

Escuela Técnica Superior de Ingeniería de Telecomunicación



**Estudio de la función monopulso como un input de un sistema de
posicionamiento basado en machine learning**

Trabajo fin de máster

María Pérez Buitrago

01/07/2019



Directores:

José Luís Gómez Tornero

José Antonio López Pastor

Contenido

Resumen	3
Capítulo 1	4
INTRODUCCIÓN	4
1.1 Principales conceptos	6
1.3 Equipos de medida	9
Capítulo 2	12
MEDIDA SIN MULTIPATH Y UN SOLO SNIFFER	12
2.1 Resultados obtenidos	12
2.1 Resultado con sniffer 2	19
Capítulo 3	26
Medida sin multipath con dos sniffers funcionando simultáneamente	26
3.1 Función monopulso y DoA	28
3.2 Localización de un punto exacto	34
Capítulo 4	38
Entorno con multipath	38
Capítulo 5	51
DOA COMO INPUT DE UN SISTEMA DE POSICIONAMIENTO BASADO EN MACHINE LEARNING.51	
5.1 Entorno sin multipath	51
5.2 Entorno con multipath	57
5.3 Entorno con multipath. Localización de terminales distintos a los empleados en la calibración.	62
Capítulo 6	67
CONCLUSIONES	67
Capítulo 7	68
LÍNEAS FUTURAS	68
BIBLIOGRAFÍA	69

Resumen

En este trabajo se va a estudiar posibilidad de emplear la función monopolso, generada a partir de la RSSI adquirida por sniffers, como input de un sistema de localización pasivo de dispositivos WiFi (smartphones y dispositivos IoT) en entornos indoor. Para estudiar todos los factores que intervienen en este tipo de sistema novedoso, de forma iterativa, se ha realizado una serie de experimentos empleando un único sniffer monopolso. La señal recibida ha sido empleada como input de un sistema de machine learning que nos permitirá inferir una función de clasificación. Posteriormente se realizaron pruebas empleando dos sniffer de forma simultánea con el fin de averiguar cómo de preciso es función monopolso para poder estimar la posición exacta.

Capítulo 1

INTRODUCCIÓN

El objetivo principal de este proyecto es profundizar en el estudio la función monopulso en entornos multipath como entrada de un sistema de localización de terminales móviles WiFi empleando sniffer híbridos analógicos digitales y antenas directivas.

La técnica monopulso permite obtener el ángulo de llegada (DoA de las siglas en inglés) de los terminales WiFi a localizar mediante la comparación de dos señales recibidas de cada una de las diferentes antenas directivas. Por un lado se tiene el diagrama diferencia $\Delta(\theta)$ y por otro el diagrama suma $\Sigma(\theta)$. Para obtener el diagrama suma se hace la suma del nivel de RSSI obtenido por la antena 1 y el valor de RSSI obtenido por la antena 2. Mientras que para obtener el diagrama diferencia se hace la resta del nivel de RSSI obtenido por la antena 1 y el valor de RSSI obtenido por la antena 2. La técnica monopulso permite obtener una función que relaciona el ángulo azimutal del blanco con la relación de amplitudes o fases de los diagramas suma y diferencia enunciados anteriormente. La función se calcula según la siguiente expresión, conocida como función monopulso [1]:

$$\Psi_{(\theta)} = \frac{\Delta(\theta)}{\Sigma(\theta)}$$

Para calcular la función monopulso, se ha medido el diagrama de radiación de dos antenas de panel directivas en cámara anecoica. Para esto, el smartphone transmite tramas WiFi que son capturadas por el sniffer. El nivel de RSSI en cada canal de antena ($i = 1,2$) se obtiene a medida que el ángulo acimutal relativo de visibilidad directa (LoS) barre de -90° a 90° . Puesto que el nivel de RSSI de una antena es inferior al nivel de RSSI de otra, es necesario aplicar un factor de corrección que se denomina K_D . [2]

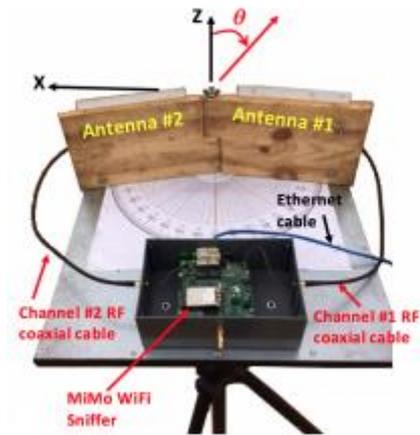


Figura 1. Antenas de panel y sniffer

Este factor de corrección K_D se extrae de los niveles medidos de RSSI en la dirección perpendicular $\theta = 0^\circ$:

$$K_D = \frac{RSSI_1(\theta = 0^\circ)}{RSSI_2(\theta = 0^\circ)}$$

$$K_D = RSSI_1(0^\circ) - RSSI_2(0^\circ) \quad (\text{dB})$$

Una vez obtenido el factor de corrección, se puede definir la función a partir de los valores RSSI relativos en diferentes ángulos:

$$\psi_D = \frac{\Delta_D(\theta)}{\sum_D(\theta)} = \frac{RSSI_1(\theta) - K_D \cdot RSSI_2(\theta)}{RSSI_1(\theta) + K_D \cdot RSSI_2(\theta)}$$

Esta función digital se representa en la siguiente figura que es comparada con la función analógica y teórica monopulso. Se obtiene un Field of view (FoV) reducido de $[-30^\circ, +20^\circ]$, es decir, donde se es capaz de localizar.

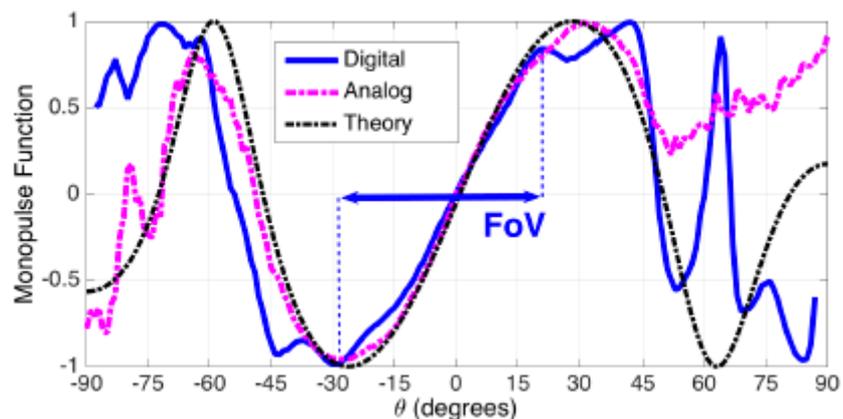


Figura 2. Función monopulso digital, analógica y teórica

Para cumplir con el objetivo fundamental del proyecto, se han planteado una serie de cuestiones relevantes. Estas cuestiones son las siguientes:

- ¿Cuántos metros cuadrados se puede cubrir con un único dispositivo?
- En trabajos previos, realizados en entorno sin multipath, la función monopolso ha determinado con éxito el DoA. Pero, ¿se puede emplear la función monopolso para estimar la posición y no solo el DoA en entorno con multipath?
- En los entornos reales como universidades, centros comerciales u hospitales se tienen paredes y suelos/techos de muy diversas características que provocan multipath. ¿Cómo afecta el multipath a la función monopolso?
- Heterogeneidad del hardware a localizar. Utilización de distintas antenas, chipset o smartphones. ¿Cuál es la variación de la función monopolso ante distinto hardware a localizar?
- ¿Se puede emplear la función monopolso como entrada de un algoritmo de posicionamiento basado en machine learning?
- Variabilidad de la RSSI ante cambios del entorno como puede ser la presencia de gente, movimiento de puertas, temperatura o humedad. Se conoce que todos estos factores pueden afectar a la variabilidad de la RSSI. ¿Cómo afecta a la función monopolso la alta variabilidad de la RSSI?
- Los dispositivos a localizar pueden estar en movimiento, ¿cómo afecta el movimiento a la precisión de la función monopolso? (Este punto es similar al movimiento en la cámara de girar y subir/bajar el smartphone)
- Si la zona a localizar es muy extensa y los dispositivos a localizar están en movimiento (suponed el movimiento natural de los smartphone por una universidad, centro comercial, etc), y se desea implementar un sistema de localización por clase/aula/zona, ¿se puede emplear la función monopolso para localizar con estas premisas? (calibración cost-effective).

El objetivo de este proyecto es resolver las cuestiones enunciadas anteriormente. Para ello se han realizado los siguientes experimentos que se describen a continuación. Primero se realizan experimentos en entornos sin multipath con un solo sniffer. Los resultados de estas pruebas se muestran en el capítulo 2. A continuación se realizaron las pruebas en un entorno sin multipath pero utilizando dos sniffers de forma simultánea esperando estimar la posición del móvil. Los resultados de este experimento se detallan en el capítulo 3. Una vez hecho el estudio en un entorno sin multipath, se realiza una campaña de medida en un entorno con multipath. Los resultados obtenidos se analizan en el capítulo 4. Tras en el análisis de la función monopolso en entornos con y sin multipath, se va a estudiar el DOA como input de un sistema de posicionamiento basado en machine learning empleando redes neuronales. Se estudiarán escenarios con multipath y sin multipath para comprobar su performance. Los resultados de este experimento se explicarán con detalle en el capítulo 5. Durante la realización de todos los experimentos se han empleado hasta 7 smartphones con interfaz WiFi diferentes con el fin de comprobar el funcionamiento del sistema ante el conocido problema de la heterogeneidad del hardware.

1.1 Principales conceptos

Antes de empezar a tratar los distintos experimentos y de explicar la metodología de este proyecto, se definen a continuación los conceptos más importantes que serán empleados a lo largo de este trabajo.

- **Sniffer**

Un sniffer es una aplicación especial para redes informáticas, que permite como tal capturar los paquetes que viajan por una red. Un sniffer puede capturar paquetes dependiendo de la topología de red.

En nuestro caso, el método usado es MAC-based sniffing que funciona poniendo la tarjeta de red en modo promiscuo y olfateando todos los paquetes que coincida con el filtro de direcciones MAC. Por lo tanto, el sniffer nos permitirá filtrar a nivel de MAC el tráfico para poder capturar los paquetes y así extraer los parámetros que nos interesen como son el nivel de RSSI y el timestamp, entre otros.

- **DoA - Direction of arrival**

La técnica denominada dirección de llegada (DoA), localiza la estación móvil determinando el ángulo de incidencia en el que las señales llegan al sensor receptor. Las relaciones geométricas pueden usarse entonces para estimar la ubicación desde la intersección de dos líneas formadas por una línea radial con cada sensor receptor, como se ilustra en la figura 2. En un plano bidimensional, se requieren al menos dos receptores para la estimación de localización con una cierta precisión y de al menos tres o más receptores (triangulación) para mejorarla.

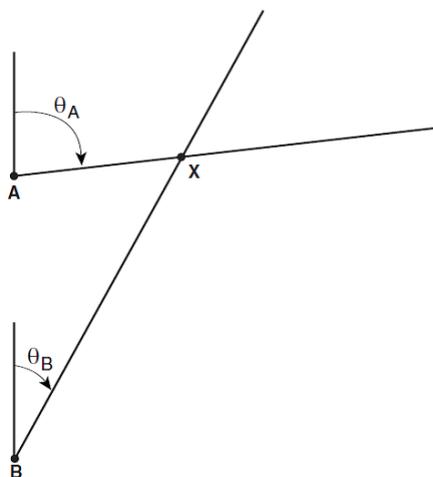


Figura 3 Angle of Arrival

- **RSSI**

El indicador de potencia de la señal recibida (RSSI por las siglas del inglés Received Signal Strength Indicator), es una escala de referencia para medir el nivel de potencia de las señales recibidas por un dispositivo en las redes inalámbricas. La diferencia entre la potencia física medida en dBm y la RSSI, es que ésta última es un índice relativo, mientras que dBm es un número absoluto que representa los niveles de potencia en mW. El estándar IEEE 802.11 especifica que RSSI puede estar en una escala de 0 a 255 y que cada fabricante de chipset puede definir su propio valor RSSI Max”.

Aunque se trate de una medida relativa, lo que está claro es que cuanto mayor sea el valor de RSSI mayor será la intensidad de la señal.

- **Antenas directivas**

Se trata de una antena capaz de concentrar la mayor parte de la energía radiada de manera localizada, aumentando así la potencia emitida hacia el receptor o desde la fuente deseada y evitando interferencias introducidas por fuentes no deseadas. En la figura 3 se muestra un

diagrama de radiación típico de este tipo de antenas. Se puede observar un lóbulo principal donde se tiene la máxima potencia.

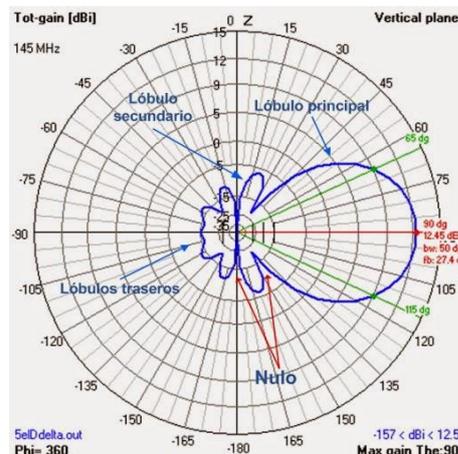


Figura 4. Diagrama de radiación de una antena direccional

- **Red Neuronal**

Las Redes Neuronales (ANN: Artificial Neural Networks) surgieron originalmente como una simulación abstracta de los sistemas nerviosos biológicos. Están constituidos por un conjunto de unidades llamadas neuronas conectadas unas con otras.

El elemento básico de computación (modelo de neurona) es un nodo o unidad. Recibe un input desde otras unidades o de una fuente externa de datos. Cada input tiene un peso asociado w , que se va modificando en el llamado proceso de aprendizaje. Cada unidad aplica una función dada f de la suma de los inputs ponderadas mediante los pesos:

$$Y_i = \sum_j^N W_{ij} Y_j$$

Hay dos fases en la modelización con redes neuronales:

- Fase de entrenamiento (Training): se usa un conjunto de datos o patrones de entrenamiento para determinar los pesos (parámetros) que definen el modelo de red neuronal. Se calculan de manera iterativa, de acuerdo con los valores de entrenamiento, con el objeto de minimizar el error cometido entre la salida obtenida por la red neuronal y la salida deseada.
- Fase de Prueba (Test): en la fase anterior, el modelo puede que se ajuste demasiado a las particularidades presentes en los patrones de entrenamiento, perdiendo su habilidad de generalizar su aprendizaje a casos nuevos (sobreajuste). Para evitar el problema del sobreajuste, es aconsejable utilizar un segundo grupo de datos diferentes a los de entrenamiento, el grupo de validación, que permita controlar el proceso de aprendizaje. [3]

1.3 Equipos de medida

El sistema híbrido analógico-digital que se ha empleado para obtener la función monopulso de terminales WiFi se muestra a continuación:

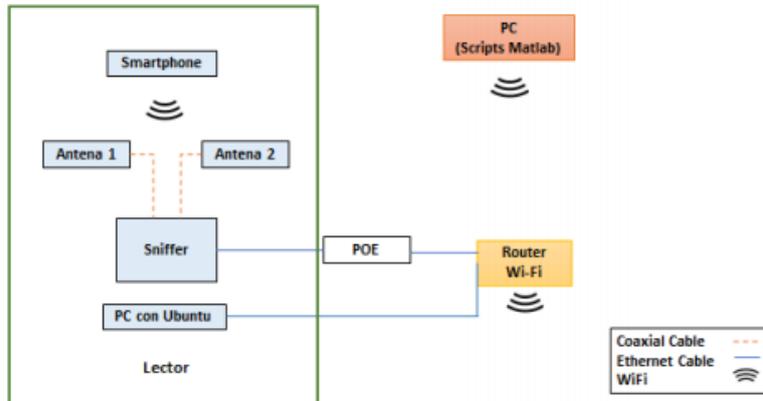


Figura 5. Diagrama de bloques del sistema



Figura 6. Sistema Monopulso WiFi

Como se muestra en la figura 5, el sistema cuenta con un terminal móvil conectado a un punto de acceso WiFi que ejecuta una aplicación en Android para forzar la transmisión de las tramas a intervalos regulares. Las antenas del lector reciben las tramas transmitidas por el terminal en cualquier momento. El lector cuenta con una tarjeta WiFi en modo promiscuo para capturar las tramas. En el lado del servidor, se registran y almacenan los datos brutos recibidos desde el lector. Por último, mediante un socket UDP los datos sin procesar llegan a un PC que, a través

de scripts de MATLAB determinar el ángulo de llegada. Para que todo el sistema funcione correctamente es necesario que todos los elementos se conecten a la misma red WiFi.

Los elementos del sistema enunciados anteriormente, con un mayor grado de detalle se describen a continuación. Se cuenta con dos antenas de panel comerciales de 2.4 GHz. El sniffer consta de una tarjeta MIMO 3x3 WiFi de Atheros, aunque solamente se emplean dos de ellas, una para cada antena, quedando la otra entrada aislada. Un PC con sistema operativo Ubuntu que cuenta con un programa de control que se encarga de la gestión de los sniffer, realizando entre otras tareas la de poner la tarjeta WiFi de los sniffer en modo promiscuo. Con respecto a la posición de las antenas directivas, estas se encuentran inclinadas con el mismo ángulo de 7°. Esto es imprescindible para obtener una potencia relativa distinta en cada una de ellas. Si solo utilizásemos una antena, resulta evidente que, a medida que nos alejamos de la antena, nos llega menos potencia y si nos acercamos, esta aumentaría. En temas de localización esto daría lugar a confusión puesto que si un obstáculo se interpone entre la antena y el teléfono móvil estaremos recibiendo menos potencia, aunque nos encontremos más cerca de la antena y el sistema interpretaría que nos hemos alejado. Por tanto, es necesario obtener lo que definimos como función de error o función monopulso. Con un solo sistema, sólo es posible conocer el ángulo de llegada, no pudiendo conocer la posición exacta mediante la función monopulso. Sin embargo, mediante la combinación de dos sistemas monopulso es posible de conocer la posición exacta de los smartphones que se desea localizar. Gracias a la combinación de las señales de dos sniffers trabajando de forma simultánea.

En la siguiente tabla se muestran los teléfonos empleados en este estudio. Como se puede observar, son distintos modelos y versiones de Android.

Nº dispositivo	Modelo	Android
1	Sony Experia SGP312	4.4.4
2	Xiaomi Redmi Note 1 LTE	4.4.4
3	BQ Aquaris M8	6
4	Huawey P10 lite	8
5	Motorola Moto G LTE	6
6	Xiaomi Mi5	7
7	Huawei P8Lite 2017	8



Figura 7. a) Sony Experia SGP312 b) Xiaomi Redmi Note 1 LTE c) Huawei P8 Lite 2017 d)BQ Aquarius M8 e) Huawei P10 Lite f) Motorola Moto G LTE g) Xiaomi Mi5

Se emplean 2 sniffer distintos:

Sniffer	Modelo MiMo WiFi Card	Embebed PC
1	Atheros AR9380 chipset	Compex WPJ344
2	Atheros AR9380 chipset	Compex WPJ531

En los siguientes puntos se describen los experimentos realizados tanto con un solo sniffer como con los dos sniffer trabajando de modo simultáneo. Se explicará con alto grado de detalle los resultados de los experimentos realizados, así como las conclusiones obtenidas en cada uno de ellos.

Capítulo 2

MEDIDA SIN MULTIPATH Y UN SOLO SNIFFER

Este primer experimento se ha realizado en cámara anecoica. Se trata de un entorno ideal que evita el multipath. Permite de esta forma estudiar el comportamiento de varios terminales móviles con respecto a la función monopulso evitando otro tipo de interferencias. Mediante el experimento se pretende explorar la independencia de la función monopulso ante la heterogeneidad del hardware.

Para este propósito, se ha fijado el sniffer 1 en el extremo de la cámara y centrado de ambas paredes. Los terminales móviles se han situado a 0° , 10° y -10° con respecto del sniffer. La distancia entre el sistema y los distintos terminales es de 310 cm.

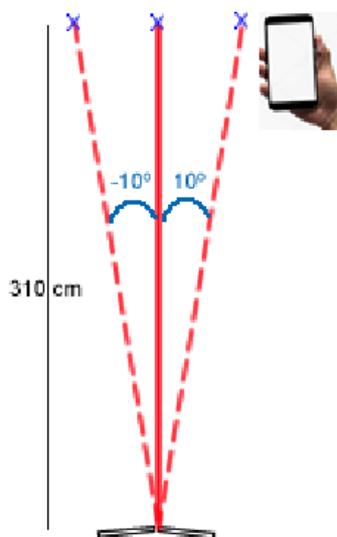


Figura 8. Posición de Sniffer y Smartphone

El objetivo de este experimento era comprobar que, aunque cada terminal cuenta con un hardware diferente y que esto puede influir en el nivel de RSSI, la función monopulso es estable.

2.1 Resultados obtenidos

De este sniffer con estas antenas se tiene el diagrama de radiación y se tiene un factor de corrección $K_{Dsniffer1}=2.0712$ dB sobre la antena 1. Es decir, es necesario aplicar el factor de

corrección sobre la antena 1 para que ambas reciban el mismo nivel de RSSI y así determinar que se está en el centro cuando el terminal móvil está a 0°.

A continuación, se describe el resultado de todos los experimentos, para cada uno de los teléfonos en cada una de las posiciones angulares enunciadas anteriormente. Para cada uno de los experimentos, en la primera gráfica se muestra el nivel de RSSI recibido por cada antena, en la gráfica central se muestra el resultado de la función monopulso y en la última se puede ver el ángulo de llegada asociado a dicha función. Como se ha comentado anteriormente, para cada smartphone se hicieron tres medidas. Una a cero grados, es decir, con el teléfono móvil perpendicular al sistema de localización y otras dos con el sistema a 10° y -10°. Los teléfonos empleados en la realización de estos experimentos han sido la Tablet BQ y Xiaomi Redmi Note 1.

