltrafico=cell2mat(row(:,2));
Distancia1=cell2mat(row1(:,1));
RSSI_Notrafico=cell2mat(row1(:,2));
Distancia2=cell2mat(row2(:,1));
RSSI_Normal=cell2mat(row2(:,2));
figure(1)
subplot(3,1,1)
plot(Distancia,RSSI_fulltrafico,'k .-')
title('Tráfico moderado','FontName','Arial','FontSize', 12)
xlabel('Distancia(m) ','FontName','Arial','FontSize', 12)
ylabel('RSSI(dBm)','FontName','Arial','FontSize', 12)
grid on
subplot(3,1,2)
plot(Distancia1,RSSI_Notrafico,'b .-')
title('Tráfico bajo ','FontName','Arial','FontSize', 12)
xlabel('Distancia(m) ','FontName','Arial','FontSize', 12)
ylabel('RSSI(dBm)','FontName','Arial','FontSize', 12)
grid on
subplot(3,1,3)
plot(Distancia2,RSSI_Normal,'r .-')
title('Tráfico normal','FontName','Arial','FontSize', 12)
xlabel('Distancia(m) ','FontName','Arial','FontSize', 12)
ylabel('RSSI(dBm)','FontName','Arial','FontSize', 12)
grid on
a=0;
b=1;
for i=1:12 %cada 0.5m a 6 metros
a=a+25;
promedios(i)=mean(RSSI_fulltrafico(b:a,:));
```

```
promedios1(i)=mean(RSSI_Notrafico(b:a,:));
promedios2(i)=mean(RSSI_Normal(b:a,:));
varianza(i)=var(RSSI_fulltrafico(b:a,:));
varianza1(i)=var(RSSI_Notrafico(b:a,:));
varianza2(i)=var(RSSI_Normal(b:a,:));
b=b+25;
end
Moderado=promedios';
bajo=promedios1';
normal=promedios2';
dist=(0.5:0.5:6)';
figure(2)
subplot(3,1,1)
err =varianza';
errorbar(dist,Moderado,err,'- k')
title('Promedio de Tráfico Moderado y varianza','FontName','Arial','FontSize', 12)
xlabel('Distancia(m) ','FontName','Arial','FontSize', 12)
ylabel('RSSI Promedio(dBm)','FontName','Arial','FontSize', 12)
grid on
hold on
subplot(3,1,2)
err1 =varianza1'
e=errorbar(dist,bajo,err1,'.-')
title('Promedio de Tráfico Bajo y varianza','FontName','Arial','FontSize', 12)
xlabel('Distancia(m) ','FontName','Arial','FontSize', 12)
ylabel('RSSI Promedio(dBm)','FontName','Arial','FontSize', 12)
grid on
subplot(3,1,3)
err2 =varianza2'
e=errorbar(dist,normal,err2,'.- r')
title('Promedio de Tráfico normal y varianza','FontName','Arial','FontSize', 12)
xlabel('Distancia(m) ','FontName','Arial','FontSize', 12)
ylabel('RSSI Promedio(dBm)','FontName','Arial','FontSize', 12)
grid on
```

A.1.3. Elaboración de las gráficas experimento 1

```

clear all
Ap5x=[1;2;3;4;5;6;7;8;9;10;11;12];
Ap5y=[-29;-36;-44;-45;-47;-48;-48;-48;-49;-52;-50;-49];
p4=plot(Ap5x,Ap5y,'r o- ');
legend('Muestras de AP5')
xlabel('Distancia(m) ','FontName','Arial','FontSize', 14)
ylabel('RSSI(dBm)','FontName','Arial','FontSize', 14)
grid on
hold on;
Ap1x=[1;2;3;4;5;6;7;8;9;10;11;12;13;14;15];
Ap1y=[-35.3;-34;-35;-42;-42;-42;-42;-42;-47;-52;-52;-52;-52;-52];
p1=plot(Ap1x,Ap1y,'b +-');
Ap3x=[1;2;3;4];
Ap3y=[-30;-38;-35;-47];
p2=plot(Ap3x,Ap3y,'g *- ');
Ap4x=[1;2;3;4;5;6];
Ap4y=[-28;-31;-30;-34;-36;-39];
p3=plot(Ap4x,Ap4y,'k *-');hold off;
h = [p1(1);p2;p3(1);p4];
leyenda=legend(h,'Muestras de AP1','Muestras de AP3','Muestras de AP4','Muestras
de AP5');
set(leyenda,'FontName','arial','FontUnits','points','FontSize',10,...
'FontWeight','normal','FontAngle','normal')
grid on

```

A.1.4. Estimador lineal y polinómico

```

clc
close all
clear all
Xm=[1;2;3;4;5;6;7;8;9;10;11;12];

```

```
Y=[-29;-36;-44;-45;-47;-48;-48;-48;-49;-52;-50;-49];
m=mean(Xm);
s=std(Xm);
X=(Xm-m)/s
plot(X,Y,'r ')
xlabel('Distancia normalizada ')
ylabel('RSSI(dBm)')
grid on
[L,N]=size(X);
Xe=[ones(L,1) X];
W=pinv(Xe)*Y;
Y_hat=Xe*W;%
hold on
Etr=mean((Y-Y_hat).^2);
plot(X,Y_hat,'b')
X_new=(50-m)/s;
X_e_new=[1 X_new];
Y_tst=X_e_new*W
k=3;
Xp_e=[];
for i=0:k
Xp_e=[Xp_e X.^i];
end
W=((Xp_e'*Xp_e)^-1)*Xp_e'*Y
Yp_hat=Xp_e*W;
hold on
plot(X,Yp_hat,'g')
grid on
X_new_p=(50-m)/s;
X_new_pp=[];
for i=0:k
X_new_pp=[X_new_pp X_new_p.^i];
end
Y_tst_p=X_new_pp*W
```

A.1.5. Especificaciones técnicas del medidor láser de distancia e imagen.