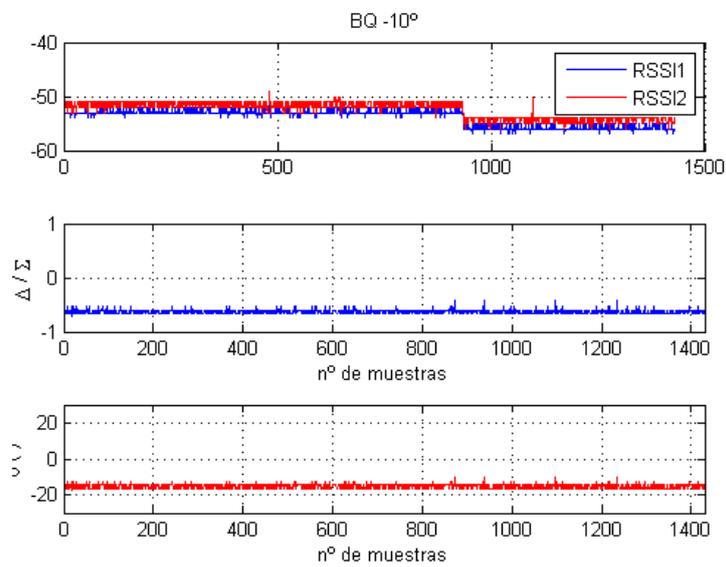


Figura 9. Función Monopulso BQ -10°

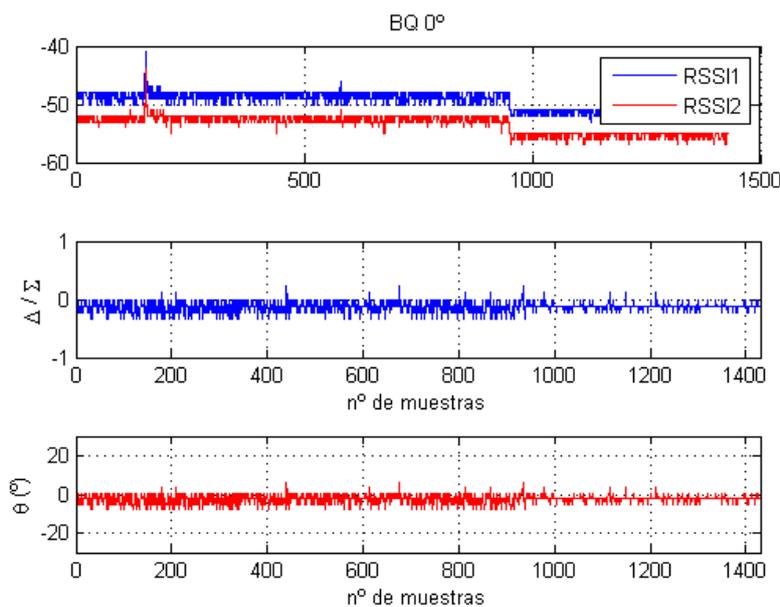


Figura 10. Función Monopulso BQ 0°

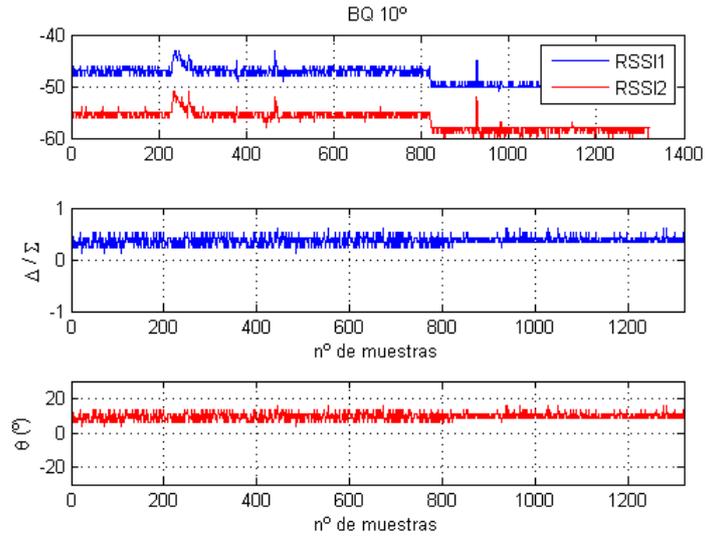


Figura 11. Función Monopulso BQ 10°

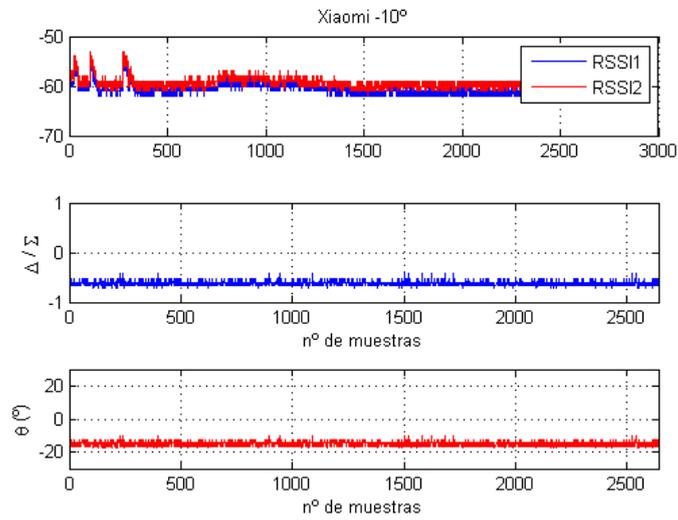


Figura 12. Función Monopulso Xiaomi Redmi -10°

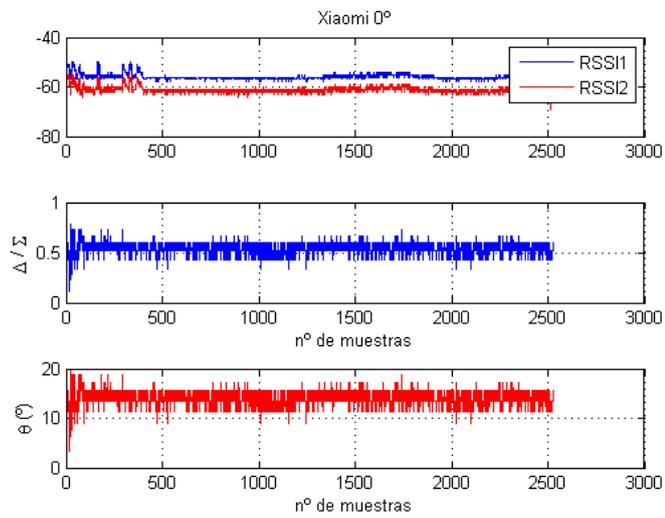


Figura 13. Función Monopulso Xiaomi Redmi 0°

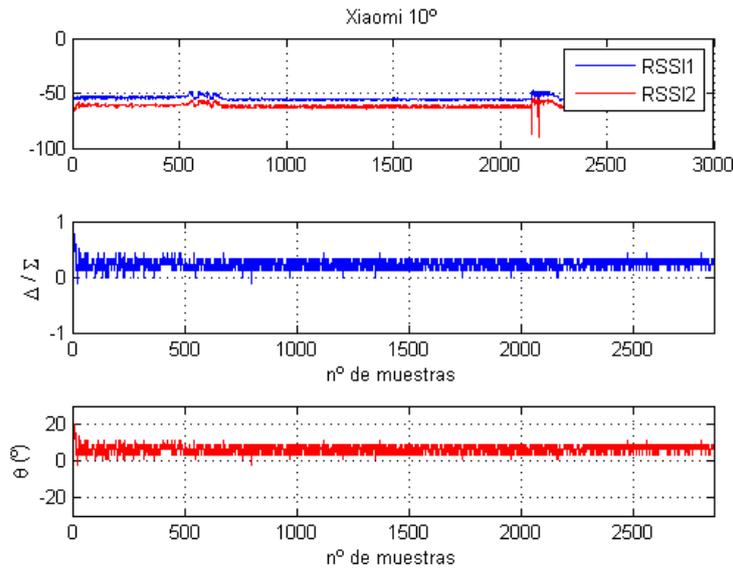


Figura 14. Función Monopulso Xiaomi Redmi 10°

Con respecto a las figuras anteriores, tal y como se ha comentado anteriormente, para cada uno de los terminales, se muestra el nivel de RSSI de las dos antenas, la representación de la función monopulso y el DoA obtenido para los terminales BQ y xiaomi Redmi. Es interesante resaltar qué, aunque el nivel de RSSI es fluctuante, los cambios en el nivel de RSSI de una antena se corresponden con el cambio en el nivel de RSSI de la otra antena. También se puede observar qué, aunque existen diferencias de hasta 10 dB de un teléfono a otro en términos de potencia absoluta, ambos terminales obtienen un resultado bastante preciso con respecto al ángulo de llegada esperado. Esto detalles se puede observar en las dos gráficas anteriores a 0° para el terminal BQ y Xiaomi. Los valores de RSSI adquiridos del terminal Xiaomi oscilan en torno a -60 dB mientras que los del terminal BQ oscilan en torno a -50 dB. Sin embargo, en todos los casos se tiene una función monopulso que permite obtener el DoA esperado, es decir, el ángulo de llegada está oscilando en cada caso con respecto al ángulo que formaba el terminal móvil con el sniffer. Se muestra a continuación el resultado del mismo experimento, pero en este caso para el terminal Huawei.

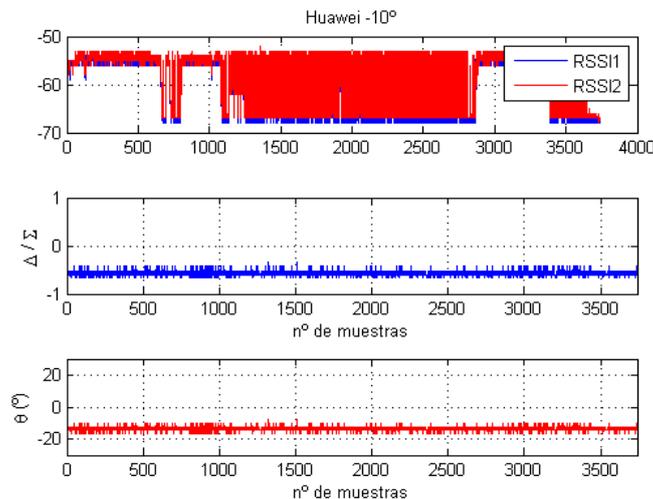


Figura 15. Función Monopulso Huawei P10 Lite -10°

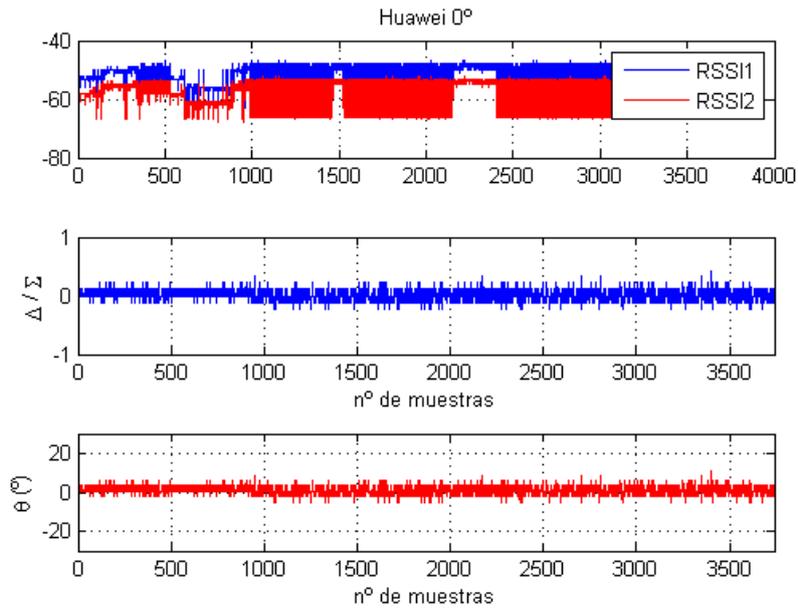


Figura 16. Función Monopulso Huawei P10 Lite 0°

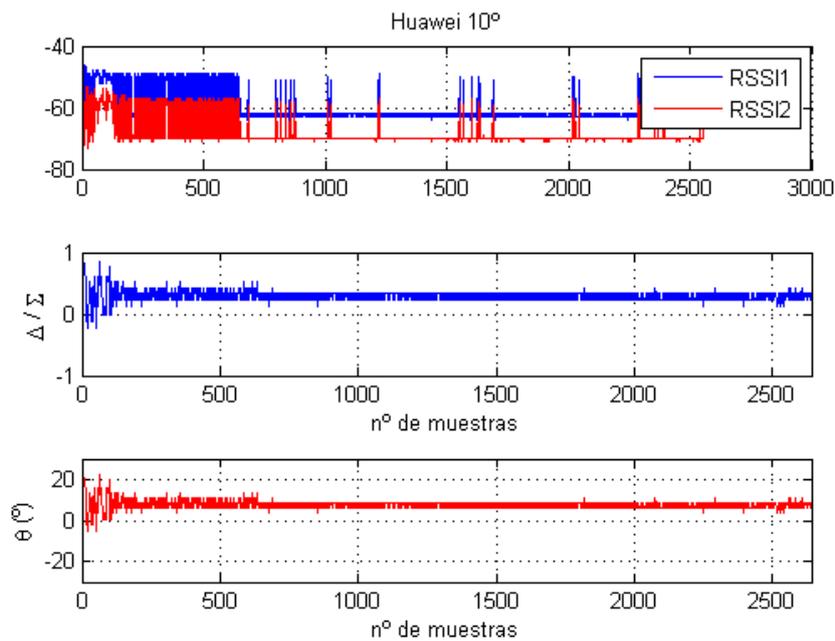


Figura 17. Función Monopulso Huawei P10 Lite 10°

En las tres gráficas anteriores, se puede observar que este teléfono presenta una característica peculiar. Se observa cómo el nivel de RSSI que capta el sniffer 1 en los 3 casos (0°, 10°, -10°) presenta muchas variaciones en términos absolutos. Esta variación llega hasta 10 dB. Pese a esa variación, al igual que sucede con el resto de teléfonos, la función monopulso permanece estable.

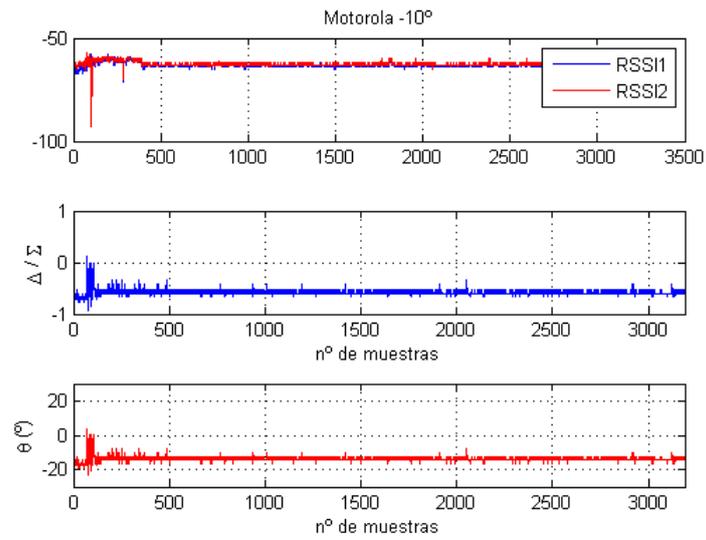


Figura 18. Función Monopulso Motorola -10°

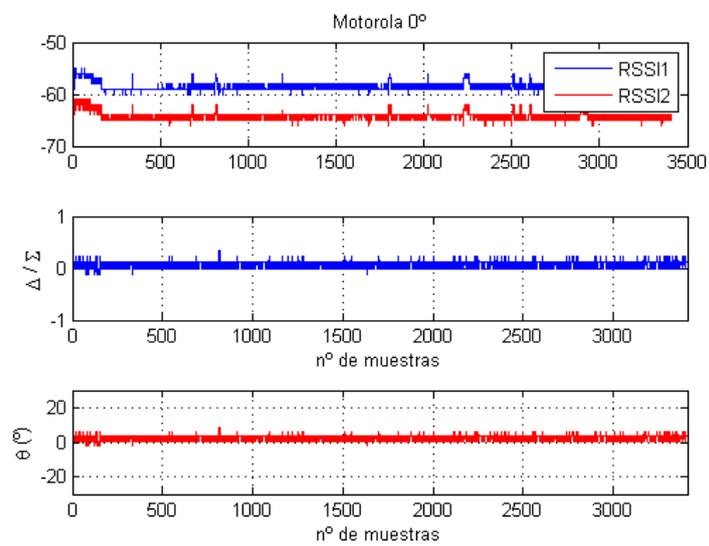


Figura 19. Función Monopulso Motorola 0°

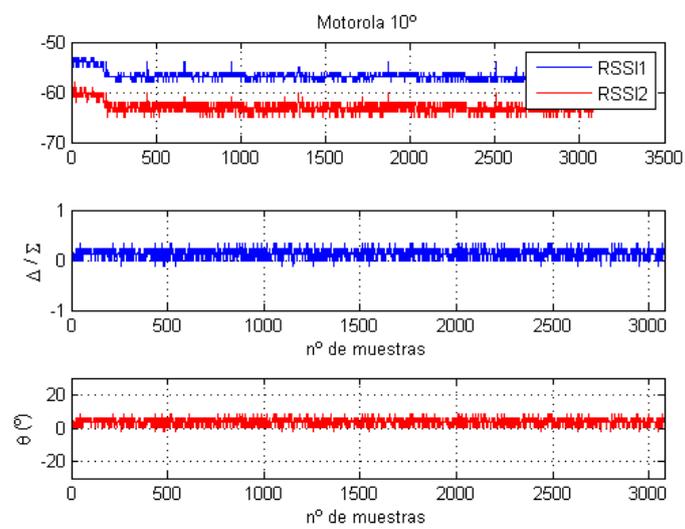


Figura 20. Función Monopulso Motorola 10°

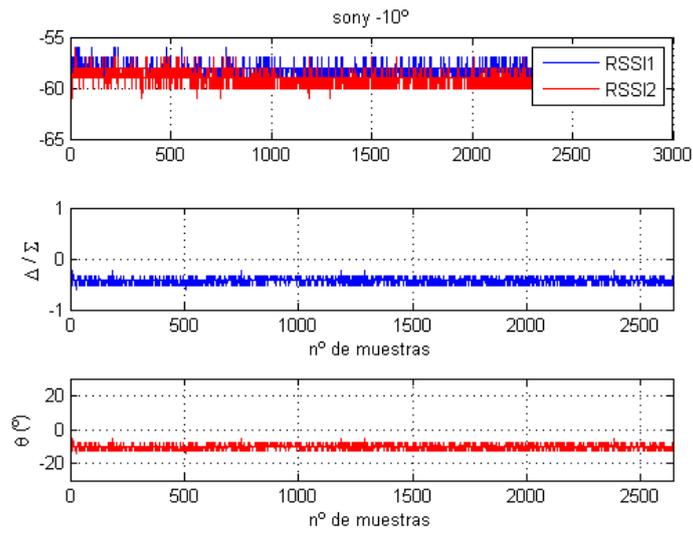


Figura 21. Función Monopulso Sony -10°

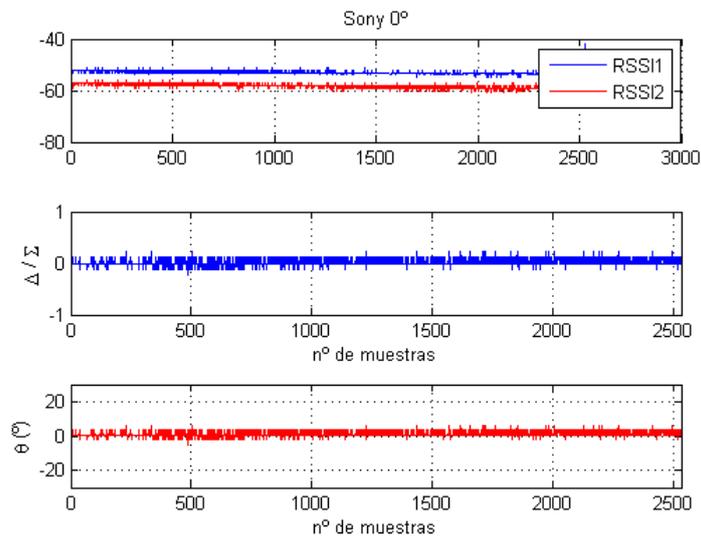


Figura 22. Función Monopulso Sony 0°

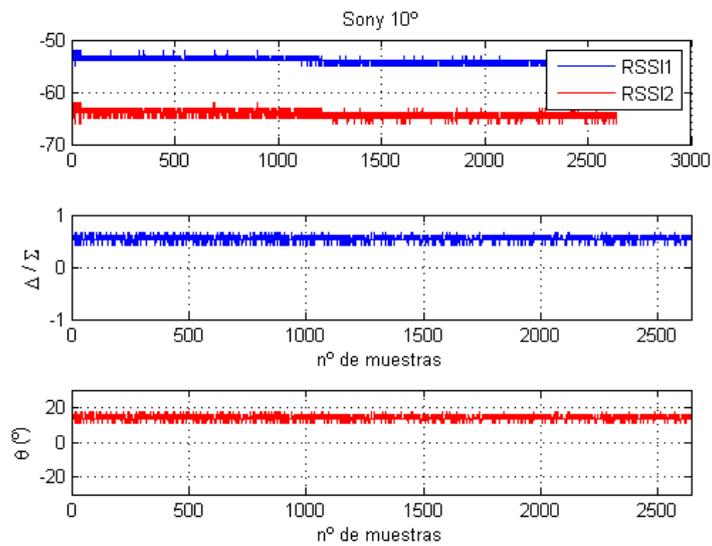


Figura 23. Función Monopulso Sony 10°

De las pruebas realizadas con estos tres teléfonos, podemos determinar que la función monopulso generada por el sniffer aproxima de forma bastante precisa el ángulo del Smartphone con respecto del sniffer. En algunos casos se observan ligeras variaciones, por ejemplo, el Motorola para 10° y los teléfonos Xiaomi y BQ para -10° .

2.1 Resultado con sniffer 2

Una vez que se ha comprobado el correcto funcionamiento del sniffer 1 como estimador del DoA para diferentes smartphones, se desea comprobar el mismo funcionamiento para el otro sniffer. Este sniffer cuenta con 2 antenas diferentes y un embebed PC que también será diferente. Para ello se realiza un experimento similar al anterior, en entorno ideal sin multipath, y comprobando el resultado de la estimación del DoA para 0 , 10° y -10° .

Este nuevo sniffer no tiene un factor de corrección calculado empleando estas dos nuevas antenas. Se emplea un factor de corrección que ha sido calculado según la media de todos los smartphones empleados. Para calcular el factor de corrección de cada smartphone, se justifica la media de todos los valores de RSSI para que coincida en 0° . Por lo tanto, tras obtener el factor de corrección de cada terminal (entre 4 y 7 dB), se usa un factor común empleando la media de estos factores, siendo el valor empleado $K_{\text{Dsniffer2}} = 5.7449$ dB sobre la antena 1.

A continuación, se muestran las gráficas de los distintos terminales, siguiendo la metodología empleada al caracterizarlos con el sniffer 1. Con la finalidad de ampliar el espectro de pruebas realizadas e incluir un número mayor de terminales y así garantizar que la función monopulso es estable para distinto hardware, se ha contado con dos nuevos terminales. Estos son el xiaomi Mi5 y el Huawei p10 lite.