Características	Especificación
Modelo	HP-5060
Rango de medida	0.3m-60m
Precisión	+ - 1.5mm
Resolución	1mm
Luz en pantalla	Sí
Auto apagado	Sí
Velocidad de medición	0.5 segundos
Tipo de láser	635-650nm, ClassII, <1mW
Láser	30 segundos
Temperatura de operación	-5°C _ 40°C
Temperatura de almacenamiento	-10°C _ 50°C
Vida útil de la batería	5000 mediciones
Tipo de batería	1.5V(AAA)x 2
Dimensiones	121x51x27mm
Peso	130g

Cuadro A.1.: Funciones básicas del medidor láser de distancia HoldPeak



Figura A.1.: Imagen del medidor láser de distancia

A.2. Cuadros de las figuras 5.7, 5.8 y 5.9

#Entradas	RMSE X(m)	RMSE Y(m)	RMSE promedio
3	7.19	10.76	8.975
4	18.29	21.17	19.73
5	8.66	13.35	11.005
6	18.41	23.05	20.73
7	10.57	14.40	12.48
8	10.88	16.19	13.53
9	9.79	14.64	12.215
10	8.87	12.91	10.89
11	8.71	12.37	10.54
12	9.19	13.23	11.21
13	8.69	9.37	9.03
14	6.74	7.89	7.315
15	2.49	4.94	3.715
16	2.17	3.73	2.95

Cuadro A.2.: Resultados de la comparación entre número de entradas y el error que produce en la estimación de la posición, red de 10 neuronas

#Neuronas	RMSE X(m)	RMSE Y(m)	RMSE promedio
1	5.95	7.05	6.50
5	5.62	9.34	7.48
10	5.71	8.19	6.95
15	6.74	7.37	7.05
20	13.04	18.40	15.72
25	6.08	6.47	6.28
30	6.34	8.44	7.39
35	7.24	14.68	10.96
40	5.36	6.27	5.81
45	9.11	13.32	11.22
50	7.74	14.77	11.26
55	7.68	11.01	9.35
60	17.34	14.27	15.80
65	7.04	12.72	9.88
70	14.37	5.58	9.98
75	15.58	11.32	13.45
80	7.11	7.14	7.13
85	8.47	9.51	8.99
90	9.62	9.34	9.48
95	10.05	10.59	10.32
100	6.631	19.86	13.25

Cuadro A.3.: Resultados de la comparación entre número de neuronas y el error que produce en la estimación de la posición, red de 14 entradas

# Neuronas	RMSE X	RMSE Y	RMSE promedio
1	3.88	4.16	4.02
5	2.60	4.45	3.53
10	3.28	5.59	4.43
15	2.99	6.37	4.68
20	8.03	8.99	8.51
25	2.69	8.02	5.36
30	5.75	7.99	6.87
35	4.64	13.08	8.86
40	4.87	7.12	5.99
45	7.87	8.42	8.15
50	6.39	6.39	6.39
55	6.23	5.48	5.85
60	6.51	9.18	7.84
65	5.67	6.50	6.09
70	8.77	9.68	9.22
75	8.89	7.51	8.20
80	12.10	7.41	9.76
85	10.54	13.67	12.10
90	6.22	9.34	7.78
95	5.91	11.32	8.62
100	8.04	7.54	7.79

Cuadro A.4.: Resultados de la comparación entre número de neuronas y el error que produce en la estimación de la posición, red de 16 entradas

A.3. Cuadro con los 100 puntos de los cuadros 4.3 y 4.4

Punto	X	Y	Puntos	X	Y	Punto	X	Y	Punto	X	Y
1	2.8	4	25	1.8	3.8	50	1.6	2.3	76	0.5	1.95
2	2.75	4.1	26	1.6	3.9	51	1.5	2.4	77	0.4	2
3	2.6	4.2	27	1.5	4	52	1.4	2.5	78	0.25	2.1
4	2.55	4.3	28	1.4	4.1	53	1.25	2.55	79	0.2	2.2
5	2.5	4.4	29	1.3	4	54	1.15	2.6	80	0.1	2.3
6	2.35	4.5	30	2	3	55	1	2.7	81	0.8	1.2
7	2.2	4.6	31	1.9	3.05	56	0.85	2.75	82	0.65	1.3
8	2.1	4.7	32	1.8	3.1	57	0.75	2.8	83	0.55	1.4
9	2	4.8	33	1.7	3.2	58	0.7	2.9	84	0.4	1.5
10	1.9	4.9	34	1.6	3.3	59	0.6	3	85	0.3	1.55
11	2.6	3.6	35	1.5	3.35	60	1.3	1.9	86	0.2	1.6
12	2.5	3.7	36	1.4	3.4	61	1.2	2	87	0.1	1.7
13	2.4	3.8	37	1.3	3.5	62	1.1	2.1	88	0	1.75
14	2.3	3.9	38	1.2	3.6	63	1	2.2	89	-0.1	1.8
15	2.1	4	39	1.1	3.7	64	0.9	2.25	90	-0.2	1.9
16	2	4.1	40	1.8	2.65	65	0.8	2.3	91	0.5	0.9
17	1.9	4.2	41	1.7	2.7	66	0.7	2.4	92	0.4	0.95
18	1.8	4.3	42	1.6	2.8	67	0.5	2.5	93	0.3	1
19	1.7	4.4	43	1.5	2.85	68	0.4	2.6	94	0.2	1.1
20	1.6	4.5	44	1.4	2.9	69	0.3	2.7	95	0.1	1.2
21	2.4	3.3	45	1.3	3	70	1	1.6	96	0	1.25
22	2.3	3.4	46	1.2	3.1	71	0.9	1.7	97	-0.1	1.35
23	2.1	3.5	47	1.1	3.2	72	0.8	1.8	98	-0.3	1.4
24	2	3.6	48	1	3.3	73	0.7	1.85	99	-0.4	1.5
25	1.9	3.7	49	0.9	3.35	74	0.6	1.9	100	-0.6	1.6

Cuadro A.5.: 100 puntos ML

A.4. Cuadro explicativo del Cuadro 4.33

Para obtener el RMSE promedio se ha tomado el promedio de X RMSE e Y RMSE

A.4 Cuadro explicativo del Cuadro 4.33

Escenarios	X RMSE	Y RMSE	RMSE promedio
Espacio libre	86.77m	100.94m	93.85m
Espacio libre +10dB	14.20m	17.99m	16.09m
Espacio libre + 10dB con 6 muestras	15.98m	14.11m	15.04 m
Ajuste1	44.43m	45.10m	44.76m
Ajuste 1 +10dB	17.28m	24.55m	20.91m
Ajuste 2	25.42m	27.26m	26.34 m
Ajuste2 +10dB	27.47m	35.80m	31.64 m
Ajuste2 +10 dB con 6 muestras	45.51m	59.17m	52.34 m
Multilateración	24.48m	37.65m	31.06 m
ML+trilateración	46.18m	18.89m	32.54 m
LVM14	13.81m	16.33m	15.07 m
BR14	12.82m	6.26m	9.54 m
SCG14	4.69m	5.77m	5.23 m
LVM16	9.79m	7.45m	8.62 m
BR16	10.11m	11.74m	10.92m
SCG16	11.83m	7.72m	9.78m
SCG16 Reentrenado	2.17m	3.73m	2.95m

Cuadro A.6.: Comparación de todos los enfoques incluido el mejor SCG reentrenado de 16 neuronas

A.5. Cuadro de comparación de todos los enfoques respecto al SCG16 reentrenado

Escenarios	SCG16 Reentrenado
Espacio libre	96.86 %
Espacio libre +10dB	81.67 %
Espacio libre + 10dB con 6 muestras	80.39 %
Ajuste1	93.41 %
Ajuste 1 +10dB	85.89 %
Ajuste 2	88.80 %
Ajuste2 +10dB	90.67 %
Ajuste2 +10 dB con 6 muestras	94.36 %
Multilateración	90.50 %
ML+trilateración	90.93 %
LVM14	80.42 %
BR14	69.08 %
SCG14	43.59 %
LVM16	65.78 %
BR16	72.99 %
SCG16	69.82 %

Cuadro A.7.: Comparación de todos los enfoques al SCG reentrenado de 16 neuronas. La mejora se da en porcentajes

A.6. Especificaciones de los modelos de AP Ruckus 500 y 600 respectivamente

[an ARRIS company, 2019a, an ARRIS company, 2019b]

ACCESS POINT ANTENNA PATTERN

Ruckus' BeamFlex+ adaptive antennas allow the R500 AP to dynamically choose among a host of antenna patterns (up to 64 possible combinations) in real-time to establish the best possible connection with every device. This leads to:

- Better Wi-Fi coverage
- Reduced RF interference

Traditional omni-directional antennas, found in generic access points, oversaturate the environment by needlessly radiating RF signals in all directions. In contrast, the Ruckus BeamFlex+ adaptive antenna directs the radio signals per-device on a packet-by-packet basis to optimize Wi-Fi coverage and capacity in real-time to support high device density environments. BeamFlex+ operates without the need for device feedback and hence can benefit even devices using legacy standards.

Figure 1. Example of BeamFlex+ pattern




Figure 2. R500 2.4GHz Azimuth Antenna Patterns



Figure 3. R500 5GHz Azimuth Antenna Patterns



Figure 4. R500 2.4GHz Elevation Antenna Patterns





Figure 5. R500 5GHz Elevation Antenna Patterns



Note: The outer trace represents the composite RF footprint of all possible BeamFlex+ antenna patterns, while the inner trace represents one BeamFlex+ antenna pattern within the composite outer trace.