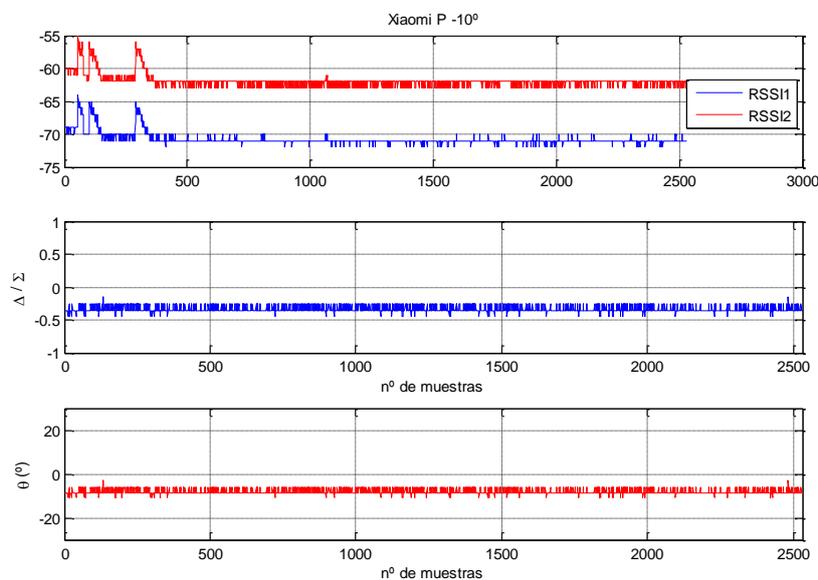


Figura 24. Función Monopulso Xiaomi Mi5- 10° Sniffer 2

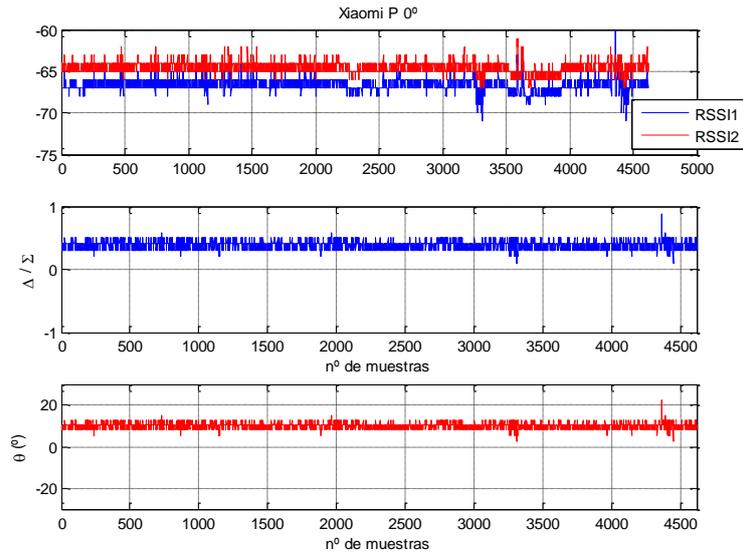


Figura 25. Función Monopulso Xiaomi Mi5 0° Sniffer 2

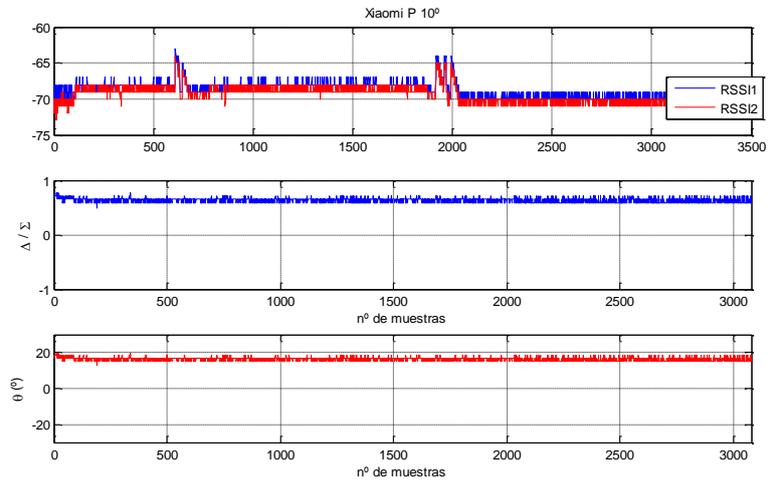


Figura 26. Función Monopulso Xiaomi Mi5 10° Sniffer 2

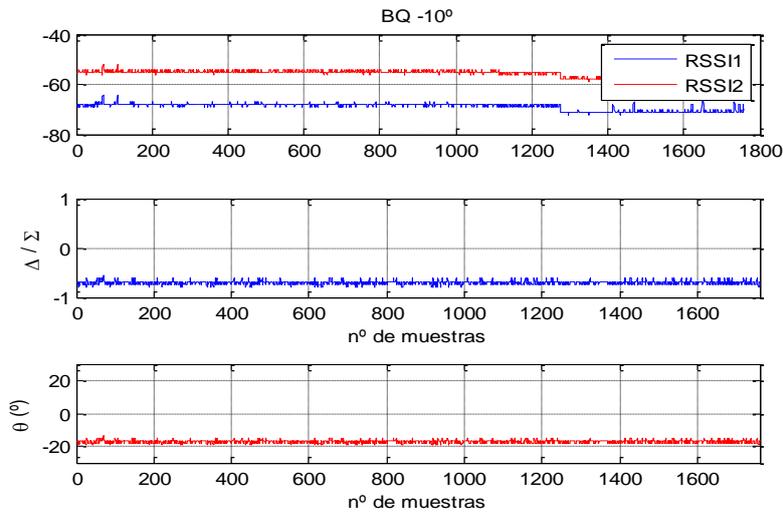


Figura 27. Función Monopulso BQ -10° Sniffer2

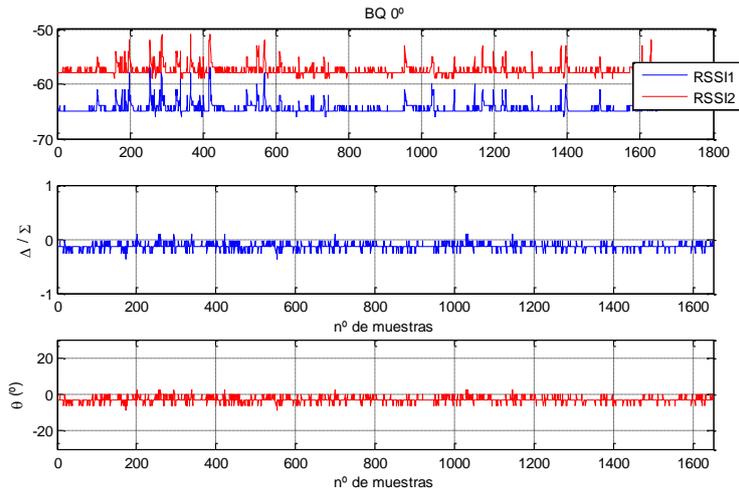


Figura 28. Función Monopulso BQ 0° Sniffer2

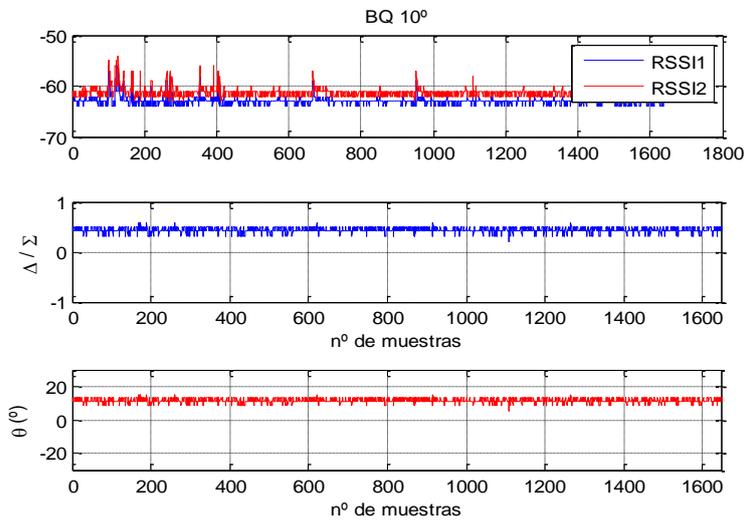


Figura 29. Función Monopulso BQ 10° Sniffer2

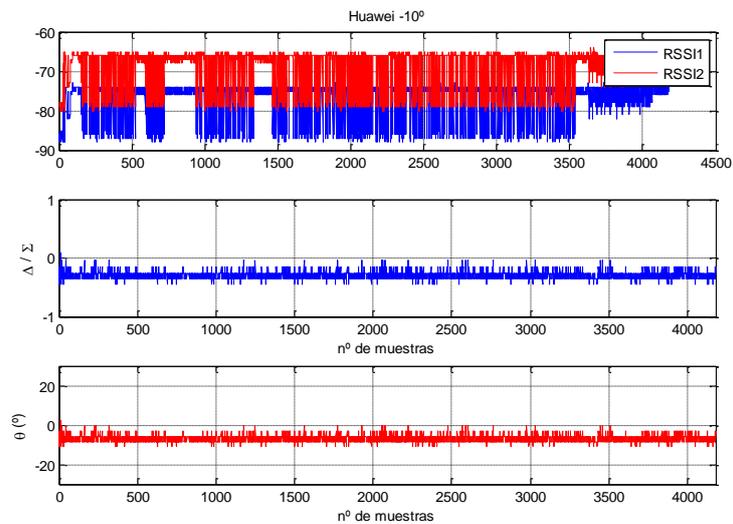


Figura 30. Función Monopulso Huawei P10 Lite -10° Sniffer

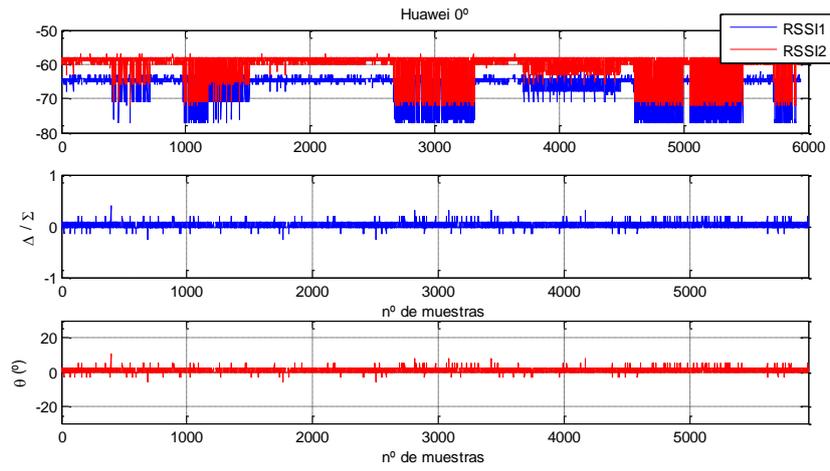


Figura 31. Función Monopulso Huawei P10 Lite 0° Sniffer2

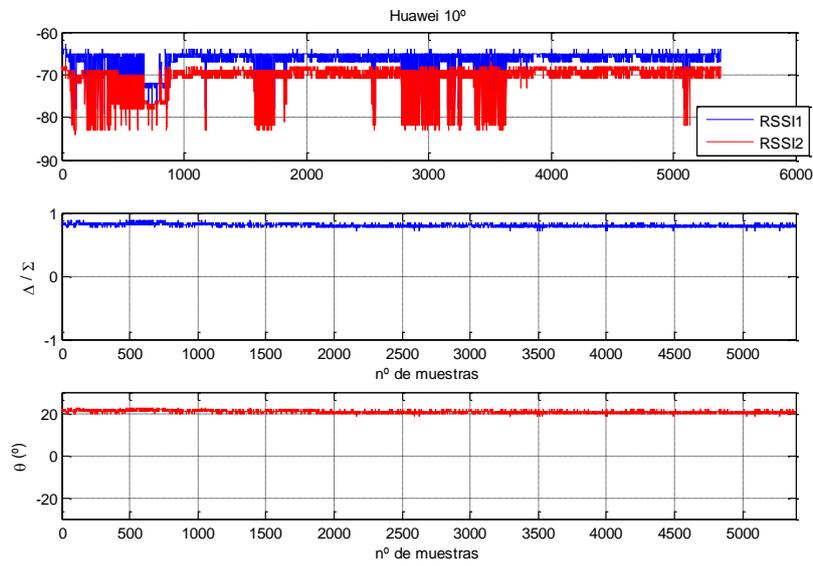


Figura 32. Función Monopulso Huawei P10 Lite 10° Sniffer2

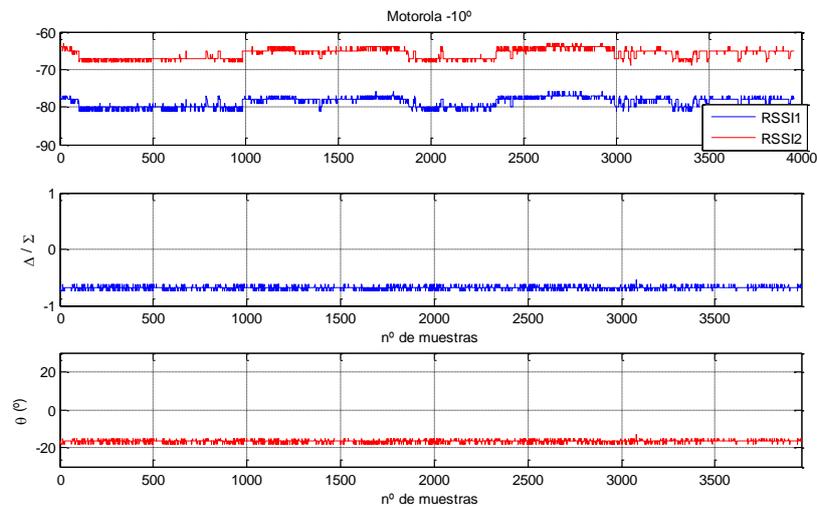


Figura 33. Función Monopulso Motorola -10° Sniffer2

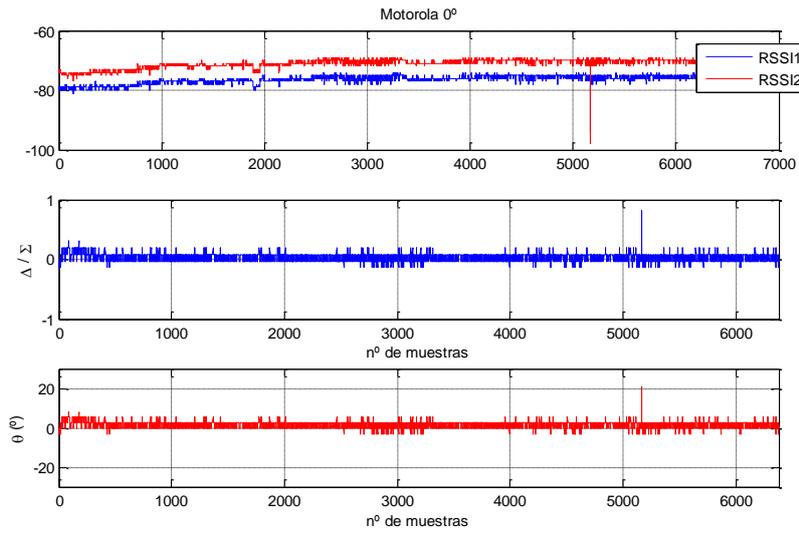


Figura 34. Función Monopulso Motorola 0° Sniffer2

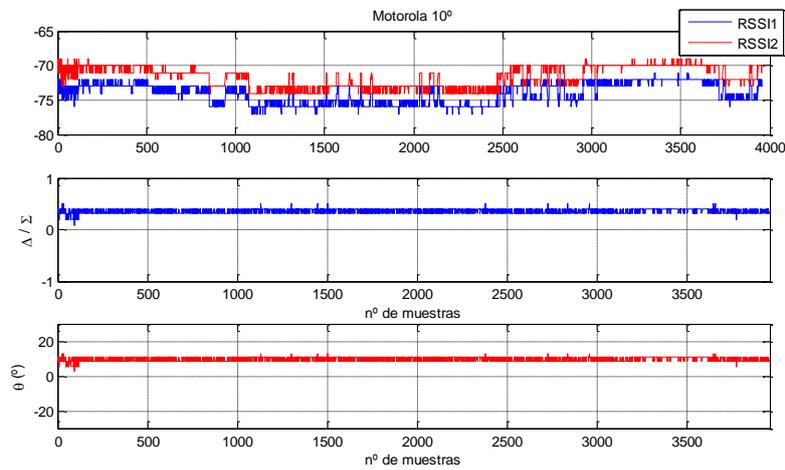


Figura 35. Función Monopulso Motorola 10° Sniffer2

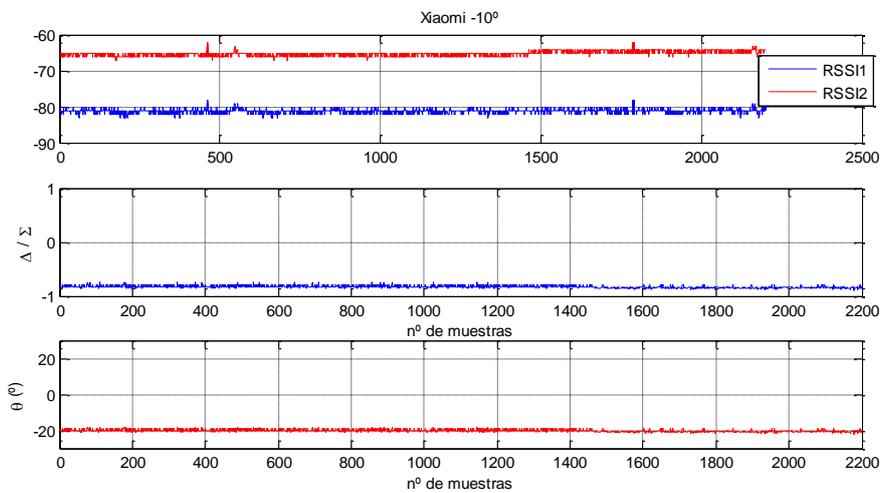


Figura 36. Función Monopulso Xiaomi Redmi -10° Sniffer2

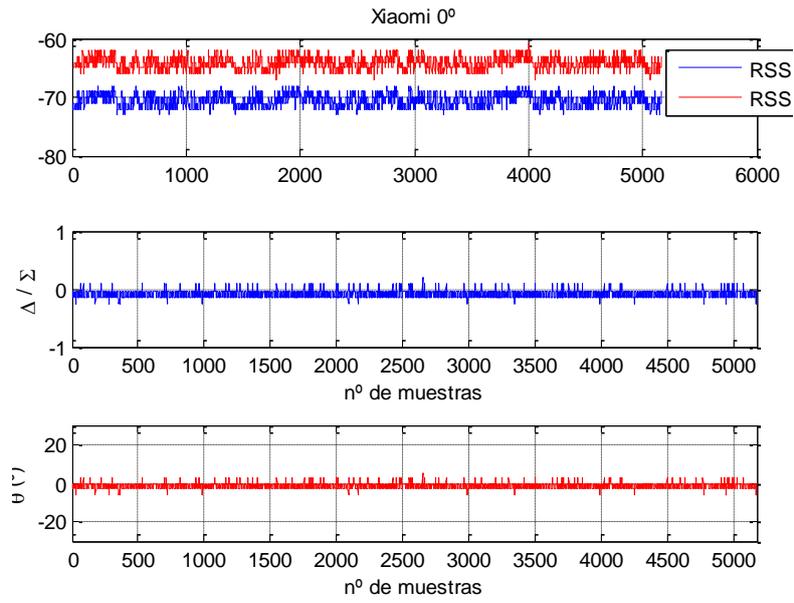


Figura 37. Función Monopulso Xiaomi Redmi 0° Sniffer2

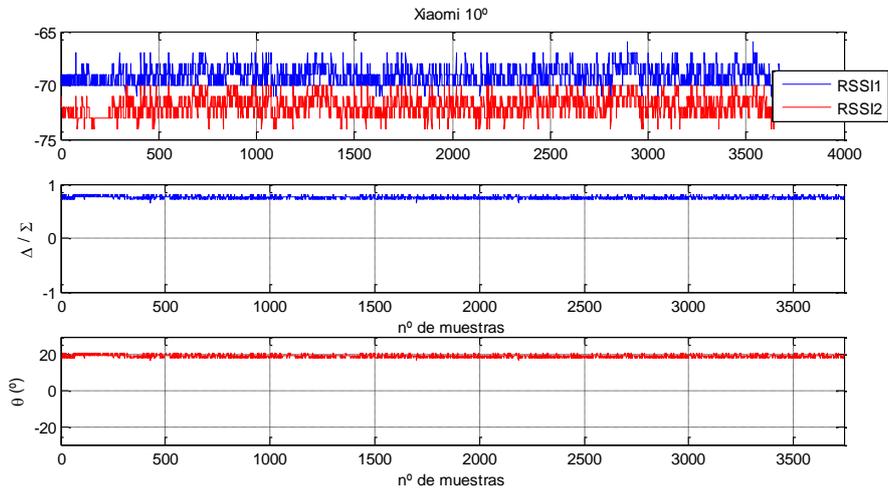


Figura 38. Función Monopulso Xiaomi Redmi 10° Sniffer2

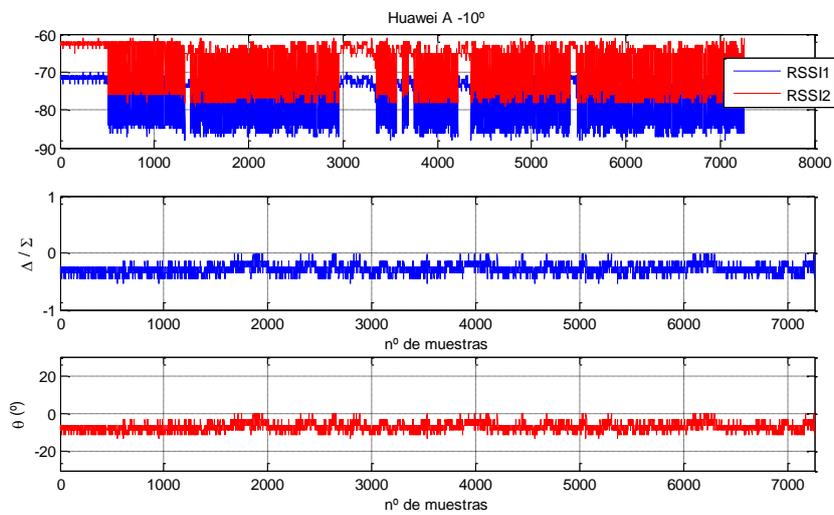


Figura 39. Función Monopulso Huawei P8 Lite -10° Sniffer2

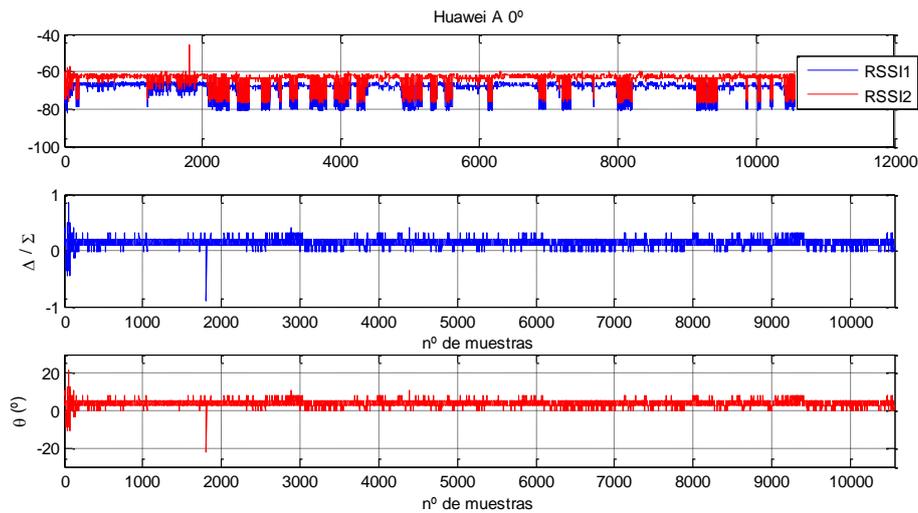


Figura 40. Función Monopulso Huawei P8 Lite 0° Sniffer2

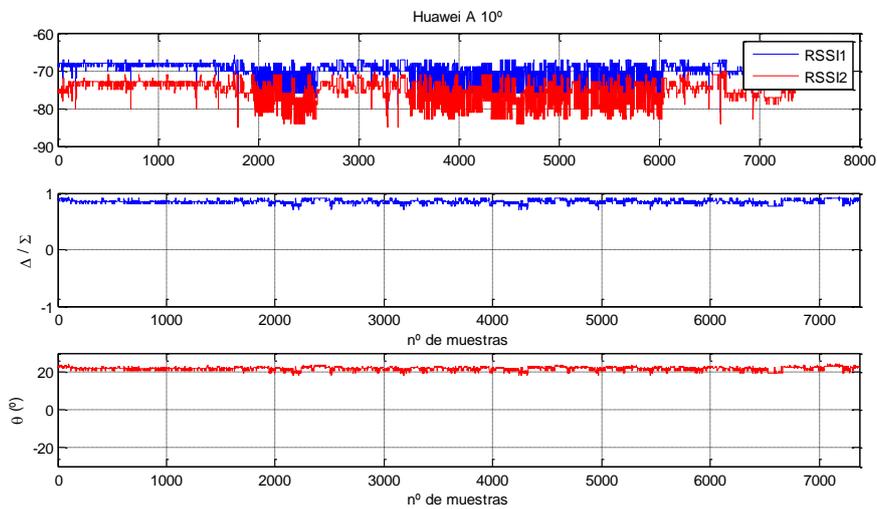


Figura 41. Función Monopulso Huawei P8 Lite 10° Sniffer2

Detalles que se pueden observar de estudiar estas gráficas:

- Al igual que sucede en el caso del sniffer 1, para los teléfonos de la marca Huawei se muestra una alta variabilidad de potencia de transmisión. Resulta muy satisfactorio comprobar que aunque exista una gran variabilidad en el nivel de RSSI, la función monopulso permanece casi constante.
- En cuanto a diferencias entre sniffer, el sniffer 1 proporciona valores de RSSI absolutos con 10 dB de diferencia aproximadamente respecto al sniffer 2. Esta diferencia vuelve a demostrar la robustez del sistema monopulso. Es decir, no importa tanto la diferencia de potencia, siempre y cuando la función monopulso sea capaz de estimar el ángulo de llegada de forma correcta.
- Hay de nuevo grandes diferencias entre los valores de RSSI absolutos entre los terminales. Debido al hardware de cada modelo, se obtienen valores de RSSI distintos. Esto no será un problema siempre y cuando se comporte de forma estable.

Capítulo 3

Medida sin multipath con dos sniffers funcionando simultáneamente

En este apartado se pretende extender el experimento del punto 2, pero ahora, al contar con dos sniffers se pretende localizar un punto concreto y no sólo el ángulo de llegada. Mediante las rectas generadas por el DoA estimado en cada sniffer, se puede calcular el punto de corte ambas y así calcular el punto x, y como la posición estimada.

Para las medidas han sido realizadas de nuevo en la cámara anecoica y se han tomado medidas en 3 puntos de interés.

- P3: 0° sniffer2 y 25° sniffer 1
- P2: -12.5° sniffer2 y 12.5° sniffer 1
- P1: -25° sniffer2 y 0° sniffer 1

Los teléfonos que se han empleado para este experimento han sido los mismo que para el punto 2. Se representan en las imágenes a continuación cada uno de los smarthones y los puntos P1, P2 y P3. También se debe de tener en cuenta que la representación de las muestras es con respecto al tiempo.