WI-FI	
Wi-Fi Standards	<ul style="list-style-type: none"> IEEE 802.11a/b/g/n/ac
Supported Rates	<ul style="list-style-type: none"> 802.11ac: 6.5 to 867Mbps (MCS0 to MCS9, NSS = 1 to 2 for VHT20/40/80) 802.11n: 6.5 Mbps to 300Mbps (MCS0 to MCS15) 802.11a/g: 54, 48, 36, 24, 18, 12, 9, 6Mbps 802.11b: 11, 5.5, 2 and 1 Mbps
Supported Channels	<ul style="list-style-type: none"> 2.4GHz: 1-13 5GHz: 36-64, 100-144, 149-165
MIMO	<ul style="list-style-type: none"> 2X2 SU-MIMO
Spatial Streams	<ul style="list-style-type: none"> 2 SU-MIMO
Channelization	<ul style="list-style-type: none"> 20, 40, 80MHZ
Security	<ul style="list-style-type: none"> WPA-PSK, WPA-TKIP, WPA2 AES, 802.11i, Dynamic PSK WIPS/WIDS
Other Wi-Fi Features	<ul style="list-style-type: none"> WMM, Power Save, Tx Beamforming, LDPC, STBC, 802.11r/k/v Hotspot Hotspot 2.0 Captive Portal WISPr

RF	
Antenna Type	<ul style="list-style-type: none"> BeamFlex+ adaptive antennas with polarization diversity Adaptive antenna that provides up to 64 unique antenna patterns per band
Antenna Gain (max)	<ul style="list-style-type: none"> Up to 4dBi
Peak Transmit Power (aggregate across MIMO chains)	<ul style="list-style-type: none"> 2.4GHz: 22dBm 5GHz: 22dBm
Minimum Receive Sensitivity ¹	<ul style="list-style-type: none"> -100dBm
Frequency Bands	<ul style="list-style-type: none"> ISM (2.4-2.484GHz) U-NII-1 (5.15-5.25GHz) U-NII-2A (5.25-5.35GHz) U-NII-2C (5.47-5.725GHz) U-NII-3 (5.725-5.85GHz)

2.4GHZ RECEIVE SENSITIVITY			
HT20		HT40	
MCS0	MCS7	MCS0	MCS7
-92	-76	-89	-73

5GHZ RECEIVE SENSITIVITY					
VHT20		VHT40		VHT80	
MCS0	MCS7	MCS0	MCS7	MCS0	MCS7
-94	-76	-92	-74	-90	-69

2.4GHZ TX POWER TARGET	
Rate	Pout (dBm)
MCS0 HT20	22
MCS7 HT20	15

5GHZ TX POWER TARGET	
Rate	Pout (dBm)
MCS0 VHT20	22
MCS7 VHT20	18
MCS0 VHT40, VHT80	22
MCS7 VHT40, VHT80	18

PERFORMANCE AND CAPACITY	
Peak PHY Rates	<ul style="list-style-type: none"> 2.4GHz: 300Mbps 5 GHz: 867Mbps
Client Capacity	<ul style="list-style-type: none"> Up to 512 clients per AP
SSID	<ul style="list-style-type: none"> Up to 43 per AP

RUCKUS RADIO MANAGEMENT	
Antenna Optimization	<ul style="list-style-type: none"> BeamFlex+ Polarization Diversity with Maximal Ratio Combining (PD-MRC)
Wi-Fi Channel Management	<ul style="list-style-type: none"> ChannelFly Background Scan Based
Client Density Management	<ul style="list-style-type: none"> Adaptive Band Balancing Client Load Balancing Airtime Fairness Airtime-based WLAN Prioritization
SmartCast Quality of Service	<ul style="list-style-type: none"> QoS-based scheduling Directed Multicast L2/L3/L4 ACLs
Mobility	<ul style="list-style-type: none"> SmartRoam
Diagnostic Tools	<ul style="list-style-type: none"> Spectrum Analysis SpeedFlex

NETWORKING	
Controller Platform Support	<ul style="list-style-type: none"> SmartZone ZoneDirector Cloud Wi-Fi Unleashed² Standalone
Mesh	<ul style="list-style-type: none"> SmartMesh™ wireless meshing technology Self-healing Mesh
IP	<ul style="list-style-type: none"> IPv4, IPv6
VLAN	<ul style="list-style-type: none"> 802.1Q (1 per BSSID or dynamic per use based on RADIUS) VLAN Pooling Port-based
802.1x	<ul style="list-style-type: none"> Authenticator & Supplicant
Tunnel	<ul style="list-style-type: none"> L2TP, GRE, Soft-GRE
Policy Management Tools	<ul style="list-style-type: none"> Application Recognition and Control Access Control Lists Device Fingerprinting Rate Limiting

¹ Rx sensitivity varies by band, channel width and MCS rate.
² Refer to Unleashed datasheets for SKU ordering information.

PHYSICAL INTERFACES	
Ethernet	<ul style="list-style-type: none"> 2 x 1GbE ports, RJ-45

PHYSICAL CHARACTERISTICS	
Physical Size	<ul style="list-style-type: none"> 15.8(L) x 15.8(W) x 4(H) cm 6.2(L) x 6.2(W) x 1.57(H) in
Weight	<ul style="list-style-type: none"> 350g (0.77oz)
Mounting	<ul style="list-style-type: none"> Wall, Drop ceiling, Desk Secure bracket (sold separately)
Physical Security	<ul style="list-style-type: none"> Hidden latching mechanism Kensington lock T-bar Torx Bracket (902-0108-0000) Torx screw & padlock (sold separately)
Operating Temperature	<ul style="list-style-type: none"> 0°C (32°F) to 50°C (122°F)
Operating Humidity	<ul style="list-style-type: none"> Up to 95%, non-condensing

POWER ³	
Power Supply	Maximum Power Consumption
802.3af	<ul style="list-style-type: none"> 10.5W
12VDC-Powered	<ul style="list-style-type: none"> 11.1W

CERTIFICATIONS AND COMPLIANCE	
Wi-Fi Alliance ⁴	<ul style="list-style-type: none"> Wi-Fi CERTIFIED™ a, b, g, n, ac Passpoint®⁵, Vantage
Standards Compliance ⁵	<ul style="list-style-type: none"> EN 60950-1 Safety EN 60601-1-2 Medical EN 61000-4-2/3/5 Immunity EN 50121-1 Railway EMC EN 50121-4 Railway Immunity IEC 61373 Railway Shock & Vibration UL 2043 Plenum EN 62311 Human Safety/RF Exposure WEEE & RoHS ISTA 2A Transportation

SOFTWARE AND SERVICES	
Location Based Services	<ul style="list-style-type: none"> SPoT
Network Analytics	<ul style="list-style-type: none"> SmartCell Insight (SCI)
Security and Policy	<ul style="list-style-type: none"> Cloudpath

ORDERING INFORMATION	
901-R500-XX00	<ul style="list-style-type: none"> Concurrent dual band 802.11ac AP, no power adapter

See Ruckus price list for country-specific ordering information. Warranty: Sold with a limited lifetime warranty. For details see: <http://support.ruckuswireless.com/warranty>.

OPTIONAL ACCESSORIES	
902-0108-0000	<ul style="list-style-type: none"> Spare, accessory mounting bracket with padlock support
902-0120-0000	<ul style="list-style-type: none"> Spare, Accessory Mounting Bracket
902-0173-XXYY	<ul style="list-style-type: none"> Power Adapter (12V, 1.0A, 12W) (Sold in quantities of 1 or 10)
902-0162-XXYY	<ul style="list-style-type: none"> PoE injector (24W) (Sold in quantities of 1, 10 or 100)
902-0195-0000	<ul style="list-style-type: none"> Spare, T-bar ceiling mount kit for mounting to flush frame ceiling
902-1169-XX00	<ul style="list-style-type: none"> Power Supply (12V, 2.0A, 24W)

PLEASE NOTE: When ordering Indoor APs, you must specify the destination region by indicating -US, -WW, or -Z2 instead of XX. When ordering PoE injectors or power supplies, you must specify the destination region by indicating -US, -EU, -AU, -BR, -CN, -IN, -JP, -KR, -SA, -UK, or -UN instead of -XX. For access points, -Z2 applies to the following countries: Algeria, Egypt, Israel, Morocco, Tunisia, and Vietnam.

³ Max power varies by country setting, band, and MCS rate.

⁴ For complete list of WFA certifications, please see the Wi-Fi Alliance website.

⁵ For current certification status, please see the price list.

ACCESS POINT ANTENNA PATTERN

Ruckus' BeamFlex+ adaptive antennas allow the R600 AP to dynamically choose among a host of antenna patterns (up to 512 possible combinations) in real-time to establish the best possible connection with every device. This leads to:

- Better Wi-Fi coverage
- Reduced RF interference

Traditional omni-directional antennas, found in generic access points, over saturate the environment by needlessly radiating RF signals in all directions. In contrast, the Ruckus BeamFlex+ adaptive antenna directs the radio signals per-device on a packet-by-packet basis to optimize Wi-Fi coverage and capacity in real-time to support high device density environments. BeamFlex+ operates without the need for device feedback and hence can benefit even devices using legacy standards.

Figure 1. Example of BeamFlex+ pattern




Figure 2. R600 2.4GHz Azimuth Antenna Patterns



Figure 3. R600 5GHz Azimuth Antenna Patterns



Figure 4. R600 2.4GHz Elevation Antenna Patterns





Figure 5. R600 5GHz Elevation Antenna Patterns



Note: The outer trace represents the composite RF footprint of all possible BeamFlex+ antenna patterns, while the inner trace represents one BeamFlex+ antenna pattern within the composite outer trace.

WI-FI	
Wi-Fi Standards	<ul style="list-style-type: none"> IEEE 802.11a/b/g/n/ac
Supported Rates	<ul style="list-style-type: none"> 802.11ac: 6.5 to 1,300Mbps (MCS0 to MCS9, NSS = 1 to 3 for VHT20/40/80) 802.11n: 6.5 Mbps to 450Mbps (MCS0 to MCS23) 802.11a/g: 54, 48, 36, 24, 18, 12, 9, 6Mbps 802.11b: 11, 5.5, 2 and 1 Mbps
Supported Channels	<ul style="list-style-type: none"> 2.4GHz: 1-13 5GHz: 36-64, 100-144, 149-165
MIMO	<ul style="list-style-type: none"> 3x3 SU-MIMO
Spatial Streams	<ul style="list-style-type: none"> 3 SU-MIMO
Radio Chains and Streams	<ul style="list-style-type: none"> 3x3:3
Channelization	<ul style="list-style-type: none"> 20, 40, 80MHz
Security	<ul style="list-style-type: none"> WPA-PSK, WPA-TKIP, WPA2 AES, 802.11i, Dynamic PSK WIPS/WIDS
Other Wi-Fi Features	<ul style="list-style-type: none"> WMM, Power Save, Tx Beamforming, LDPC, STBC, 802.11r/k/v Hotspot Hotspot 2.0 Captive Portal WISPr

RF	
Antenna Type	<ul style="list-style-type: none"> BeamFlex+ adaptive antennas with polarization diversity Adaptive antenna that provides up to 512 unique antenna patterns per band
Antenna Gain (max)	<ul style="list-style-type: none"> Up to 3dBi
Peak Transmit Power (aggregate across MIMO chains)	<ul style="list-style-type: none"> 2.4GHz: 26dBm 5GHz: 25dBm
Minimum Receive Sensitivity ¹	<ul style="list-style-type: none"> -101dBm
Frequency Bands	<ul style="list-style-type: none"> ISM (2.4-2.484GHz) U-NII-1 (5.15-5.25GHz) U-NII-2A (5.25-5.35GHz) U-NII-2C (5.47-5.725GHz) U-NII-3 (5.725-5.85GHz)