Figura 42. Posición en la cámara anecoica de los dos Sniffer y el smartphone

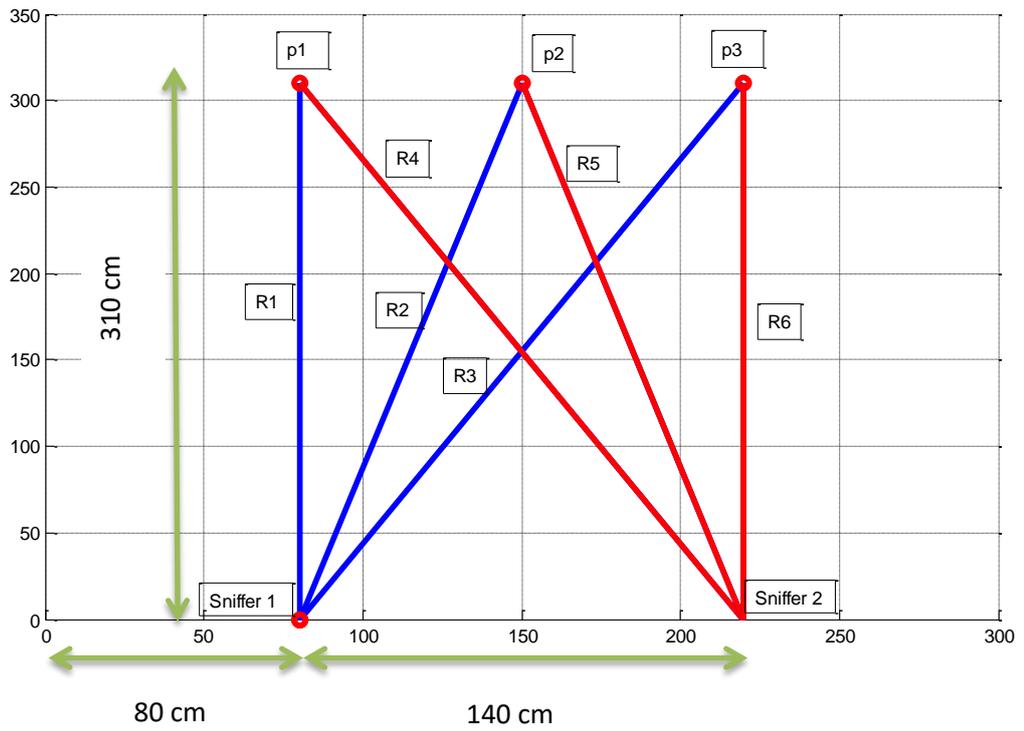


Figura 43. Esquema posición de los Sniffer y smartphone

3.1 Función monopulso y DoA

Al igual que antes, en la primera gráfica se muestra el nivel de RSSI recibido por cada antena, pero ahora se observan 4 valores de RSSI ya que tenemos dos sistemas. En la gráfica central se muestra el resultado de la función monopulso y en la última se puede ver el ángulo de llegada asociado a dicha función. Para cada smartphone se hicieron tres medidas. Una donde un sniffer 1 está a 0° y sniffer 2 a 25°, respecto al terminal móvil. Otra medida donde el terminal móvil se ponía en el centro, es decir, a 12.5° de cada sistema. La última medida es como la primera pero con en sniffer 1 a 25° y el sniffer 2 a 0°.