2.4GHZ RECEIVE SENSITIVITY			
HT20		HT40	
MCS0	MCS7	MCS0	MCS7
-92	-78	-90	-84

5GHZ RECEIVE SENSITIVITY					
VHT20		VHT40		VHT80	
MCS0	MCS7	MCS0	MCS7	MCS0	MCS7
-95	-78	-91	-76	-89	-67

2.4GHZ TX POWER TARGET	
Rate	Pout (dBm)
MCS0 HT20	22
MCS7 HT20	15

5GHZ TX POWER TARGET	
Rate	Pout (dBm)
MCS0 VHT20	22
MCS7 VHT20	18
MCS0 VHT40, VHT80	22
MCS7 VHT40, VHT80	18

PERFORMANCE AND CAPACITY	
Peak PHY Rates	<ul style="list-style-type: none"> 2.4GHz: 450Mbps 5 GHz: 1300Mbps
Client Capacity	<ul style="list-style-type: none"> Up to 512 clients per AP
SSID	<ul style="list-style-type: none"> Up to 43 per AP

RUCKUS RADIO MANAGEMENT	
Antenna Optimization	<ul style="list-style-type: none"> BeamFlex+ Polarization Diversity with Maximal Ratio Combining (PD-MRC)
Wi-Fi Channel Management	<ul style="list-style-type: none"> ChannelFly Background Scan Based
Client Density Management	<ul style="list-style-type: none"> Adaptive Band Balancing Client Load Balancing Airtime Fairness Airtime-based WLAN Prioritization
SmartCast Quality of Service	<ul style="list-style-type: none"> QoS-based scheduling Directed Multicast L2/L3/L4 ACLs
Mobility	<ul style="list-style-type: none"> SmartRoam
Diagnostic Tools	<ul style="list-style-type: none"> Spectrum Analysis SpeedFlex

NETWORKING	
Controller Platform Support	<ul style="list-style-type: none"> SmartZone ZoneDirector Cloud Wi-Fi Unleashed² Standalone
Mesh	<ul style="list-style-type: none"> SmartMesh™ wireless meshing technology. Self-healing Mesh
IP	<ul style="list-style-type: none"> IPv4, IPv6
VLAN	<ul style="list-style-type: none"> 802.1Q (1 per BSSID or dynamic per use based on RADIUS) VLAN Pooling Port-based
802.1x	<ul style="list-style-type: none"> Authenticator & Supplicant
Tunnel	<ul style="list-style-type: none"> L2TP, GRE, Soft-GRE
Policy Management Tools	<ul style="list-style-type: none"> Application Recognition and Control Access Control Lists Device Fingerprinting Rate Limiting

PHYSICAL INTERFACES	
Ethernet	<ul style="list-style-type: none"> 2 x 1 GbE ports, RJ-45

¹ Rx sensitivity varies by band, channel width and MCS rate.
² Refer to Unleashed datasheets for SKU ordering information.

PHYSICAL CHARACTERISTICS	
Physical Size	<ul style="list-style-type: none"> 15.8(L) x 15.8 (W) x 1.57 (H) cm 6.22 (L) x 6.22 (W) x 0.5 (H) in
Weight	<ul style="list-style-type: none"> 364g (12.84oz)
Mounting	<ul style="list-style-type: none"> Wall, Drop ceiling, Desk Secure bracket (sold separately)
Physical Security	<ul style="list-style-type: none"> Hidden latching mechanism Kensington lock T-bar Torx Bracket (902-0108-0000) Torx screw & padlock (sold separately)
Operating Temperature	<ul style="list-style-type: none"> 0 °C (32 °F) to 40 °C (104 °F)
Operating Humidity	<ul style="list-style-type: none"> Up to 95%, non-condensing

POWER ³	
Power Supply	Maximum Power Consumption
802.3af	<ul style="list-style-type: none"> 11.2W
DC	<ul style="list-style-type: none"> 11.8W

CERTIFICATIONS AND COMPLIANCE	
Wi-Fi Alliance ⁴	<ul style="list-style-type: none"> Wi-Fi CERTIFIED™ a, b, g, n, ac Passpoint®, Vantage
Standards Compliance ⁵	<ul style="list-style-type: none"> EN 60950-1 Safety EN 60601-1-2 Medical EN 61000-4-2/3/5 Immunity EN 50121-1 Railway EMC EN 50121-4 Railway Immunity IEC 61373 Railway Shock & Vibration UL 2043 Plenum EN 62311 Human Safety/RF Exposure WEEE & RoHS ISTA 2A Transportation

SOFTWARE AND SERVICES	
Location Based Services	<ul style="list-style-type: none"> SPoT
Network Analytics	<ul style="list-style-type: none"> SmartCell Insight (SCI)
Security and Policy	<ul style="list-style-type: none"> Cloudpath

ORDERING INFORMATION	
901-R600-XX00	<ul style="list-style-type: none"> Concurrent dual band 802.11ac AP, no power adapter

See Ruckus price list for country-specific ordering information.
 Warranty: Sold with a limited lifetime warranty.
 For details see: <http://support.ruckuswireless.com/warranty>.

OPTIONAL ACCESSORIES	
902-0162-XXYY	<ul style="list-style-type: none"> PoE injector (24W) (Sold in quantities of 1, 10 or 100)
902-0195-0000	<ul style="list-style-type: none"> Spare, T-bar ceiling mount kit for mounting to flush frame ceiling
902-1169-XX00	<ul style="list-style-type: none"> Power Supply (12V, 2.0A, 24W)
902-0120-0000	<ul style="list-style-type: none"> Spare, Accessory Mounting Bracket
902-0108-0000	<ul style="list-style-type: none"> Spare, accessory mounting bracket with padlock support
902-0173-XXYY	<ul style="list-style-type: none"> Power Adapter (12V, 1.0A, 12W) (Sold in quantities of 1 or 10)

PLEASE NOTE: When ordering Indoor APs, you must specify the destination region by indicating -US, -WW, or -Z2 instead of XX. When ordering PoE injectors or power supplies, you must specify the destination region by indicating -US, -EU, -AU, -BR, -CN, -IN, -JP, -KR, -SA, -UK, or -UN instead of -XX.

For access points, -Z2 applies to the following countries: Algeria, Egypt, Israel, Morocco, Tunisia, and Vietnam.

³ Max power varies by country setting, band, and MCS rate.

⁴ For complete list of WFA certifications, please see the Wi-Fi Alliance website.

⁵ For current certification status, please see the price list.

Bibliografía

- [an ARRIS company, 2019a] an ARRIS company, R. (2019a). R500 indoor 802.11 ac 2x2:2 wi-fi access point datasheet. url<https://ruckus-www.s3.amazonaws.com/pdf/datasheets/ds-ruckus-r500.pdf>. Accedido 21-6-2019.
- [an ARRIS company, 2019b] an ARRIS company, R. (2019b). R600 indoor 802.11 ac 3x3:3 wi-fi access point data sheet. url<https://ruckus-www.s3.amazonaws.com/pdf/datasheets/ds-ruckus-r600.pdf>. Accedido 21-6-2019.
- [Blanco et al., 2017] Blanco, R., Fontrodona, J., and Poveda, C. (2017). La industria 4.0. el estado de la cuestión. *Revista Economía Industrial*, 2017(404):13.
- [Boonsriwai and Apavatjirut, 2013] Boonsriwai, S. and Apavatjirut, A. (2013). Indoor wifi localization on mobile devices. In *2013 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, pages 1–5.
- [Chintalapudi et al., 2010] Chintalapudi, K., Padmanabha Iyer, A., and Padmanabhan, V. N. (2010). Indoor localization without the pain. In *Proceedings of the Sixteenth Annual International Conference on Mobile Computing and Networking, MobiCom '10*, pages 173–184, New York, NY, USA. ACM.
- [Developers, 2019] Developers, G. (2019). Características y api de android 9). url<https://developer.android.com/about/versions/pie/android-9.0?hl=es-419>. Accedido 22-10-2019.
- [Electronicsnotes, 2019] Electronicsnotes (2019). Wi-fi channels, frequencies, bands & bandwidths. url<https://www.electronics-notes.com/articles/connectivity/wifi-ieee-802-11/channels-frequencies-bands-bandwidth.php>. Accedido 21-6-2019.
- [Farahani, 2008a] Farahani, S. (2008a). Chapter 5. rf propagation, antennas, and regulatory requirements. In Farahani, S., editor, *ZigBee Wireless Networks and Transceivers*, pages 171 – 206. Newnes, Burlington.
- [Farahani, 2008b] Farahani, S. (2008b). Chapter 7. location estimation methods. In Farahani, S., editor, *ZigBee Wireless Networks and Transceivers*, pages 225 – 246. Newnes, Burlington.
- [Farid et al., 2013] Farid, Z., Nordin, R., and Ismail, M. (2013). Recent advances in wireless indoor localization techniques and system. *Journal of Computer Networks and Communications*, vol. 2013:12.

- [Figuera et al., 2011] Figuera, C., Rojo-Álvarez, J. L., Mora-Jiménez, I., Guerrero-Curieses, A., Wilby, M., and Ramos-López, J. (2011). Time-space sampling and mobile device calibration for WiFi indoor location systems. *IEEE Transactions on Mobile Computing*, 10(7):913–926.
- [Gerez et al., 2020] Gerez, A., Goñi, O. E., and Leiva, L. (2020). Aumento de precisión en localización indoor basado en redes neuronales. *Elektron: ciencia y tecnología en la electrónica de hoy*, 4(2):74–80.
- [Gómez and Pedraza, 2018] Gómez, C. A. and Pedraza, L. F. (2018). Ubicación de dispositivos móviles en ambientes interiores por medio de análisis de radiación de redes wifi y deformaciones de campo magnético. *Ingeniare. Revista chilena de ingeniería*, 26(2):203–212.
- [Gu et al., 2019] Gu, F., Hu, X., Ramezani, M., Acharya, D., Khoshelham, K., Valae, S., and Shang, J. (2019). Indoor localization improved by spatial context a survey. *ACM Computing Surveys (CSUR)*, 52(3):1–35.
- [He and Chan, 2016] He, S. and Chan, S. . G. (2016). Wi-fi fingerprint-based indoor positioning: Recent advances and comparisons. *IEEE Communications Surveys Tutorials*, 18(1):466–490.
- [Ignatov et al., 2018] Ignatov, A., Timofte, R., Chou, W., Wang, K., Wu, M., Hartley, T., and Gool, L. V. (2018). Ai benchmark: Running deep neural networks on android smartphones. In *ECCV Workshops*.
- [Inc, 2002] Inc, W. (2002). Converting signal strength percentage to dbm values. Technical report, I. WildPacket.
- [Kuhllins et al., 2020] Kuhllins, C., Rathonyi, B., Zaidi, A., and Hogan, M. (2020). Cellular networks for massive iot. *Ericsson White Paper*, 1217.