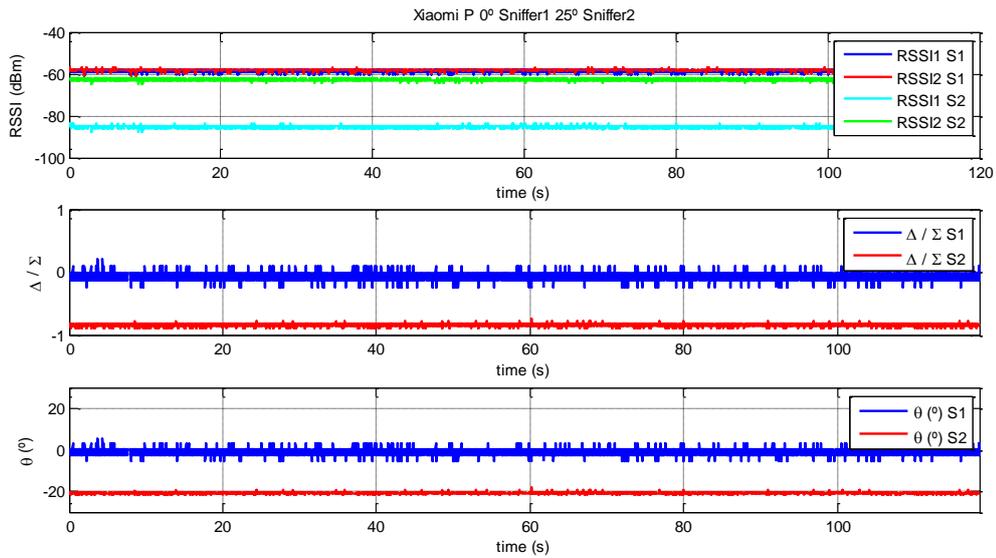


Figura 44. Función Monopulso Xiaomi Redmi Sniffer1 a 0° y Sniffer2 a 25°

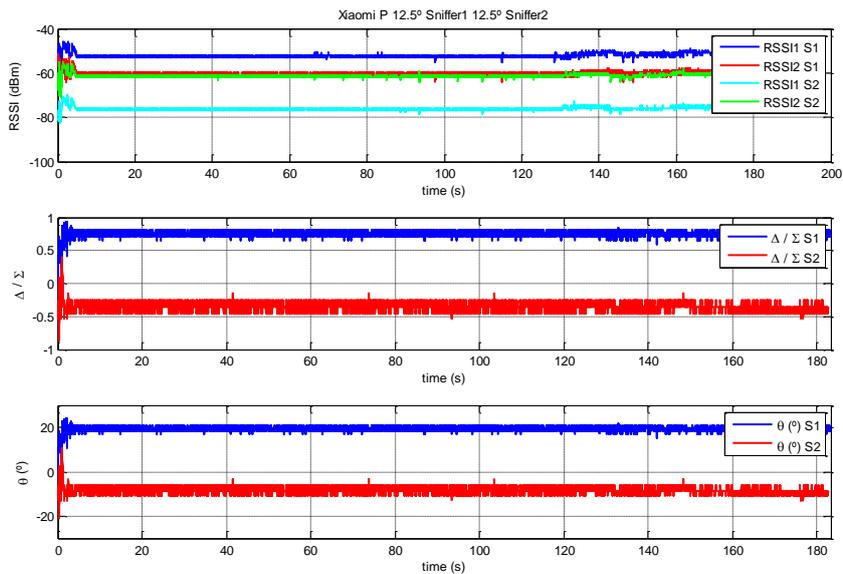


Figura 45. Función Monopulso Xiaomi Redmi Sniffer1 a 12.5° y Sniffer2 a 12.5°

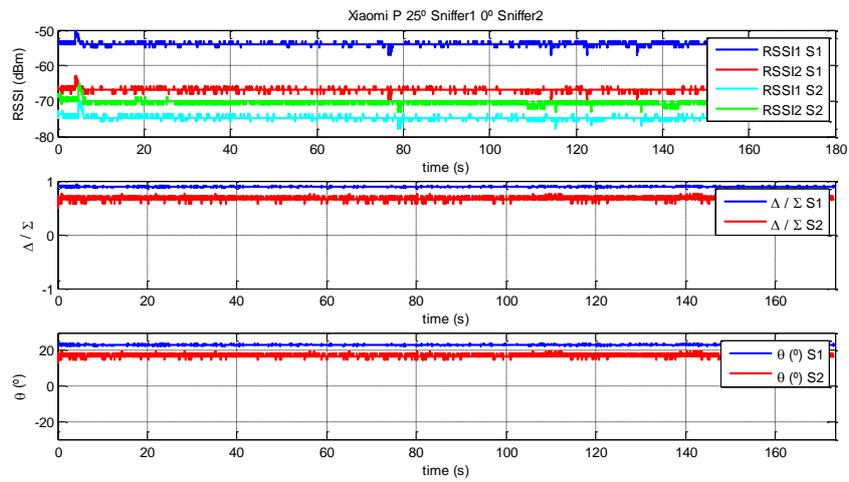


Figura 46. Función Monopulso Xiaomi Redmi Sniffer1 a 25° y Sniffer2 a 25°

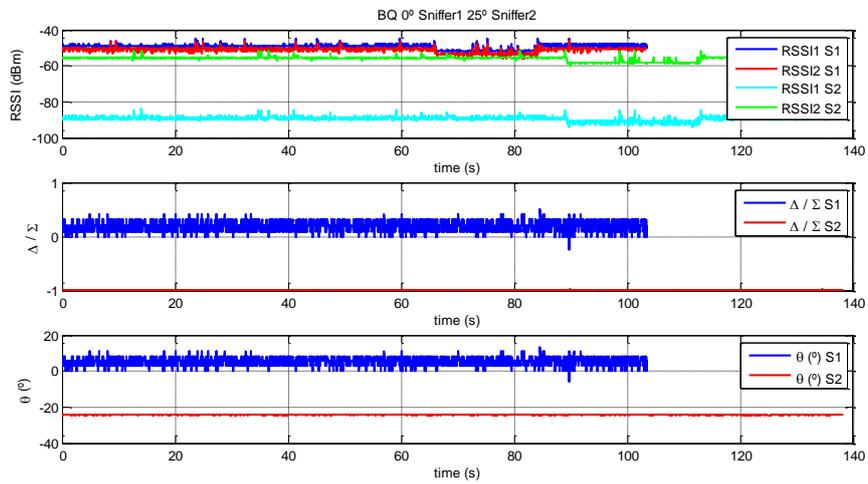


Figura 47. Función Monopulso BQ Sniffer1 a 25° y Sniffer2 a 0°

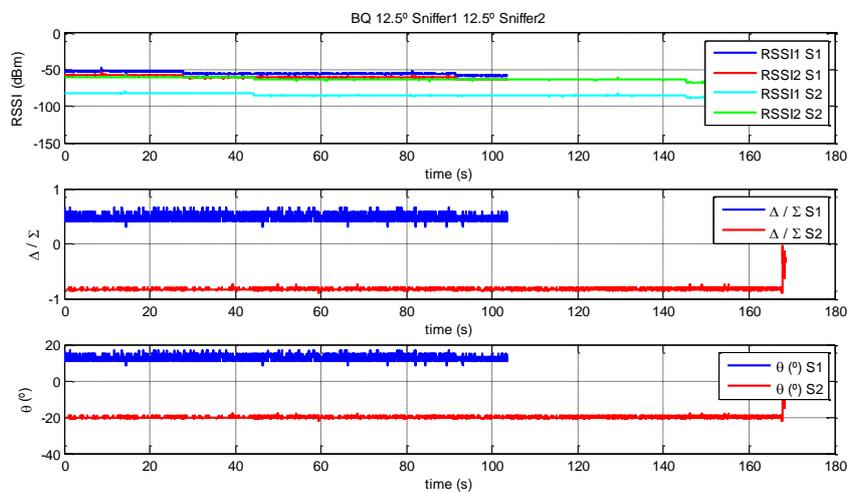


Figura 48. Función Monopulso BQ Sniffer1 a 12.5° y Sniffer2 a 12.5°

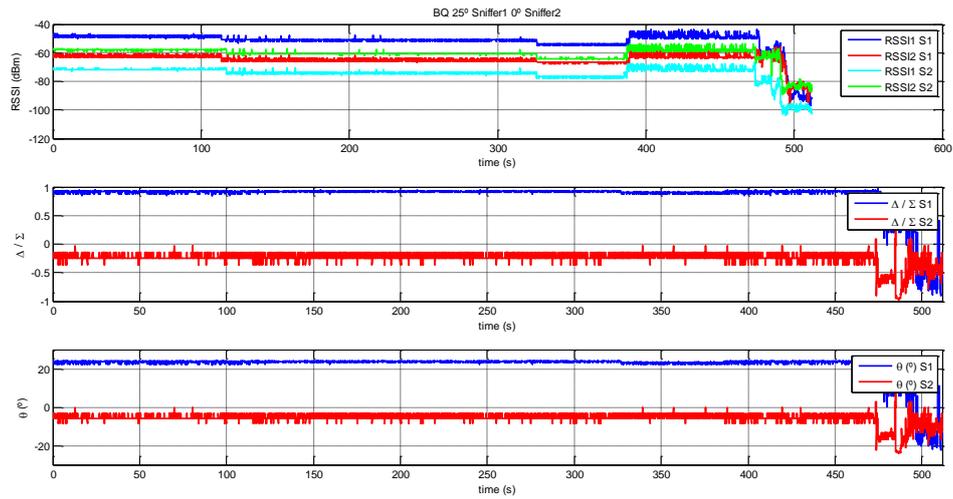


Figura 49. Función Monopulso BQ Sniffer1 a 25° y Sniffer2 a 0°

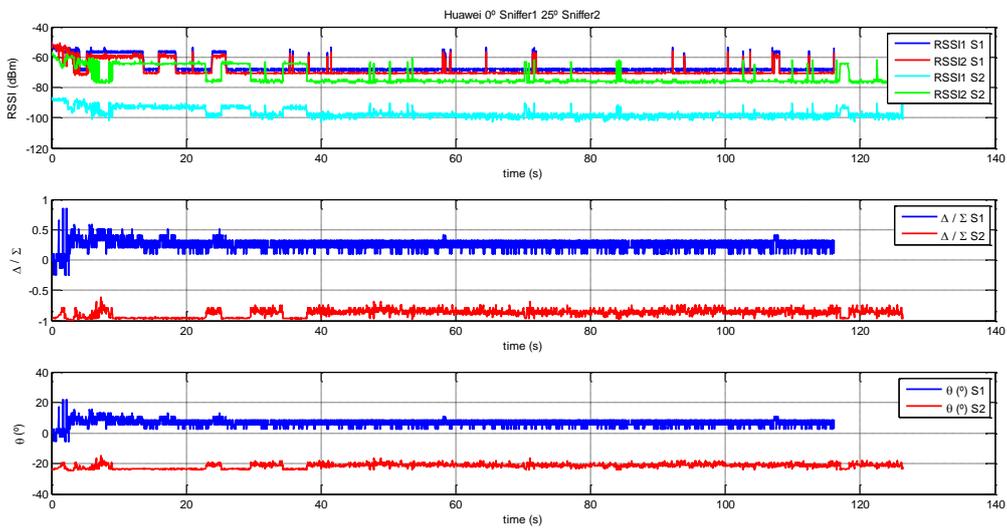


Figura 50. Función Monopulso Huawei P10 Lite Sniffer1 a 0° y Sniffer2 a 25°

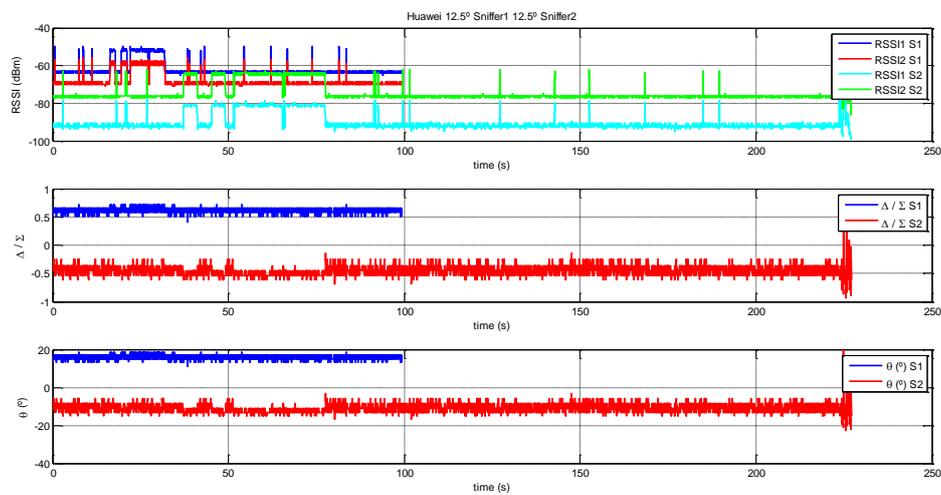


Figura 51. Función Monopulso Huawei P10 Lite Sniffer1 a 12.5° y Sniffer2 a 12.5°

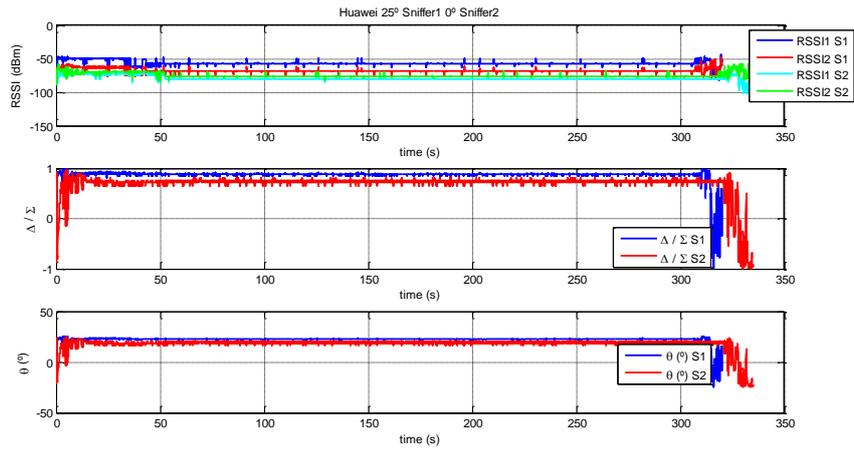


Figura 52. Función Monopulso Huawei P10 Lite Sniffer1 a 25° y Sniffer2 a 0°

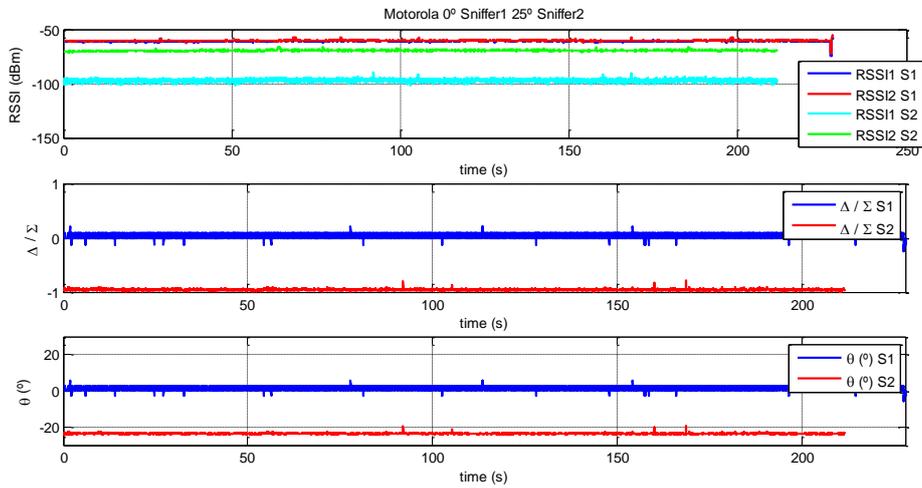


Figura 53. Función Monopulso Motorola Sniffer1 a 0° y Sniffer2 a 25°

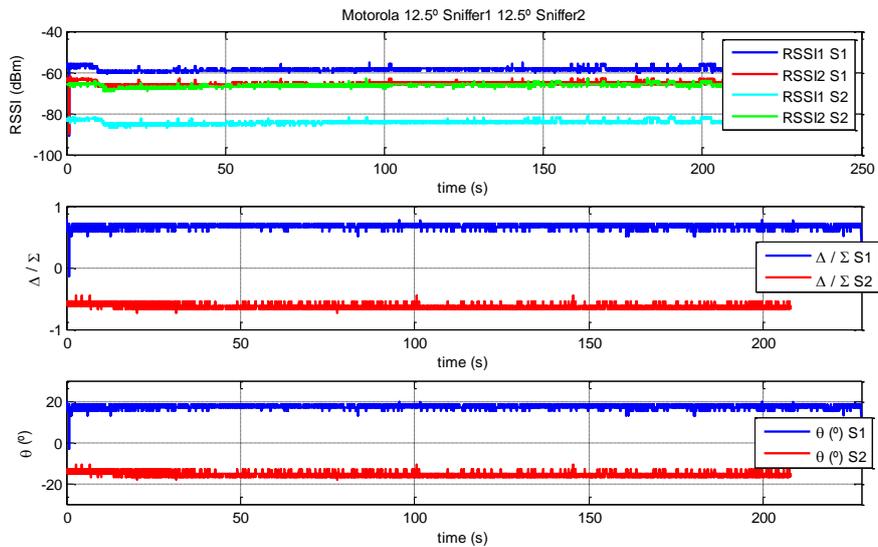


Figura 54. Función Monopulso Motorola Sniffer1 a 12.5° y Sniffer2 a 12.5°

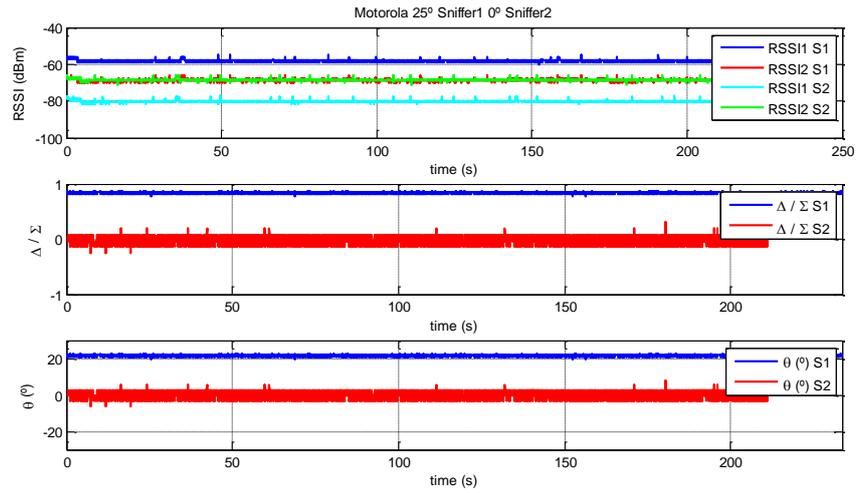


Figura 55. Función Monopulso Motorola Sniffer1 a 25° y Sniffer2 a 0°

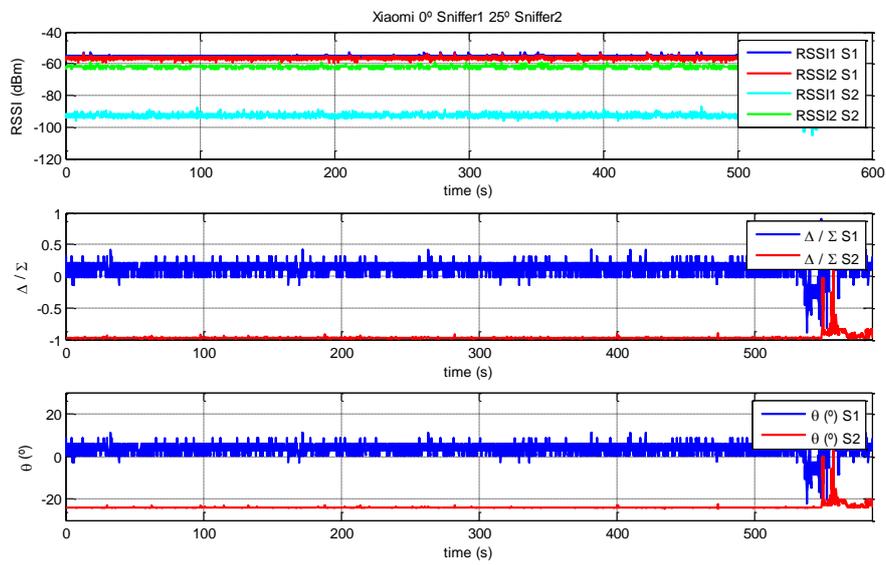


Figura 56. Función Monopulso Xiaomi Mi5 Sniffer1 a 0° y Sniffer2 a 25°

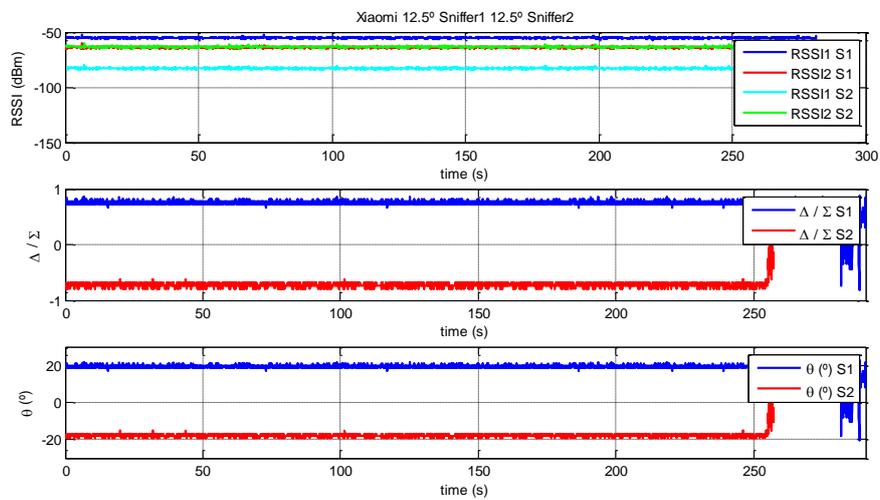


Figura 57. Monopulso Xiaomi Mi5 Sniffer1 a 12.5° y Sniffer2 a 12.5°

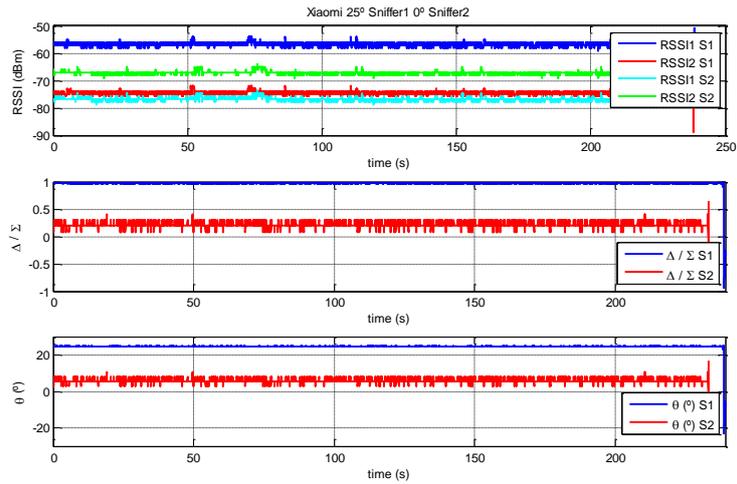


Figura 58. Función Monopulso Xiaomi Mi5 Sniffer1 a 25° y Sniffer2 a 0°

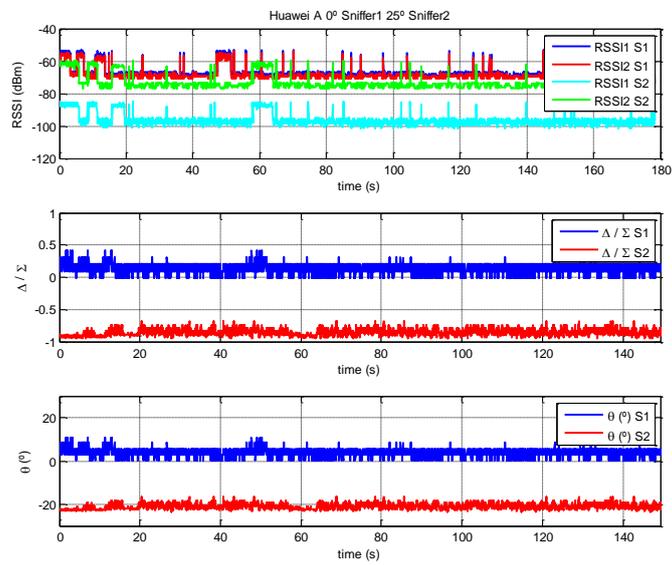


Figura 59. Función Monopulso Huawei P8 Lite Sniffer1 a 0° y Sniffer2 a 25°

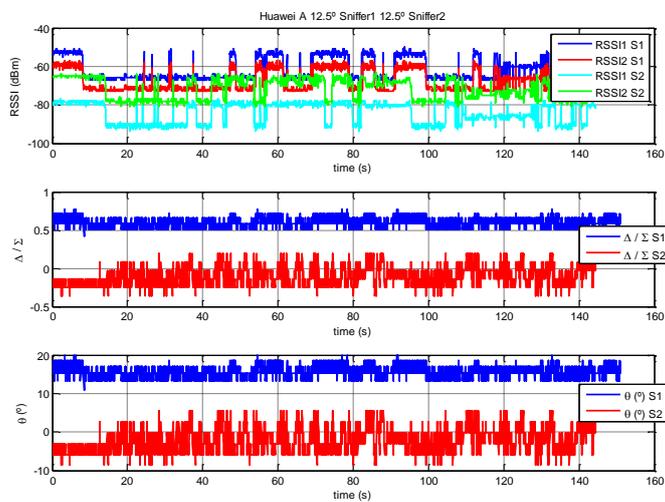


Figura 60. Función Monopulso Huawei P8 Lite Sniffer1 a 12.5° y Sniffer2 a 12.5°

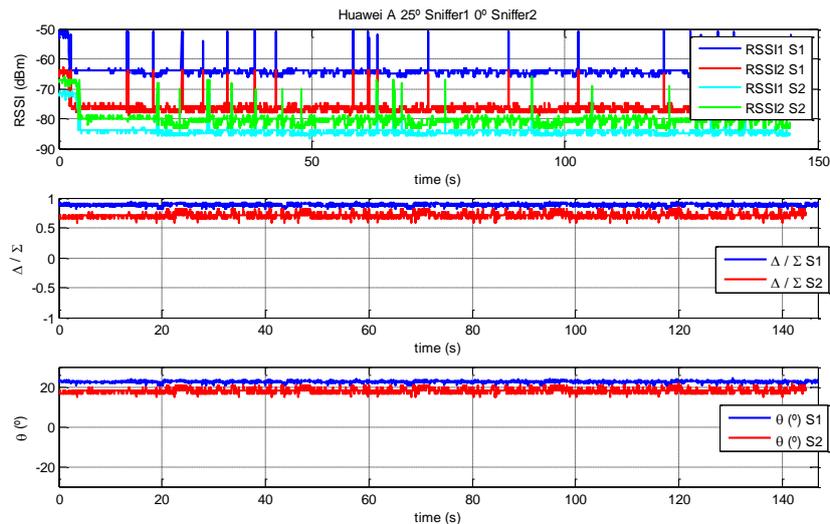


Figura 61. Función Monopulso Huawei P8 Lite Sniffer1 a 25° y Sniffer2 a 25°

Conclusiones del estudio de las gráficas:

- En algunos momentos alguno de los sniffers dejó de tomar muestras de la RSSI como como se observa para el terminal BQ y Huawei P10 para el punto 2.
- Se sigue encontrando una alta variabilidad en los teléfonos de la marca Huawei. Como se ha comentado antes, esto es solventado con éxito por la función monopulso.
- El resultado de la función monopulso en la mayoría de smartphones devuelve resultados que estiman con éxito el valor del ángulo de transmisión.
- En algunos casos, como para el smartphone Xiaomi Redmi y Huawei p8, para el punto 3, se obtienen ligeras variaciones respecto del ángulo teórico del ángulo obtenido.

Por lo tanto, si se coge cada uno de los distintos DoA de cada sniffer, se puede intentar estimar la posición exacta del smartphone empleando el punto de corte de los DoA resultantes.

3.2 Localización de un punto exacto

A continuación, se muestra una rejilla para ver si es posible obtener con una cierta precisión la situación del móvil con dos sniffers. Se ha empleado el cuadrado como representación del punto 1, el círculo como representación del punto 2 y rombo del punto 3.

Para obtener el punto de corte se ha utilizado la siguiente trigonometría:

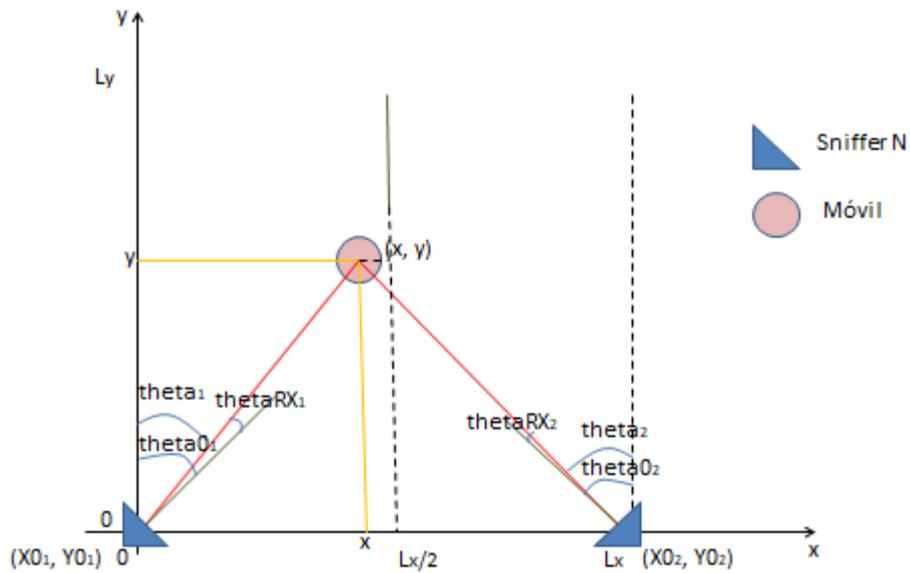


Figura 62. Trigonometría para calcular la posición de llegada

- $L_y \equiv$ longitud en la coordenada y de la malla rectangular.
- $L_x \equiv$ longitud en la coordenada x de la malla rectangular.
- $\tan(\theta_1) = \frac{x}{y}$ (1)
- $\tan(\theta_2) = \frac{L_x - x}{y}$ (2)

Por los errores no coincidirán en el mismo punto.

Para obtener los puntos:

- (x_{12}, y_{12})

$$x_{12} = y_{12} * \tan(\theta_1)$$

$$y_{12} = \frac{L_x}{\tan(\theta_1) + \tan(\theta_2)}$$

- Con dos sniffers únicamente se calcula un punto (x_{12}, y_{12}) .

$$x = x_{12}$$

$$y = y_{12}$$

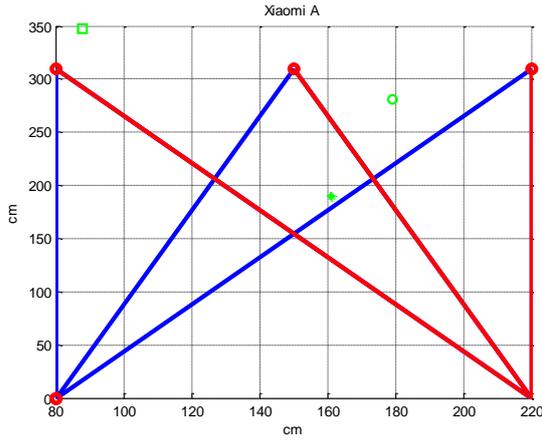


Figura 63. Posición estimada Xiaomi Redmi

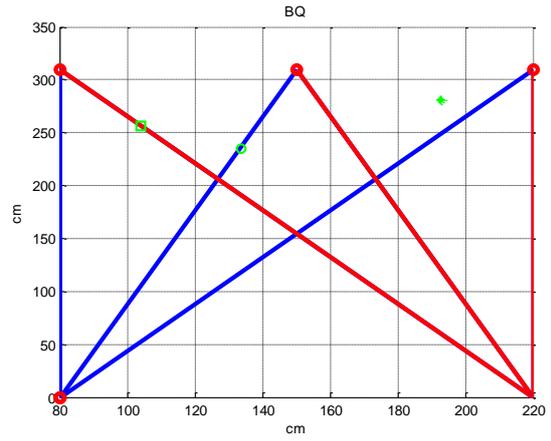


Figura 64. Posición estimada BQ

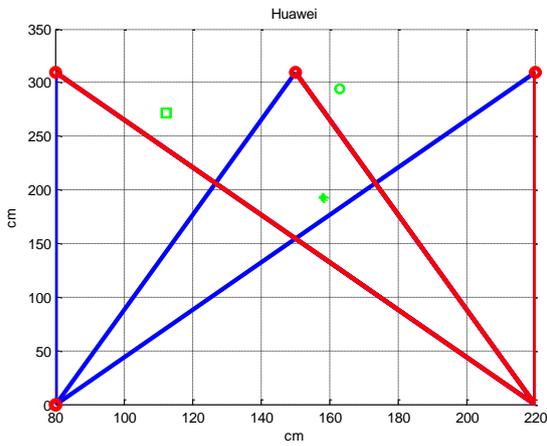


Figura 65. Posición estimada Huawei P10 Lite

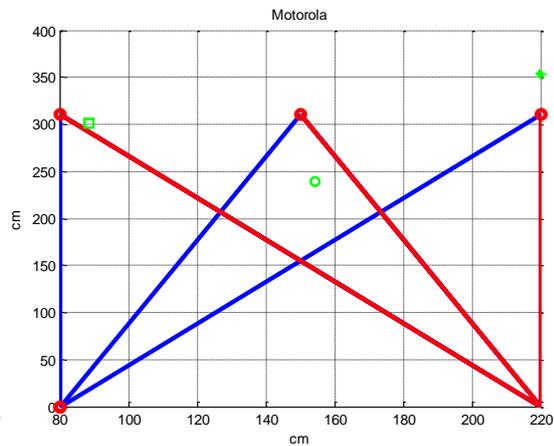


Figura 66. Posición estimada Motorola

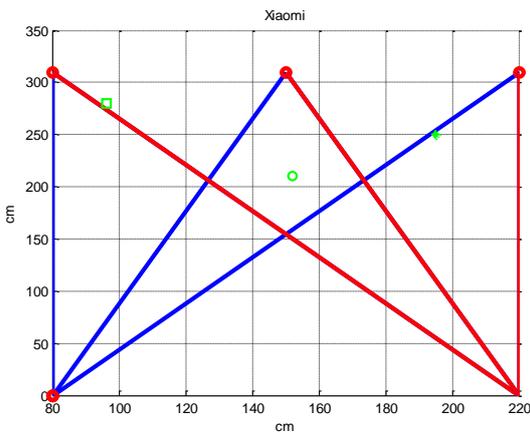


Figura 67. Xiaomi MiA1

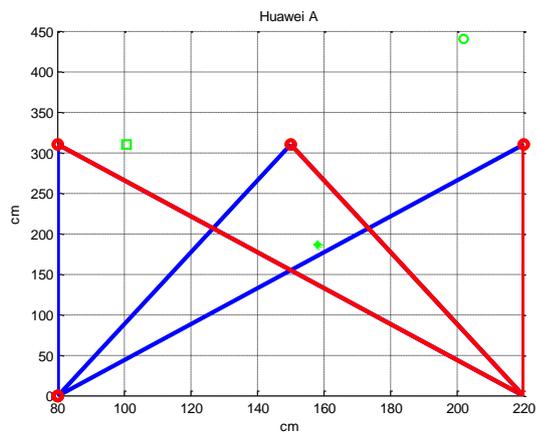
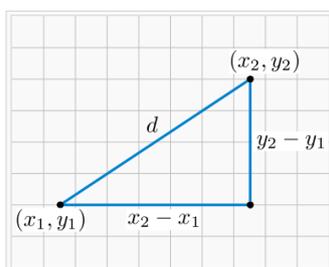


Figura 68. Huawei P8 Lite

Si se muestran los resultados exactos de la posición (x',y') estimada respecto de la posición (x,y) real, se observa que en algunos casos se tiene una estimación muy aproximada del resultado teórico respecto del obtenido.

En la siguiente tabla se muestra, en términos de distancia euclídea, el error en cada punto para cada teléfono. Hay que tener en cuenta que el error estimado es en centímetros.

La fórmula empleada para el error es la siguiente:



$$d_E(P_1, P_2) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

Punto de medida	P1			P2			P3		
	X	Y	D	X	Y	D	X	Y	D
2	161.	190.232	50.6164	179.130	280.801	127.516	87.9728	347.876	37.027
	2790	1		8	5	3		4	7
3	192.	280.675	10.4628	133.837	235.308	83.7632	104.125	256.112	48.185
	6052	1		0	4		3	4	5
4	158.	192.685	55.4601	163.176	294.202	143.599	112.538	272.086	19.460
	1783	1		3	4	1	2	5	2
5	219.	353.232	133.232	154.473	239.729	89.6177	88.4848	301.221	2.2525
	7020	9	5	1	2			3	
6	194.	250.257	16.9461	152.205	210.499	60.4589	96.1367	279.530	25.845
	9329	7		1	1			7	5
7	158.	186.635	51.9896	202.122	440.768	28,6.05	100.959	309.642	20.956
	2253	4		2	2	84	5	3	4

Del resultado de la tabla se pueden extraer las siguientes conclusiones:

- En el peor de los casos, el error no es superior a 150cm, luego en todos los casos sería posible acertar con el punto de medida en el que está situado el smartphone.
- Hay puntos donde la función monopulso es capaz de estimar la posición con una diferencia de pocos centímetros.
- Al tener una zona de medida con pocas dimensiones, el error parece mayor al tratarse de centímetros. Con una zona de medida mayor donde se puedan tener más puntos de medida, se comprobaría el funcionamiento de mejor forma.
- Para el terminal Huawei P10 lite se observa como para el punto 2, es decir, para la medida donde el terminal de medida se sitúa en el centro de los dos sniffer, el error es mucho mayor que en los otros dos puntos. XXX

Capítulo 4

Entorno con multipath

Una vez comprobado el funcionamiento del sistema como estimador de posición en entornos sin multipath, se va a profundizar en el funcionamiento del sistema en entornos con multipath. Para ello, se va a analizar el funcionamiento del sistema MiMo WiFi hybrid analog digital (HAD) RSSI-based monopulse en un entorno con una fuerte componente multipath.

Para esta campaña de medidas, se colocó un sniffer en la primera planta de la ETSIT (UPCT). Se han utilizado diferentes terminales móviles para comprobar cómo de robusta es la función monopulso. Este entorno está formado por clases y pasillos, por lo tanto, hay puertas, paredes, zonas con cristal, muros de ladrillos, etc. Será muy interesante estudiar cómo responde según la distancia, y los rebotes debido a todos los elementos citados anteriormente.

Con este experimento se pretende responder a las preguntas que han sido planteadas en la introducción de este trabajo:

- ¿Cuántos metros cuadrados se puede cubrir con un único dispositivo?
- En entorno sin multipath, la función monopulso ha determinado con éxito el DoA. Pero, ¿se puede emplear la función monopulso para estimar la posición y no solo el DoA en entorno con multipath?
- En los entornos reales como universidades, centros comerciales u hospitales se tienen paredes y suelos/techos de muy diversas características que provocan multipath. ¿Cómo afecta el multipath a la función monopulso?
- Heterogeneidad del hardware a localizar. Utilización de distintas antenas, chipset o smartphones. ¿Cuál es la variación de la función monopulso ante distinto hardware a localizar?
- Variabilidad de la RSSI ante cambios del entorno como puede ser la presencia de gente, movimiento de puertas, temperatura o humedad. Se conoce que todos estos factores pueden afectar a la variabilidad de la RSSI. ¿Cómo afecta a la función monopulso la alta variabilidad de la RSSI?

Sobre una rejilla de zonas de 5x5 metros, se va a realizar una toma de datos con varios teléfonos de diferente fabricante, antena y chipset. Se realiza la prueba sobre una zona de 1200 m² (60 metros de largo por 20 de ancho). Se recogen datos en 33 puntos. En cada uno de los puntos se recogen muestras. El HAD sniffer no llega a las zonas 1, 2, 23 ni 24. Este problema se debe a las antenas del router, no por las antenas directivas del sniffer. Además, no se puede acceder a la zona 27 dado que se trata de una zona técnica sin acceso.

Sobre cada una de estas zonas se toman muestras durante 1 minuto, con 5 teléfonos diferentes. Los teléfonos se ponen a transmitir datos en continuo mediante una app Android y el sniffer HAD radar monopulso captura la RSSI de cada antena. Los teléfonos que han sido

empleados son los que aparecen en la siguiente tabla:

Device	Android	Muestras recogidas
Sony Experia SGP312	4.4.4	94490
Xiaomi Redmi Note 1 LTE	4.4.4	78540
BQ Aquaris M8	6	53250
Huawey p10 lite	8	129140
Motorola Moto G LTE	6	109407

Lo primero que vamos a estudiar es la variabilidad de la RSSI en este entorno con una alta componente de multipath. Se ha seleccionado 3 zonas estratégicas, cada una con un ángulo distinto como son las zonas 7, 18 y 29.

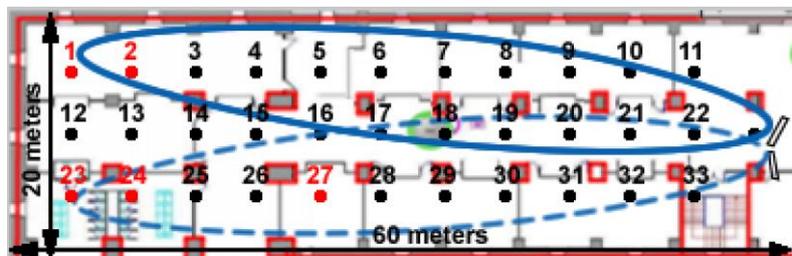


Figura 69. Zona de clases de la ETSIT de la UPCT donde se lleva a cabo la campaña de medidas

Para estudiar la variabilidad de la RSSI se ha utilizado el diagrama de cajas y bigotes. Los diagramas de Caja-Bigotes (boxplots o box and whiskers) son una presentación visual que describe varias características importantes, al mismo tiempo, tales como la dispersión y simetría. Para su realización se representan los tres cuartiles y los valores mínimo y máximo de los datos, sobre un rectángulo, alineado horizontal o verticalmente. Una gráfica de este tipo consiste en una caja rectangular, donde los lados más largos muestran el recorrido intercuartílico. Este rectángulo está dividido por un segmento vertical que indica donde se posiciona la mediana y por lo tanto su relación con los cuartiles primero y tercero (recordemos que el segundo cuartil coincide con la mediana). Esta caja se ubica a escala sobre un segmento que tiene como extremos los valores mínimo y máximo de la variable. Las líneas que sobresalen de la caja se llaman bigotes. Estos bigotes tienen un límite de prolongación, de modo que cualquier dato o caso que no se encuentre dentro de este rango es marcado e identificado individualmente.

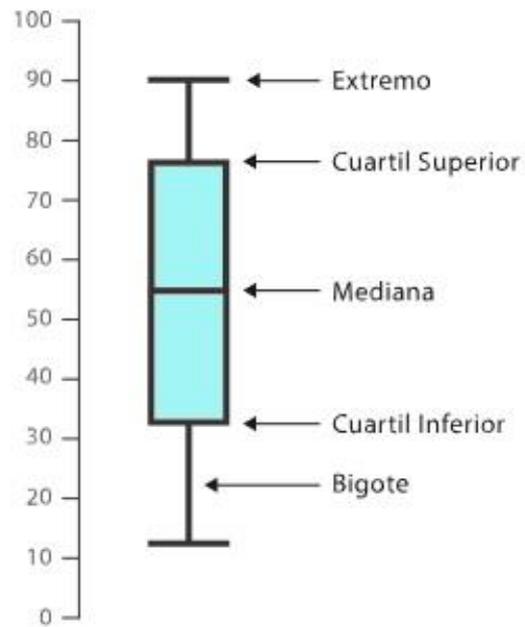


Figura 70. Diagrama de cajas y bigotes

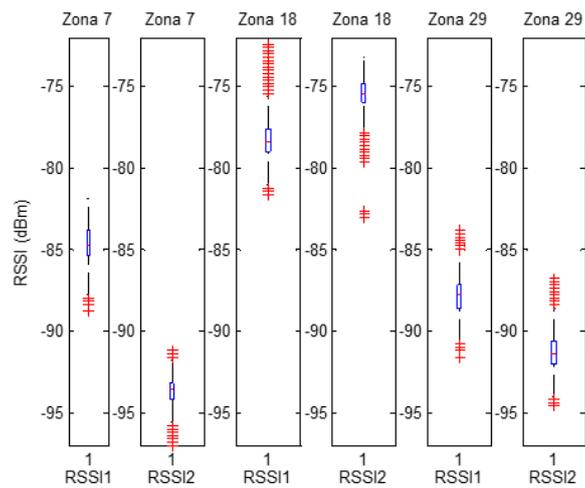


Figura 71. Variación de la RSSI para las zonas 7, 18 y 29 para Motorola

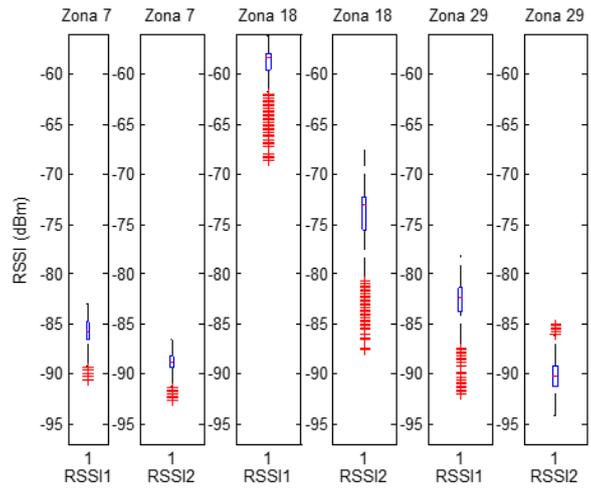


Figura 72. Variación de la RSSI para las zonas 7, 18 y 29 para Huawei P10 Lite

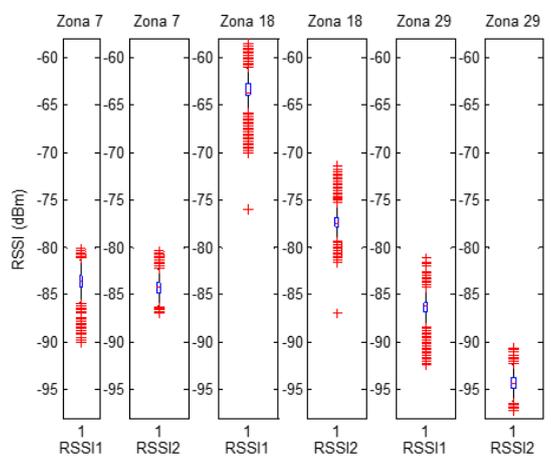


Figura 73. Variación de la RSSI para las zonas 7, 18 y 29 para Xiaomi Mi5

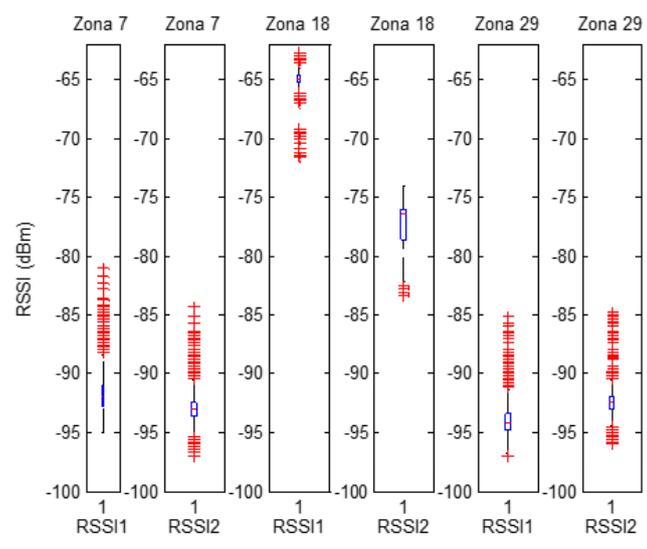


Figura 74. Variación de la RSSI para las zonas 7, 18 y 29 para Sony

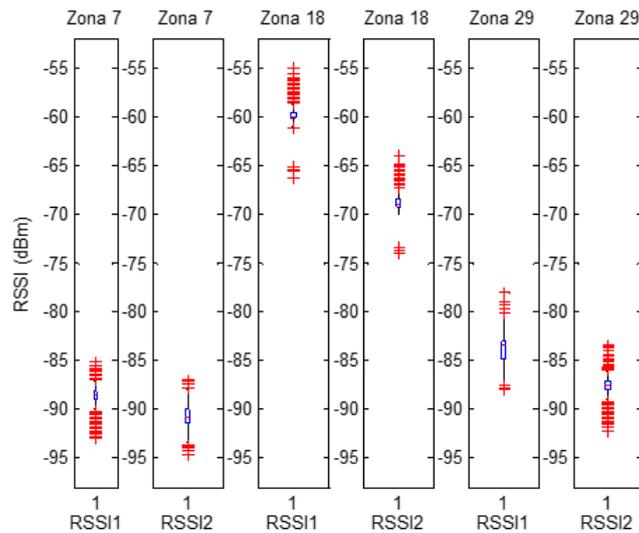


Figura 75. Variación de la RSSI para las zonas 7, 18 y 29 para BQ

Se pueden observar en las imágenes la fuerte correlación que hay entre la distribución de la RSSI1 y RSSI2 para todos los terminales. Si bien cada teléfono tiene unos rangos de RSSI distintos, en todas las zonas se observa correlación entre la potencia RSSI1 y la potencia RSSI2. Aunque, debido a la alta componente multipath ya no se puede esperar obtener el DoA directamente de la función monopulso, se observa estabilidad durante la campaña de medidas. En las representaciones se puede observar, que aunque hay una mayor variabilidad de la RSSI y que el DoA no corresponde con el que se espera real, se tiene una gran estabilidad a lo largo de las mediciones. Se puede observar en el diagrama de cajas y bigotes como los valores de RSSI son bastante estables, es decir, no hay una gran dispersión en los bigotes y los valores están muy concentrados. Aunque en zonas con multipath no es posible calcular el DoA con precisión, el hecho de que los valores de RSSI se puedan considerar estables, va a hacer posible que sea un buen input para el algoritmo de posicionamiento basado en machine learning como se verá más adelante.