- [Li et al., 2021] Li, Y., Zhuang, Y., Hu, X., Gao, Z., Hu, J., Chen, L., He, Z., Pei, L., Chen, K., Wang, M., Niu, X., Chen, R., Thompson, J., Ghannouchi, F. M., and El-Sheimy, N. (2021). Toward location-enabled IoT (LE-IoT): IoT positioning techniques, error sources, and error mitigation. *IEEE Internet of Things Journal*, 8(6):4035–4062.
- [Liu et al., 2007] Liu, H., Darabi, H., Banerjee, P., and Liu, J. (2007). Survey of wireless indoor positioning techniques and systems. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 37(6):1067–1080.
- [Liu et al., 2012] Liu, H., Gan, Y., Yang, J., Sidhom, S., Wang, Y., Chen, Y., and Ye, F. (2012). Push the limit of wifi based localization for smartphones. In *Proceedings of the 18th Annual International Conference on Mobile Computing and Networking, Mobicom '12*, pages 305–316, New York, NY, USA. ACM.
- [Liu and Yang, 2011] Liu, H.-H. and Yang, Y.-N. (2011). Wifi-based indoor positioning for multi-floor environment. In *TENCON 2011 - 2011 IEEE Region 10 Conference*, pages 597–601.

- [Mathworks.Inc., 2019a] Mathworks.Inc., T. (2019a). Bayesian regularization backpropagation. url<https://la.mathworks.com/help/deeplearning/ref/trainbr.html>. Accedido 19-10-2019.
- [Mathworks.Inc., 2019b] Mathworks.Inc., T. (2019b). Levenberg-marquardt backpropagation. url<https://la.mathworks.com/help/deeplearning/ref/trainlm.html>. Accedido 19-10-2019.
- [Mathworks.Inc., 2019c] Mathworks.Inc., T. (2019c). Machine learning (tres cosas que es necesario saber). url<https://la.mathworks.com/discovery/machine-learning.html>. Accedido 10-10-2019.
- [Mathworks.Inc., 2019d] Mathworks.Inc., T. (2019d). Scaled conjugate gradient backpropagation. url<https://la.mathworks.com/help/deeplearning/ref/trainscg.html>. Accedido 19-10-2019.
- [Obeidat et al., 2021] Obeidat, H., Shuaieb, W., Obeidat, O., and Abd-Alhameed, R. (2021). A review of indoor localization techniques and wireless technologies. *Wireless Personal Communications*, 119(1):289–327.
- [Onkar et al., 2014] Onkar, P., Pratik, P., Rajesh, P., and Mayur, T. (2014). Wi-Fi indoor positioning system based on RSSI measurements from Wi-Fi access points a trilateration approach. *International Journal of Scientific & Engineering Research*, 5.
- [Patton et al., 2019] Patton, E. W., Tissenbaum, M., and Harunani, F. (2019). *MIT App Inventor: Objectives, Design, and Development*, pages 31–49. Springer Singapore, Singapore.
- [Rábanos et al., 2013] Rábanos, J., Tomás, L., and Salis, J. (2013). *Transmisión por radio*. Ingeniería y ciencias. Centro de Estudios Ramón Areces.
- [Tejada, 2018] Tejada, J. L. O. (2018). Design and implementation of an rf system for interiors.
- [Wu et al., 2013] Wu, C., Yang, Z., Liu, Y., and Xi, W. (2013). Will: Wireless indoor localization without site survey. *IEEE Transactions on Parallel and Distributed Systems*, 24(4):839–848.
- [Zafari et al., 2019] Zafari, F., Gkelias, A., and Leung, K. K. (2019). A survey of indoor localization systems and technologies. *IEEE Communications Surveys Tutorials*, 21(3):2568–2599.

Nomenclatura

AOA	Angle of Arrival(Ángulo de llegada)
AP	Access Point(punto de acceso)
APK	Android Application Package(paquete de aplicaciones de Android)
BR	Bayesian Regularization(regularización bayesiana)
BS	Base Station(estación base)
Cell-ID	Cell Identification(Identificación de celda)
COO	Cell of Origin(Celda de origen)
CSI	Channel State Information(Información de estado del canal)
DOA	Direction of Arrival(Dirección de llegada)
FLOPS	Operador de Coma Foltante por segundo(Floating point operations per second)
GPS	Global Positioning System(sistema global de posicionamiento)
GPU	Unidad de Procesamiento Gráfico(Graphics Processing Unit)
I+D+i	Investigación,Desarrollo e innovación
IA	Inteligencia Artificial
INS	Inertial Navigation System(sistema de navegación inercial)
IoT	Internet of Things(Internet de las cosas)
IR	Infra Rojo
LBS	Localization Based Services(servicios basados en localización)
LOS	Line of Sight(Con línea de vista)
LVM	Levenberg Marquard

M2M	Machine to Machine(máquina a máquina)
ML	Machine Learning(Aprendizaje máquina o automático)
NLOS	Non Line of Sight(Sin línea de vista)
OEM	Onda Electromagnética
POA	Phase of Arrival(Fase de llegada)
RFID	Radio Frequency Identification(Identificación basada en radiofrecuencia)
RN	Red Neuronal
RSSI	Received Signal Strength Indicator(indicador de fuerza de señal recibida)
RTOF	Round-Trip Time of Flight(Tiempo de vuelo de ida y vuelta)
RTT	Round-trip Time(Tiempo de ida y vuelta)
SCG	Scaled Conjugated Gradient(Gradiente conjugado escalado)
SMP	Smallest M-vertex polygon(Polígono de vértice más pequeño)
SVM	Support Vector Machine(Maquina vector soporte)
TDOA	Time Difference of Arrival(Diferencia de tiempo de llegada)
TOA	Time of Arrival(Tiempo de llegada)