A continuación, se muestran los resultados obtenidos para las distintas zonas y teléfonos. En este caso, se representan los niveles de RSSI de los dos sniffers, el resultado de la función monopulso y el DoA.

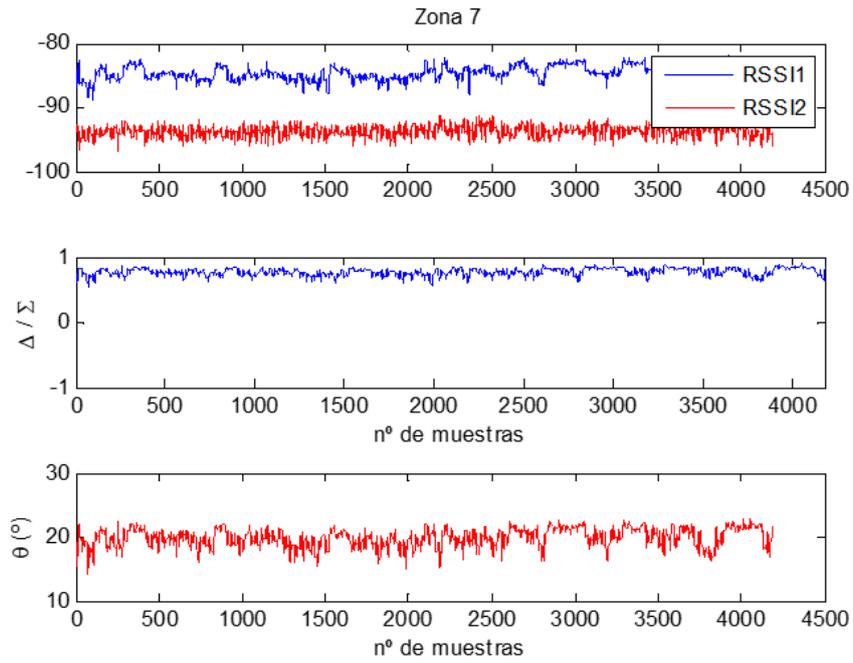


Figura 76. RSSI1 y RSSI2, función monopolso y DoA. Zona 7 para Motorola

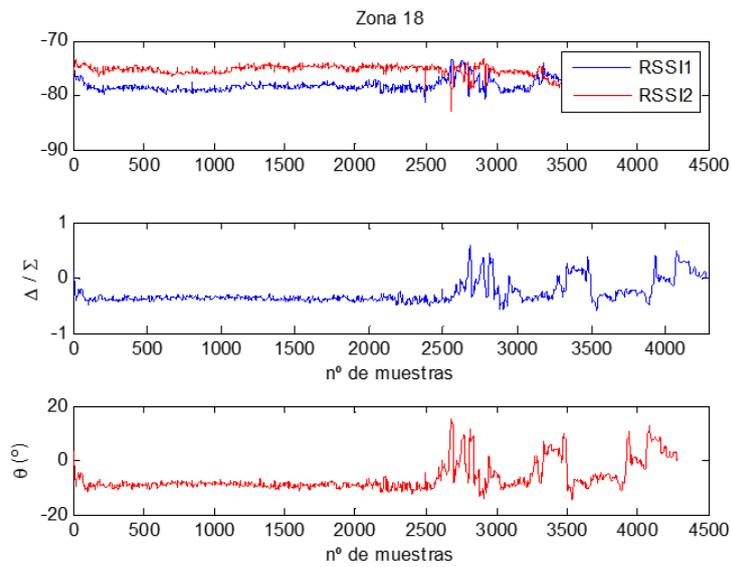


Figura 77. RSSI1 y RSSI2, función monopolso y DoA. Zona 18 para Motorola

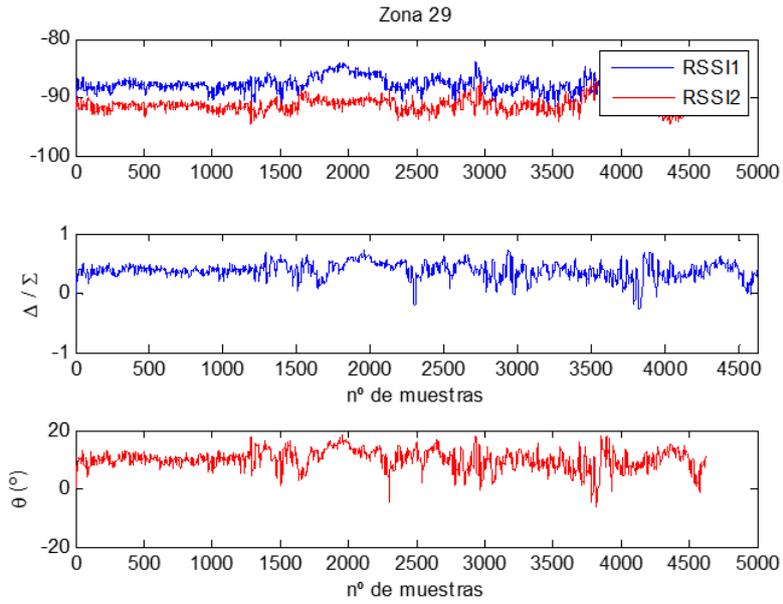


Figura 78. RSSI1 y RSSI2, función monopulso y DoA. Zona 29 para Motorola

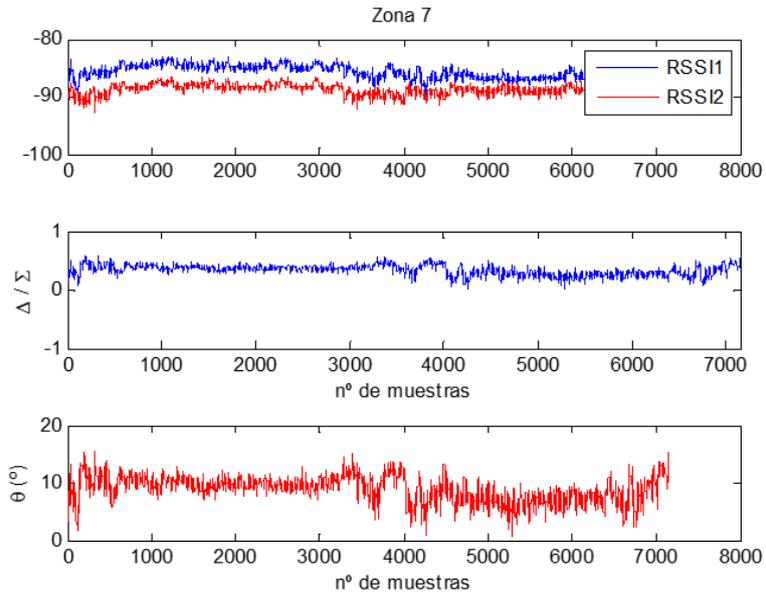


Figura 79. RSSI1 y RSSI2, función monopulso y DoA. Zona 7 para Huawei P10 Lite

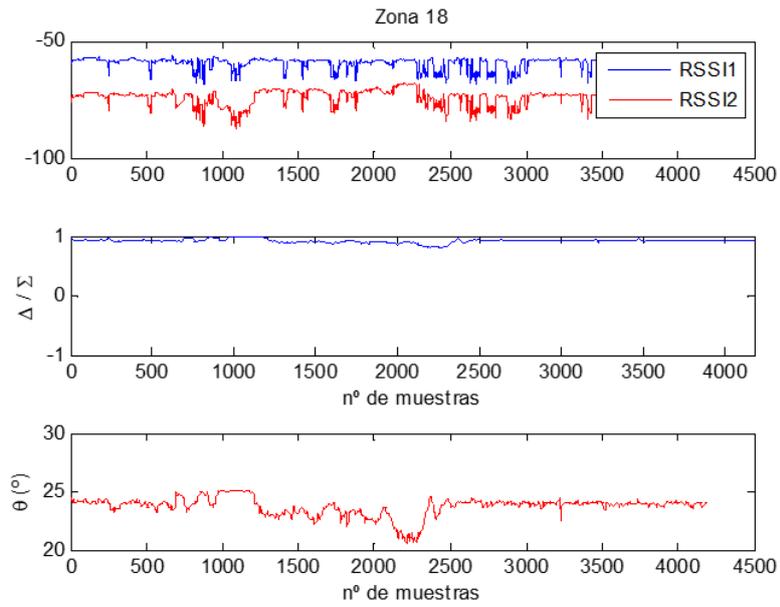


Figura 80. RSSI1 y RSSI2, función monopulso y DoA. Zona 18 para Huawei P10 Lite

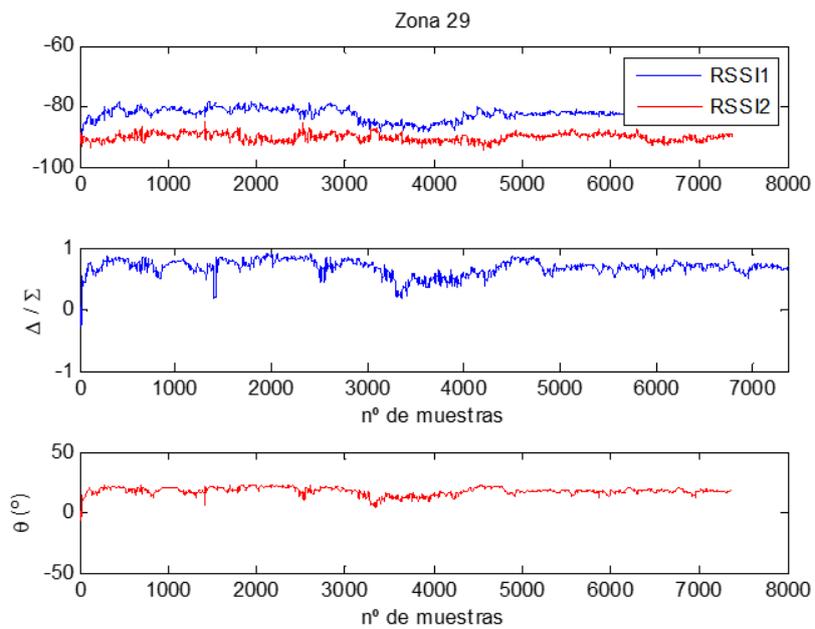


Figura 81. RSSI1 y RSSI2, función monopulso y DoA. Zona 29 para Huawei P10 Lite

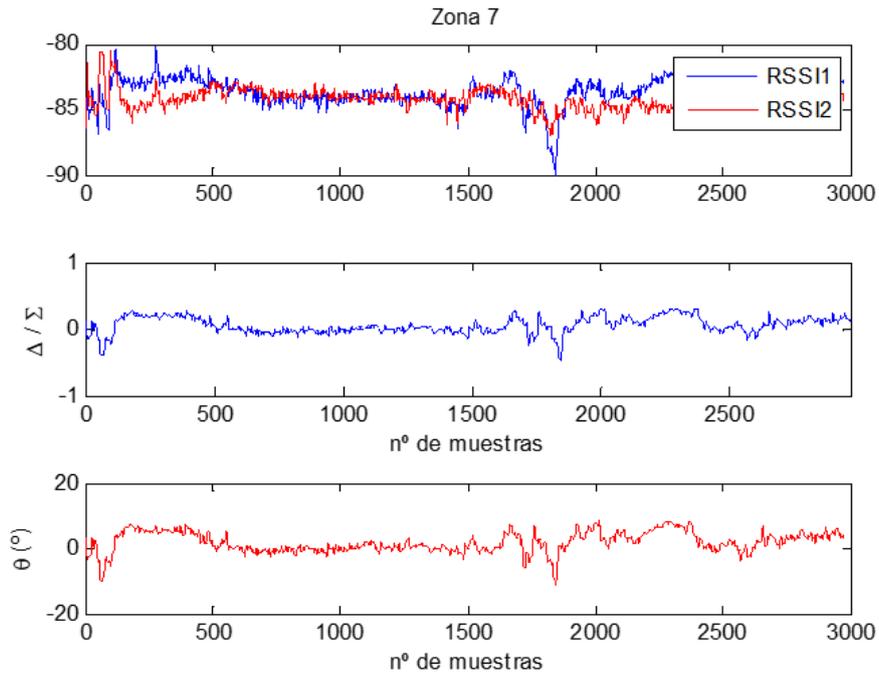


Figura 82. RSSI1 y RSSI2, función monopulso y DoA. Zona 7 para Xiaomi Mi5

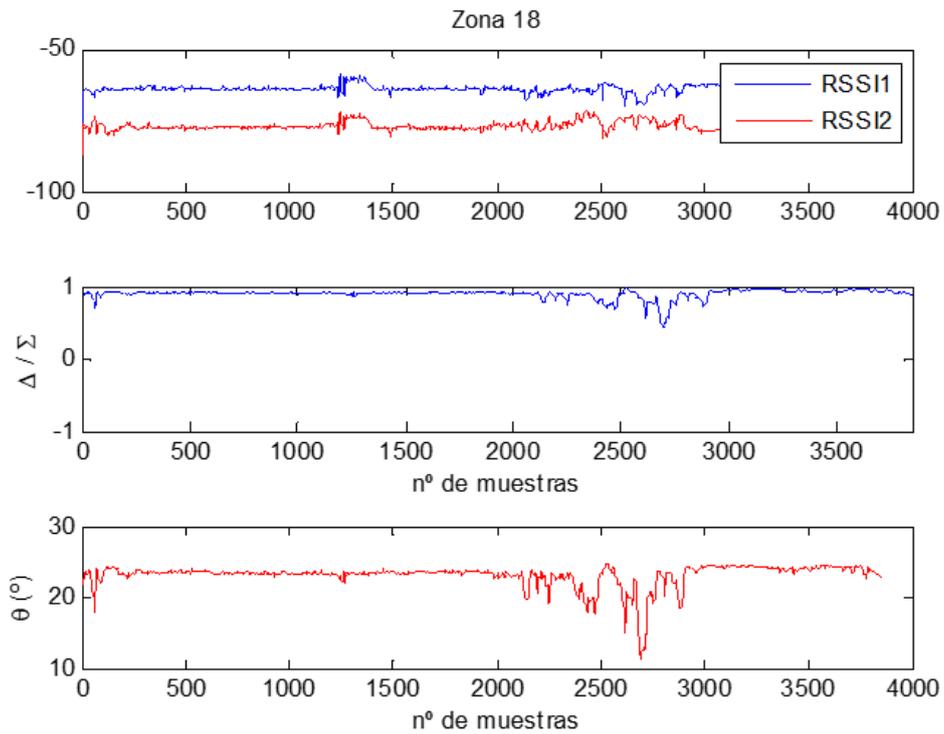


Figura 83. RSSI1 y RSSI2, función monopulso y DoA. Zona 18 para Xiaomi Mi5

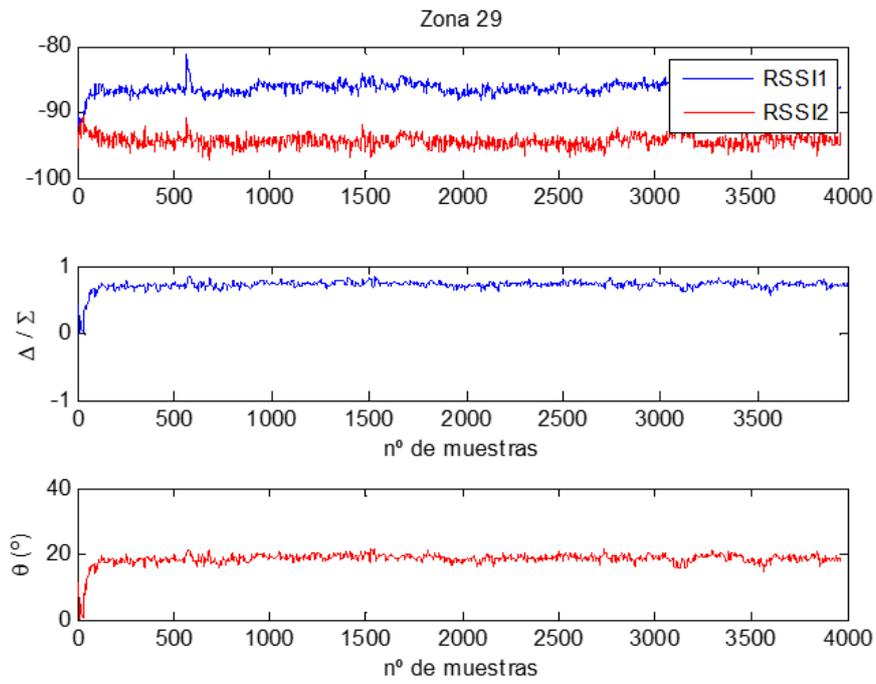


Figura 84. RSSI1 y RSSI2, función monopulso y DoA. Zona 29 para Xiaomi Mi5

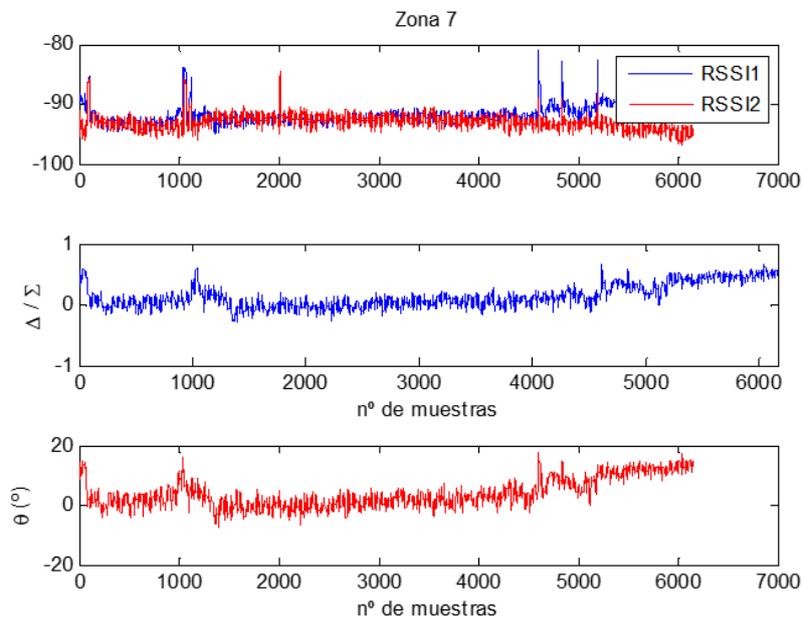


Figura 85. RSSI1 y RSSI2, función monopulso y DoA. Zona 7 para Sony

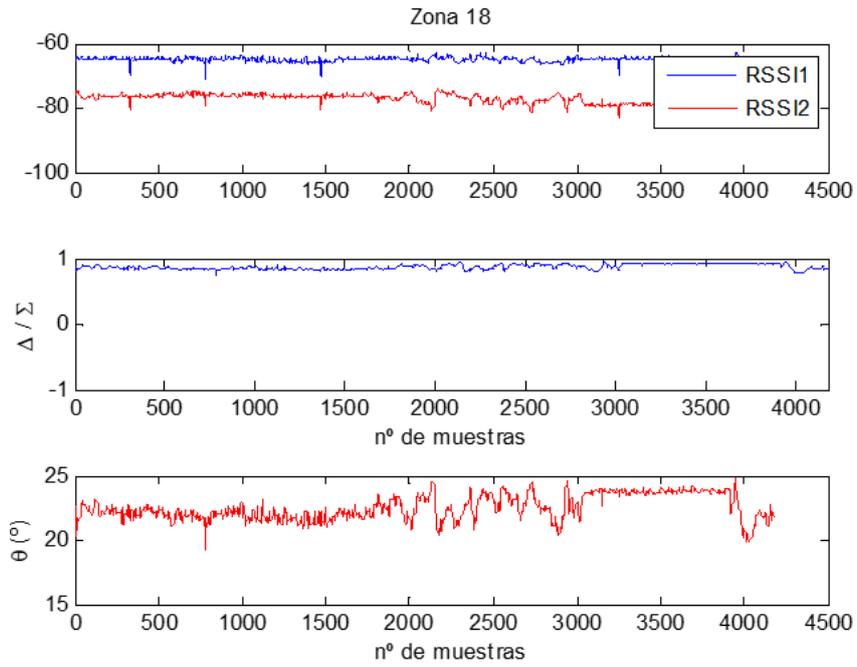


Figura 86. RSSI1 y RSSI2, función monopulso y DoA. Zona 18 para Sony

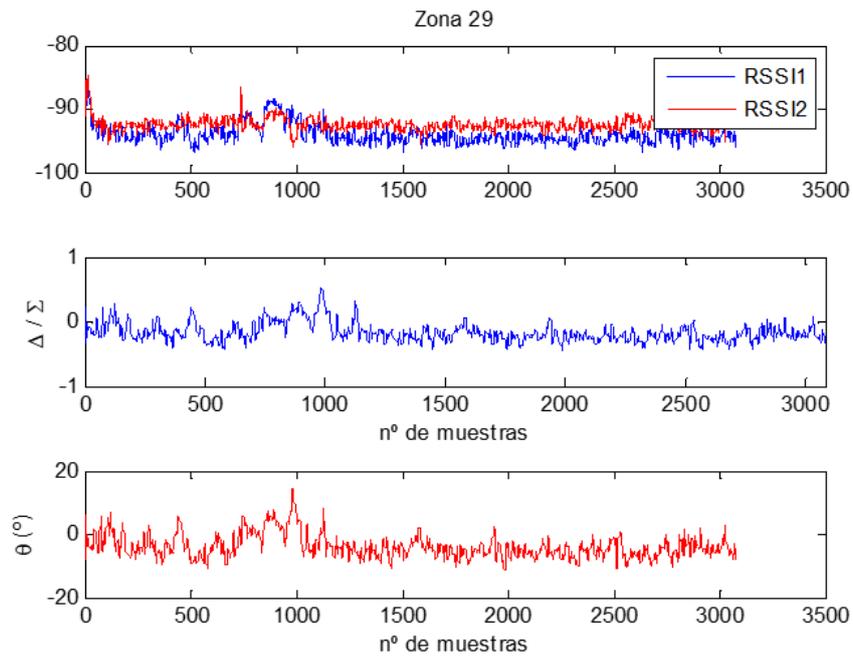


Figura 87. RSSI1 y RSSI2, función monopulso y DoA. Zona 29 para Sony

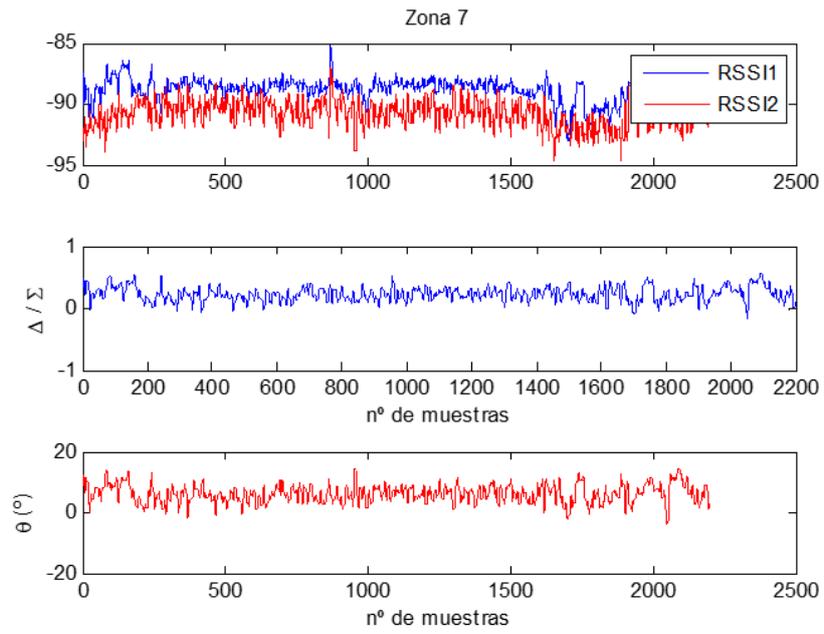


Figura 88. RSSI1 y RSSI2, función monopulso y DoA. Zona 7 para BQ

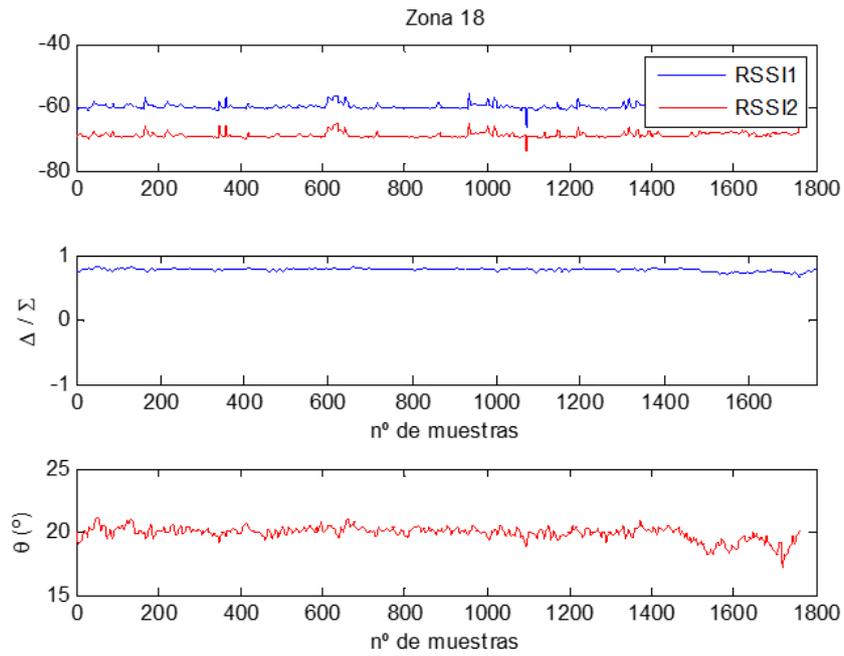


Figura 89. RSSI1 y RSSI2, función monopulso y DoA. Zona 18 para BQ

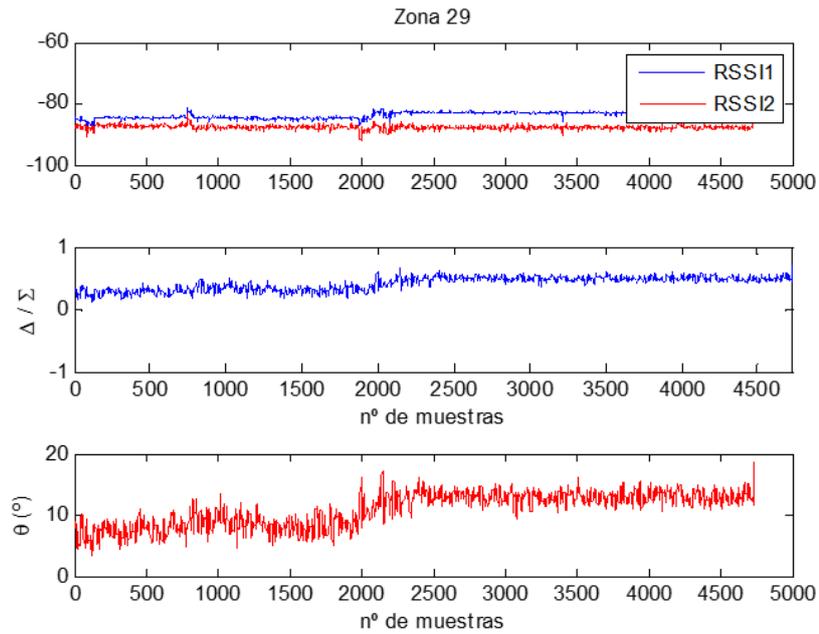


Figura 90. RSSI1 y RSSI2, función monopulso y DoA. Zona 29 para BQ

A la vista de los resultados se puede observar que al tratarse de un entorno con multipath como es un edificio, la función monopulso no es capaz de obtener el DoA esperado. Además, es muy notable la fluctuación que sufre debido a que el nivel de la señal en este caso se ve afectada por elementos como paredes o el propio suelo. Por lo tanto, estamos en condiciones de afirmar que el DoA no puede ser directamente estimado empleando la función monopulso en entornos con una alta componente multipath.

Capítulo 5

DOA COMO INPUT DE UN SISTEMA DE POSICIONAMIENTO BASADO EN MACHINE LEARNING.

Como se ha visto anteriormente se ha estudiado el funcionamiento de la función monopolso en entornos con y sin multipath. Además, se han extendido para varios terminales móviles y se ha hecho uso de un sniffer para obtener el DoA y dos simultáneos para estimar la posición exacta.

En este capítulo se estudiará si se puede emplear la función monopolso como entrada de un algoritmo de posicionamiento basado en machine learning.

Para intentar responder a todas estas preguntas comenzaremos por comprobar en entorno sin multipath la variabilidad de la RSSI, la estabilidad de la función monopolso y la posibilidad de calcular el DoA y la posición absoluta (ranging) empleando un sistema de machine learning que tenga como entrada la RSSI de las antenas y las distintas componentes de la función monopolso.

5.1 Entorno sin multipath

Primeramente, se va a estudiar la variabilidad de la función monopolso cuando se tiene el multipath del suelo. Del trabajo anterior [2], se pudo ver que el sistema monopolso es muy robusto con respecto al efecto del multipath debido al suelo ya que los dos canales de recepción sufren de igual manera el efecto de las oscilaciones. Como se puede ver en la siguiente figura, los niveles en la función monopolso se mantienen prácticamente constantes.

Se puede observar que el DoA estimado se mantiene bastante estable con las variaciones de distancia, mostrando un valor medio alrededor de -15° .

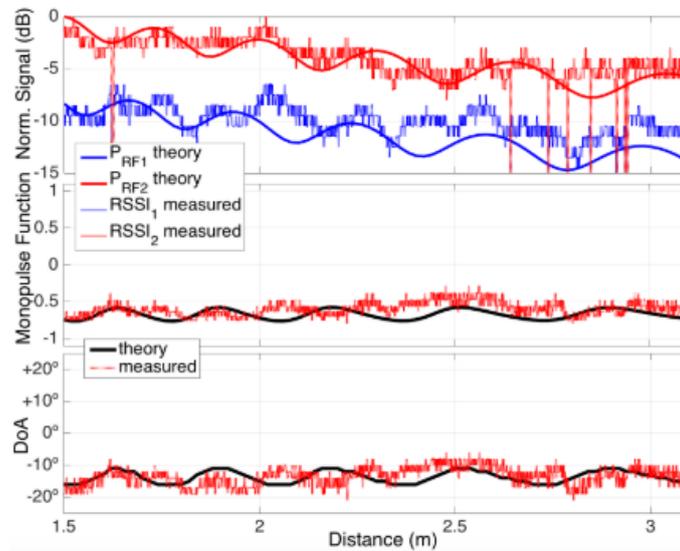


Figura 91. Variación de la función monopulso en cámara anecoica frente en función del movimiento de aproximación

Este comportamiento corresponde a un entorno ideal, es decir, el entorno de una campaña de medidas realizada en una cámara anecoica. Ahora, el primer escenario donde se plantea estudiar la variabilidad de la RSSI empleando el HAD sniffer, la estabilidad de la función monopulso y la posibilidad de emplear sus componentes como entrada de un sistema de localización, es un entorno abierto, de 38 metros cuadrados aproximadamente, donde se despliega 1 único sniffer. Se realiza una campaña de medidas en 25 puntos tal y como se muestra en la figura 82. Se usó el siguiente esquema, donde se recogieron una cantidad de muestras similar en cada uno de los puntos. Una muestra está formada por las componentes RSSI1 y RSSI2 en un mismo instante de tiempo. En total se tienen 16357 muestras que caracterizan los 25 puntos de la rejilla.

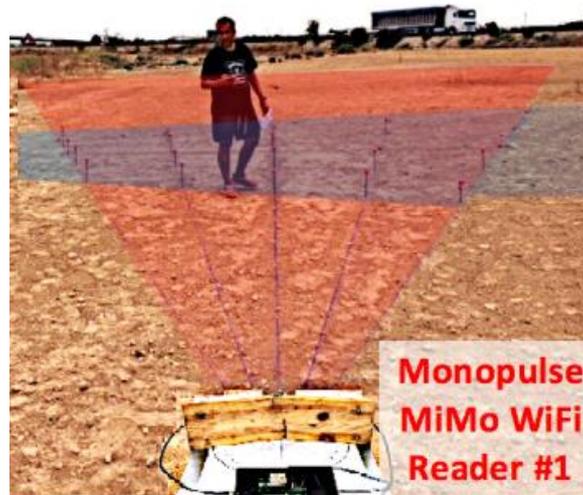


Figura 92. MiMo WiFi monopulse reader in outdoor

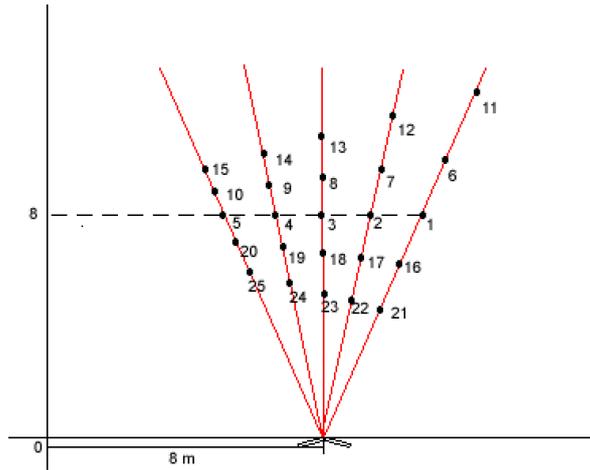


Figura 93. Puntos de medida seleccionados

El primer paso será estudiar la variabilidad de la RSSI a lo largo del tiempo de recogida de las muestras. Se han elegido tres puntos significativos como son el 1, 3 y 5. Uno de los puntos se encuentra en el ángulo de 0°, otro en 20° y otro en -20°, los tres en el FoV (Field of view) del HAD sniffer. Se ha aplicado un factor de corrección de $K_D=4\text{dB}$ ($K_D=2.51$ en forma lineal) como resultado de encontrar el valor que cumple con la ecuación:

$$K_D = \frac{RSSI_1(\theta = 0^\circ)}{RSSI_2(\theta = 0^\circ)}$$

$$K_D = RSSI_1(0^\circ) - RSSI_2(0^\circ) \quad (\text{dB})$$

Se muestra en la figura 94 como para el punto 3, situado en 0°, las dos antenas reciben la misma potencia en dB y el 100% de las muestras se obtienen entre 57 y 61 dB tanto para RSSI1 como para RSSI2 (salvo varios outliers). En la zona 1, se tiene una mayor RSSI de la antena 1 como era de esperar, pero se sigue mostrando una variación de la RSSI que no supera los 5 dBs en el peor de los casos para las dos antenas. Con respecto a la zona 5, se tiene una mayor RSSI en la antena 2, también como era de esperar, siendo la variabilidad de 5 dB, similar a la zona 1.

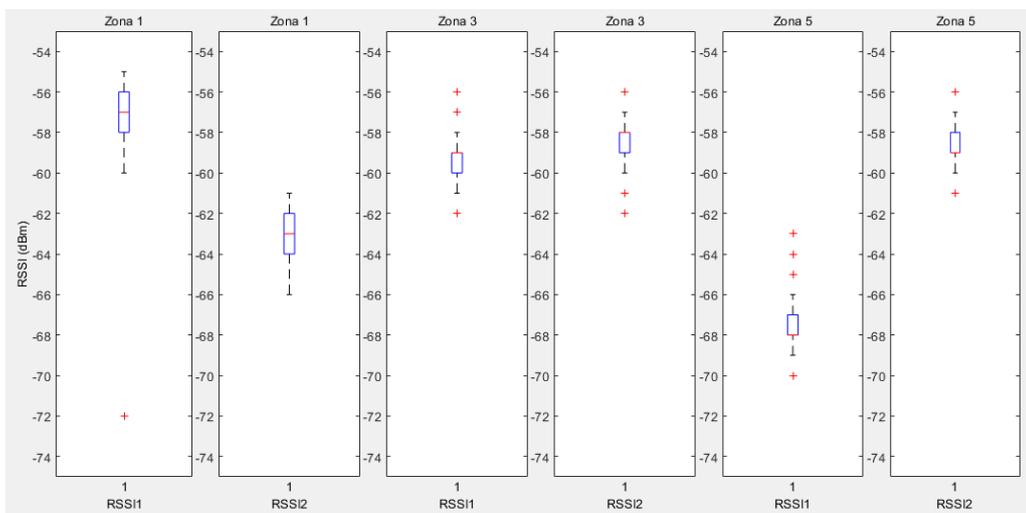


Figura 94. Variabilidad de la RSSI absoluta en cada antena para los puntos

Si se representa la evolución de la RSSI en el tiempo para las diferentes antenas, se puede ver como los cambios en la RSSI de la antena 1 y de la antena 2 están correlacionados en el tiempo, de modo que los cambios en una antena afectan a la otra en el mismo instante y, por lo tanto, la función monopulso sigue siendo estable en este entorno outdoor con presencia del único multipath del suelo. En la siguiente figura se muestra la correlación entre los cambios de la RSSI y como la función monopulso refleja los valores que se esperan de ella para cada DoA.

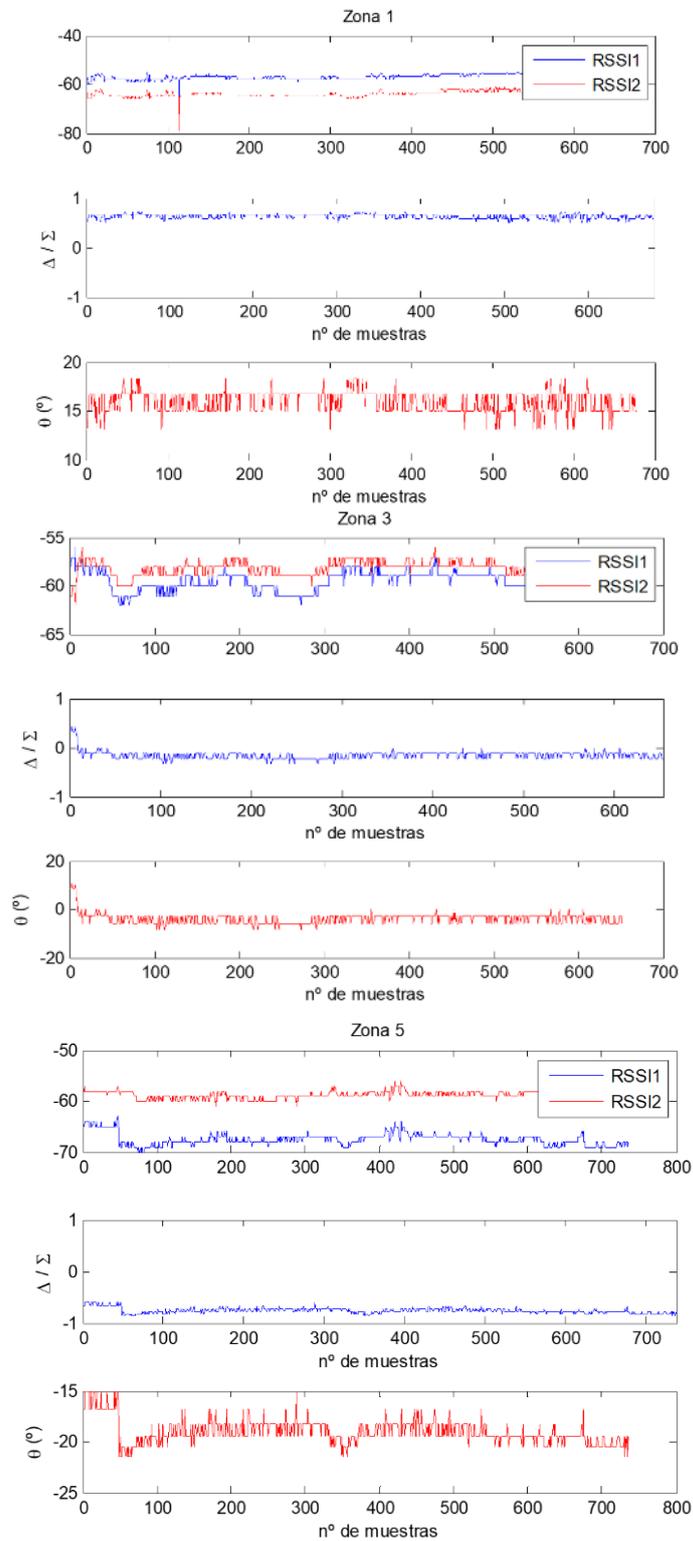


Figura 95. Variación de RSSI, valor de la función monopulso y DOA de las zonas 1, 3 y 5

Por lo tanto, para este tipo de entorno, la función monopolso es un buen y robusto estimador de la posición, incluso empleando 1 único sniffer, somos capaces de encontrar el DoA de la señal recibida. Debido a la correlación de las señales entre las antenas, las variaciones observadas en una de ellas afectan de forma proporcional a la señal que se recibe por la otra. Gracias a no tener multipath y una RSSI estable, con poca variabilidad, y tal y como se demostró en el trabajo anterior, la función monopolso puede determinar el DoA independientemente de multipath del suelo.

Gracias a la correlación y a la estabilidad de la función monopolso, se puede deducir que podrá inferir una función que estime el DoA con precisión mediante una red neuronal que funcione a modo de clasificador. Para comprobar esta hipótesis, se van a agrupar las muestras tomadas en cada punto a un ángulo correspondiente, simplificando el problema a un clasificador de 5 zonas, cada una de ellas correspondiente al ángulo 0° , 10° , 20° , -10° y -20° tal y como se muestra a continuación.

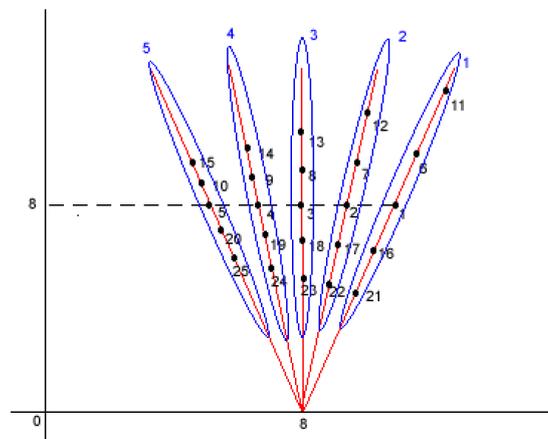


Figura 96. Representación de cada uno de los ángulos obtenidos en la NN

La red neuronal como clasificador está formada por dos capas ocultas. Un rectificador lineal de unidad (ReLU) es usado como una función de activación no lineal en ambas capas y una función softmax es usada como capa de salida. Se hacen dos diferentes approaches para estimar el ángulo de llegada (DoA). En la primera de ellas, la red neuronal (NN) cuenta con 5 entradas. Estas son el nivel de RSSI1, el nivel de RSSI2, la suma de ambas RSSI1+RSSI2, la diferencia RSSI1-RSSI2 y el resultado de la función monopolso.

Ambo sistemas NN están entrenados usando el popular algoritmo Adam, basado en gradiente. Como se describe en [4] se utiliza para minimizar el coste de la función the cross-entropy. El número de epochs es 20000, el factor de learning rate es de 0.0001 y se tiene un 80% de muestras como training subset (13085) y un 20% de muestras como test subset (3272).

En la siguiente tabla se muestran los valores de 40 nodos, 20.000 epochs y 0.0001 de learning rate como valores más representativos. En el Anexo I se muestran los resultados de las distintas variaciones de la NN.

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance
3	2	40	20000	0.0001	0.91463506	0.9125917
5	2	40	20000	0.0001	0.9143294	0.9125917

Por lo tanto, independientemente de si se emplea 5 inputs RSSI1, RSSI2, RSSI1+RSSI2, RSSI1-RSSI2, y el resultado de la función monopolso o 3 inputs, RSSI1+RSSI2, RSSI1-RSSI2 y el resultado de la función monopolso, se puede determinar el DoA empleando una NN.

Una vez que se ha comprobado que el DoA puede ser correctamente inferido por una NN además de por la función monopolso, se emplea el mismo escenario, pero se va a tener en cuenta los 25 puntos y no la simplificación por ángulo, para inferir una función de clasificación por zona. Se va a intentaremos probar la hipótesis de que se puede usar los parámetros que forman la función monopolso para tener un clasificador basado en NN. En [5], empleando el modelo de propagación en campo libre y el DoA obtenido por el sistema, son capaces de obtener la posición exacta de los TAGs RFID empleando ranging que consiste en establecer un punto intermedio en una línea recta entre dos puntos finales se conoce como rango.

De forma similar a como se ha realizado anteriormente con la clasificación por ángulo, se va a estudiar si se puede sustituir la función de ranging de cada antena por una NN que determine la posición de las muestras en cada punto en un entorno con el único multipath del suelo. Para comprobar esta hipótesis se ha empleado una NN con la misma estructura que la empleada en el caso anterior (dos capas ocultas, un rectificador lineal de unidad (ReLU) que es usado como una función de activación no lineal en ambas capas y una función softmax que es usada como capa de salida). Además, se ha obtenido la coordenada X,Y de cada uno de los 25 puntos con el fin de obtener la métrica de error de distancia media, empleando la distancia euclídea del punto estimado al punto real. El número de epochs es 20000, el factor de learning rate es de 0.0001 y 80% de muestras como training subset (13085) y 20% de muestras como test subset (3272). Los resultados obtenidos empleando 3 inputs en la NN (RSSI1+RSSI2, RSSI1-RSSI2, y el resultado de la función monopolso) y 5 inputs (RSSI1, RSSI2, RSSI1+RSSI2, RSSI1-RSSI2, y el resultado de la función monopolso).

En la tabla siguiente se muestran los valores de 40 nodos, 20.000 epochs y 0.0001 de learning rate como valores más representativos. En Anexo II se muestran los resultados de las distintas variaciones de la NN.

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance	Error medio
3	2	40	20000	0.0001	0.84203285	0.8377139	0.3775
5	2	40	20000	0.0001	0.8402751	0.83557457	0.3788

Como se puede observar, se obtiene una muy buena métrica de error medio, con menos de 30 cm de error medio entre las 3.272 muestras que forman el conjunto de test. Si se representa la CDF (“Función de Distribución Acumulada”) tanto para 3 como para 5 input, no se aprecian diferencias entre una y otra.

Una función de distribución acumulada está asociada a una variable aleatoria real: X sujeta a cierta ley de distribución de probabilidad, es una función matemática de la variable real: x que describe la probabilidad de que X tenga un valor menor o igual que x .

$$F(x) = P(X \leq x)$$

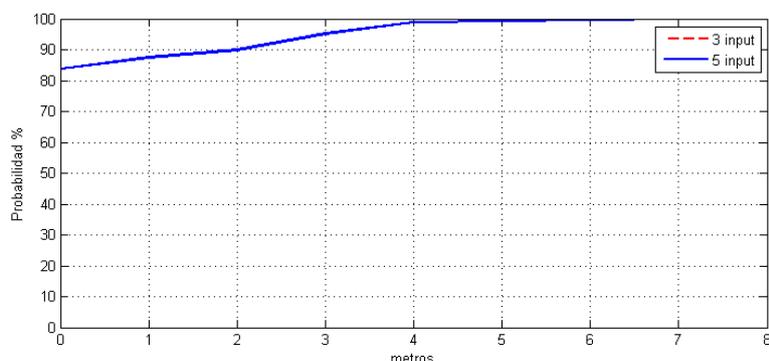


Figura 97. CDF del error en metros. Entorno sin multipath

Esta métrica de error nos indica una alta precisión en la determinación de la zona empleando una NN que infiere la función de ranging en entornos con el único multipath del suelo, tanto empleando 3 como 5 input de entrada a la NN.

Por lo tanto, se puede afirmar, que usando una NN y mediante el sistema HAD y la función monopolso se puede determinar con éxito la zona determinada, con un menor margen de error que el resto de soluciones que podemos encontrar en la bibliografía. Además, el sistema es capaz de posicionar empleando solamente como input los elementos RSSI1+RSSI2, RSSI1-RSSI2 y el resultado de la función monopolso.

5.2 Entorno con multipath

Ahora, se va a intentar resolver la siguiente cuestión de si es posible determinar la zona en la que se encuentra el smartphone usando 1 único sniffer, mediante una NN y empleando los valores de RSSI del HAD sniffer.

Con los datos de cada uno de los teléfonos, se va a entrenar una red neuronal distinta y se va a probar frente a cada red cada una de las medidas. Se propone mecanismos de pretratamiento de datos que aumenten el rendimiento del sistema. Entre ellos probar agrupación temporal de datos, cambiar el input de la red neuronal.

Para ello se va a emplear las muestras recogidas con el teléfono Motorola como primer punto de partida. De las 109.407 muestras, se emplean el 80% (87.525) en training y el 20% (21.882) en test. En el anexo III se muestran los datos de testeo de la NN.

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance	Error medio
3	2	40	20000	0.0001	0.70526135	0.7072937	3.665
5	2	40	20000	0.0001	0.70838046	0.70829904	3.62

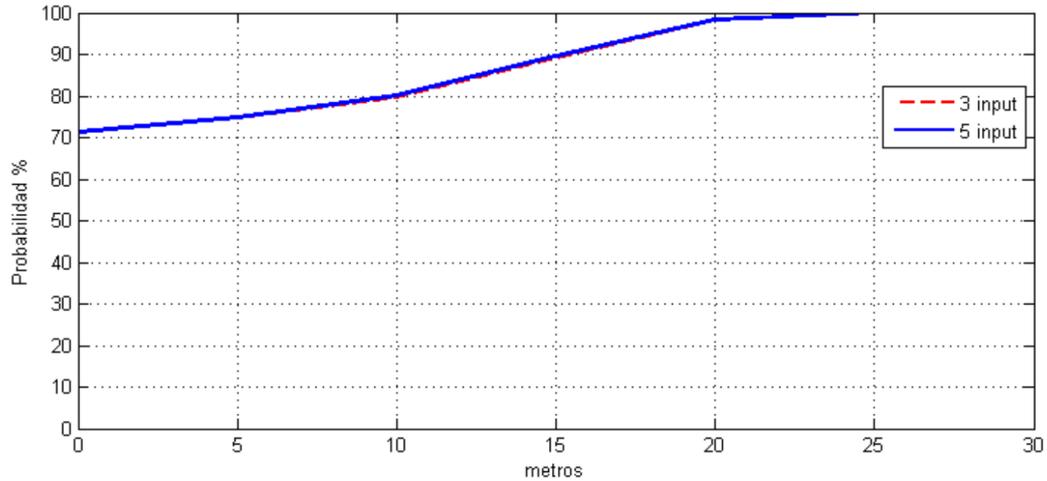


Figura 98.CDF del error en metros. Entorno con multipath

Por lo tanto, independientemente del número de inputs de la NN, se puede determinar la posición del smartphone empleando una NN que determine la posición exacta con un margen de error de 3.6 metros, teniendo una tasa de acierto en torno al 70%, tanto usando 3 como 5 inputs.

Para comprobar que se tiene un funcionamiento similar, independientemente del teléfono, se crea una NN similar a la anterior, pero en este caso empleando las medidas adquiridas con el teléfono BQ. El número de muestras es de 55120, empleando de nuevo el 80% en training (44096 muestras) y el 20% en test (11024 muestras). De nuevo se comprueba el funcionamiento empleando tanto 5 como 3 inputs:

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance	Error medio
3	2	40	20000	0.0001	0.64391327	0.6434144	4.61
5	2	40	20000	0.0001	0.6490158	0.6477685	4.5489

A la hora de estimar la localización de las muestras empleando el teléfono BQ se tiene un performance peor que empleando las muestras del teléfono Motorola. Esto se puede deber a tener un número de muestras significativamente menor.

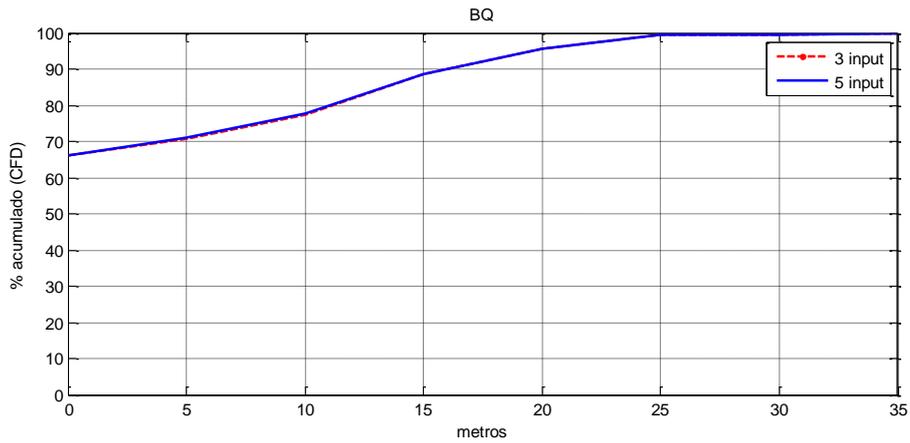


Figura 99. CDF del error en metros. Entorno con multipath. Terminal BQ

Para comprobar que el performance teniendo más muestras funciona mejor, hacemos el mismo procesamiento con Huawei, que tiene 129.910 muestras. Se emplean 80% en training (103.928) y 20% en test (25.982).

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance	Error medio
3	2	40	20000	0.0001	0.6552325	0.653183	4.1894
5	2	40	20000	0.0001	0.6738126	0.6718113	4.0672

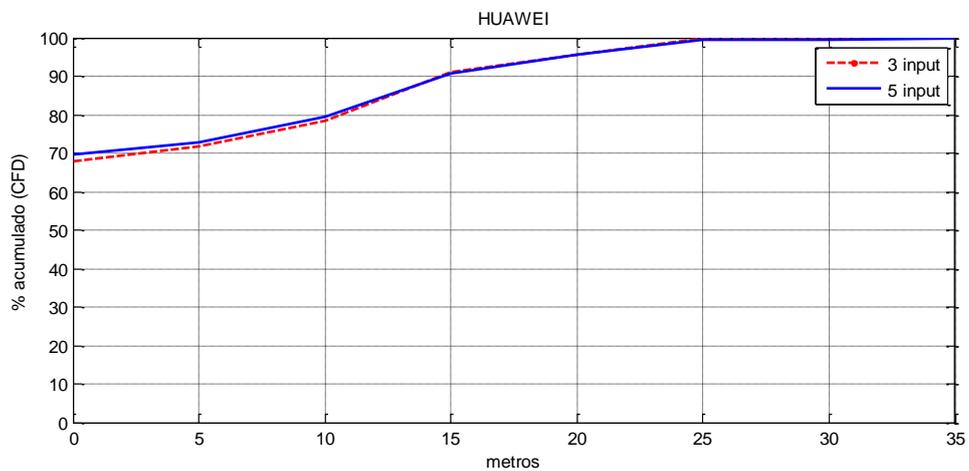


Figura 100. CDF del error en metros. Entorno con multipath. Terminal Huawei P10 Lite

Para el caso del terminal Sony, con 97.129 muestras, se emplean de nuevo el 80% (77.703) para training y 20% (19.426) para test. Los resultados son:

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance	Error medio
3	2	40	20000	0.0001	0.64704067	0.64799756	5.242059
5	2	40	20000	0.0001	0.6769108	0.6774426	4.7735417

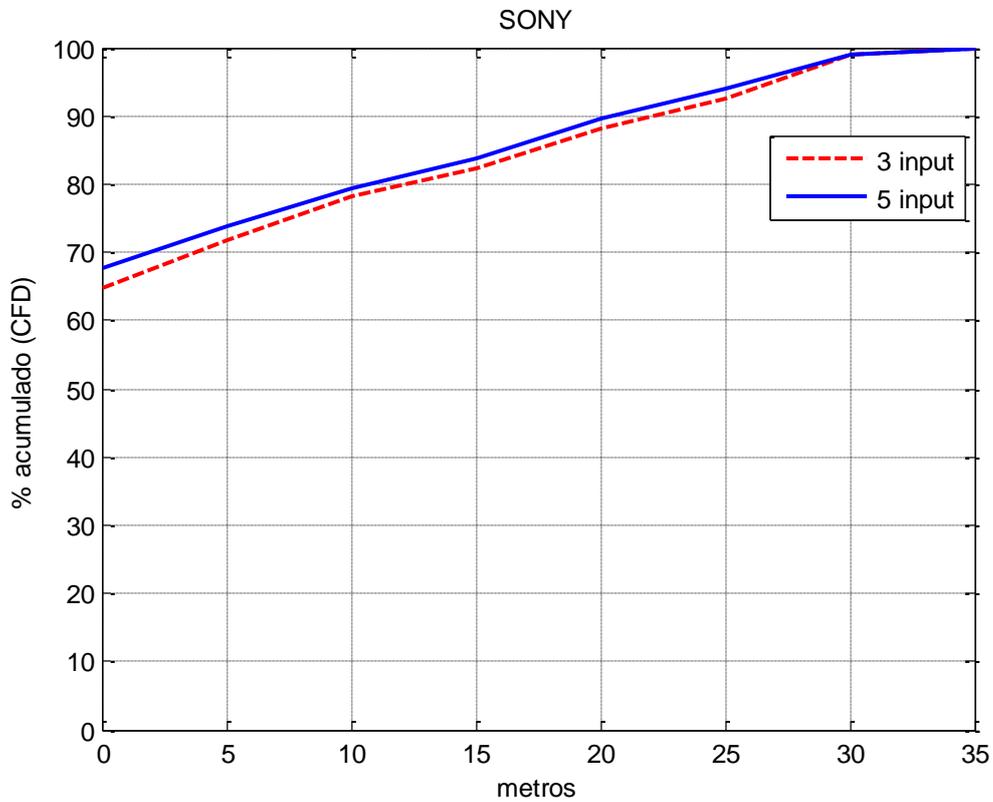


Figura 101. CDF del error en metros. Entorno con multipath. Terminal Sony

Para el caso del terminal xiaomi, con 81.400 muestras, se emplean el 80% en training (65.120) y el 20% para test (16.280). Los resultados que se obtienen son:

Input	Layers	Nodes	Epoch	Learning Rate	Training Performance	Test Performance	Error medio
3	2	40	20000	0.0001	0.7103655	0.70577395	4.42766
5	2	40	20000	0.0001	0.7097052	0.7054668	4.41315

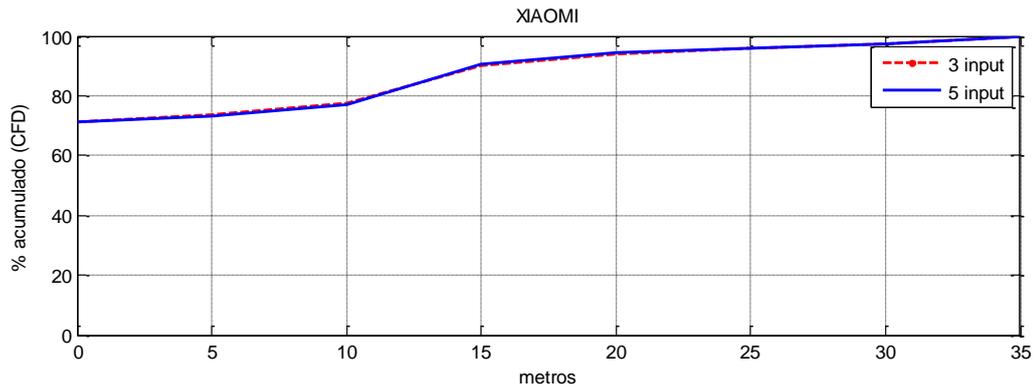


Figura 102. CDF del error en metros. Entorno con multipath. Terminal Xiaomi Mi5

A modo de resumen, el comportamiento de cada uno de los teléfonos, cuando se trata de identificar las muestras del mismo terminal:

Teléfono	Input	Training Performance	Test Performance	Error medio
Motorola	3	0.70526135	0.7072937	3.665
Motorola	5	0.70838046	0.70829904	3.62
BQ	3	0.64391327	0.6434144	4.61
BQ	5	0.6490158	0.6477685	4.5489
Huawei	3	0.6552325	0.653183	4.1894
Huawei	5	0.6738126	0.6718113	4.0672
Sony	3	0.64704067	0.64799756	5.242059
Sony	5	0.6769108	0.6774426	4.7735417
Xiaomi	3	0.7103655	0.70577395	4.42766
Xiaomi	5	0.7097052	0.7054668	4.41315

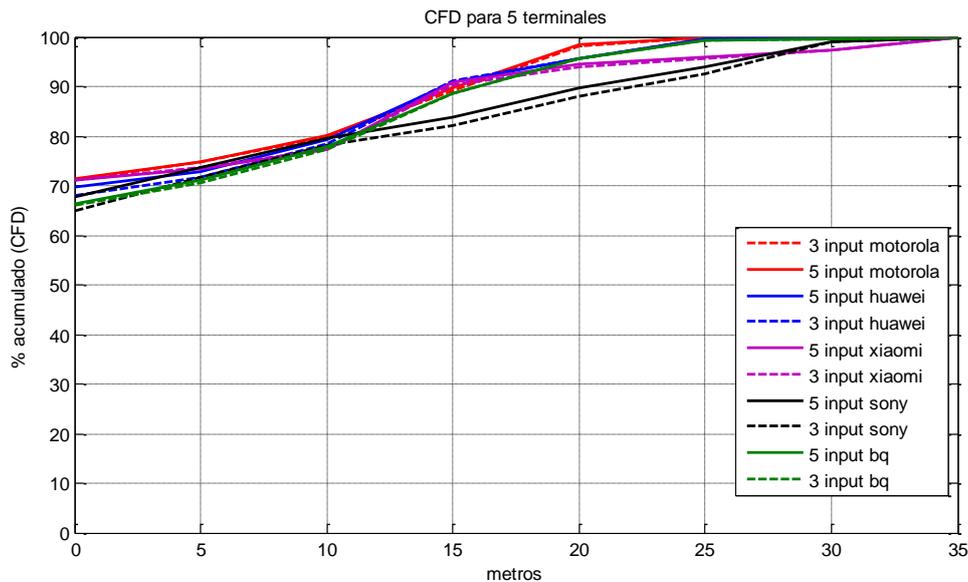


Figura 103. CDF del error en metros. Entorno con multipath. Comparación

Se puede concluir afirmando que se trata de un buen porcentaje de acierto y una distancia media de muestras aceptable dada la relación entre el número de dispositivos empleados y el coste de los mismos. Es decir, gracias a las características de la función monopulso y del uso del sistema HAD, se puede tener una buena precisión usando 1 único sniffer. Además, en la gráfica anterior se puede ver como el porcentaje de acierto entre un terminal y otro es prácticamente igual.

5.3 Entorno con multipath. Localización de terminales distintos a los empleados en la calibración.

De forma similar a como se ha realizado en el punto anterior, para cada uno de los terminales entrenamos una NN. En esta ocasión se prueba a localizar las muestras realizadas con otro teléfono.

Los resultados para Motorola son:

Teléfono training NN	Teléfono validación	Input	Layers	Nodes	Epoch	Learning Rate	Porcentaje acierto	Error medio
Motorola	BQ	3	2	40	20000	0.0001	9.9147	14.32036
Motorola	Huawei	3	2	40	20000	0.0001	11.8428	14.84133
Motorola	Sony	3	2	40	20000	0.0001	12.1487	13.427594
Motorola	Xiaomi	3	2	40	20000	0.0001	13.5749	14.66171
Motorola	BQ	5	2	40	20000	0.0001	11.2935	13.67022
Motorola	Huawei	5	2	40	20000	0.0001	10.0685	15.3319
Motorola	Sony	5	2	40	20000	0.0001	10.9389	20.65609

Motorola	Xiaomi	5	2	40	20000	0.0001	10.3993	15.352879
-----------------	--------	---	---	----	-------	--------	----------------	------------------

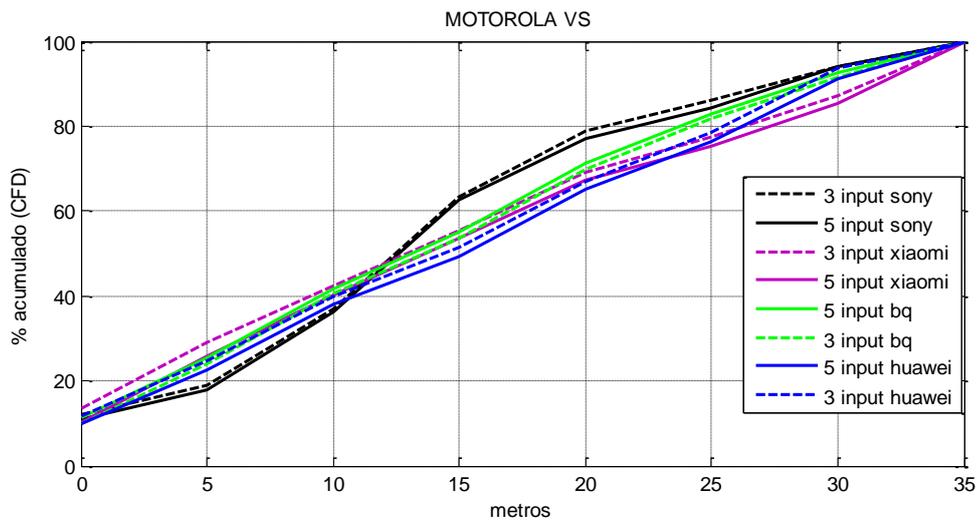


Figura 104. CDF del error en metros. Entorno con multipath. Motorola calibrado con el resto de terminales

Los resultados para BQ son:

Teléfono training NN	Teléfono validación	Input	Layers	Nodes	Epoch	Learning Rate	Porcentaje acierto	Error medio
BQ	Motorola	3	2	40	20000	0.0001	6.8230	16.9831
BQ	Huawei	3	2	40	20000	0.0001	14.6563	12.4838
BQ	Sony	3	2	40	20000	0.0001	7.6598	18.5079
BQ	Xiaomi	3	2	40	20000	0.0001	17.5491	12.42754
BQ	Motorola	5	2	40	20000	0.0001	7.2160	16.5781
BQ	Huawei	5	2	40	20000	0.0001	14.8487	12.549137
BQ	Sony	5	2	40	20000	0.0001	11.9067	16.9566
BQ	Xiaomi	5	2	40	20000	0.0001	17.3526	11.5937

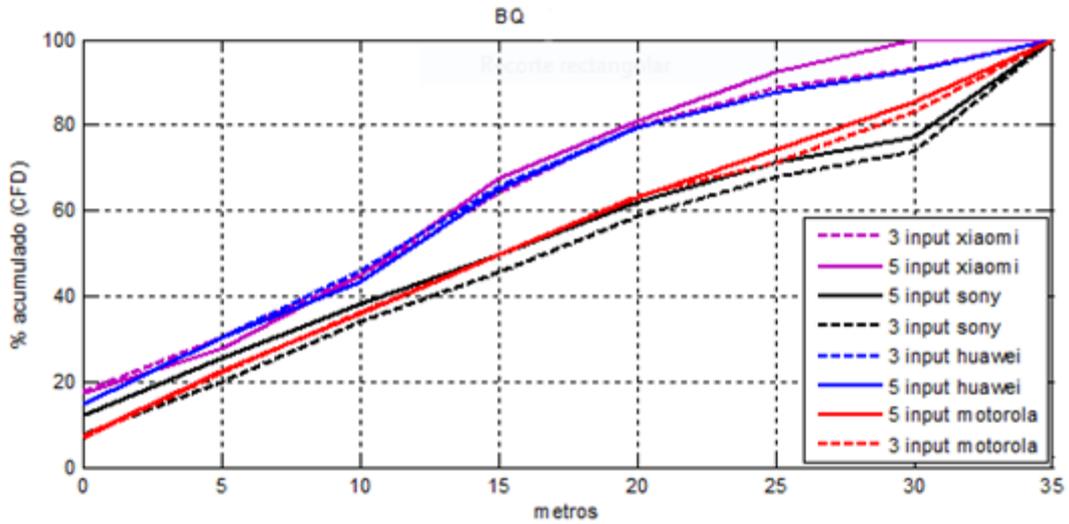


Figura 105.CDF del error en metros. Entorno con multipath. BQ calibrado con el resto de terminales

Los resultados para Huawei son:

Teléfono training NN	Teléfono validación	Input	Layers	Nodes	Epoch	Learning Rate	Porcentaje acierto	Error medio
Huawei	Motorola	3	2	40	20000	0.0001	16.6712	11.61379
Huawei	BQ	3	2	40	20000	0.0001	11.6564	20.426534
Huawei	Sony	3	2	40	20000	0.0001	9.2865	13.54444
Huawei	Xiaomi	3	2	40	20000	0.0001	21.5663	10.3444
Huawei	Motorola	5	2	40	20000	0.0001	12.1333	19.54879
Huawei	BQ	5	2	40	20000	0.0001	14.1509	20.17487
Huawei	Sony	5	2	40	20000	0.0001	7.6856	18.33677
Huawei	Xiaomi	5	2	40	20000	0.0001	27.9361	11.7063

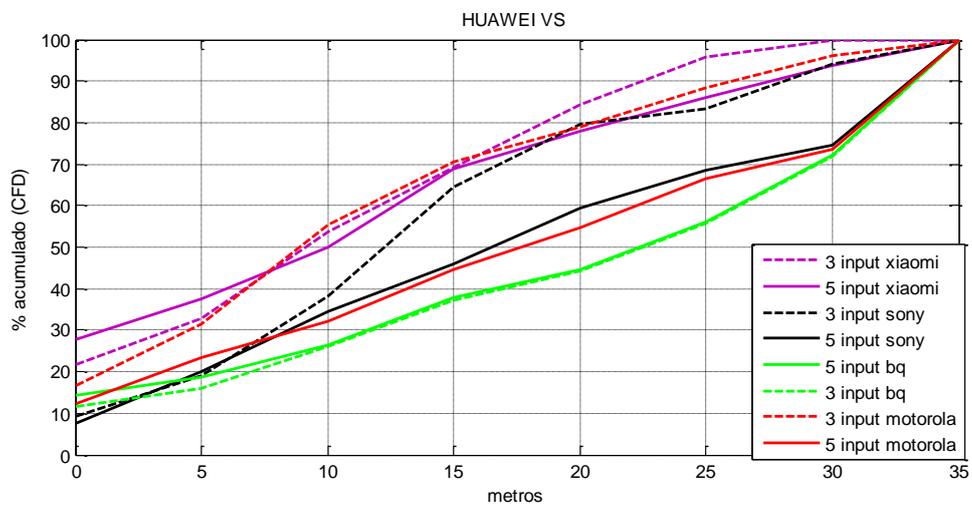


Figura 106.CDF del error en metros. Entorno con multipath. Huawei P10 Lite calibrado con el resto de terminales

Los resultados para Sony son:

Teléfono training NN	Teléfono validación	Input	Layers	Nodes	Epoch	Learning Rate	Porcentaje acierto	Error medio
Sony	Motorola	3	2	40	20000	0.0001	5.4291	13.197880
Sony	BQ	3	2	40	20000	0.0001	6.9485	19.811201
Sony	Huawei	3	2	40	20000	0.0001	13.0244	13.60308
Sony	Xiaomi	3	2	40	20000	0.0001	14.0602	13.328803
Sony	Motorola	5	2	40	20000	0.0001	7.3714	12.71030
Sony	BQ	5	2	40	20000	0.0001	3.7192	20.58872
Sony	Huawei	5	2	40	20000	0.0001	7.0741	19.83537
Sony	Xiaomi	5	2	40	20000	0.0001	6.3882	19.813606

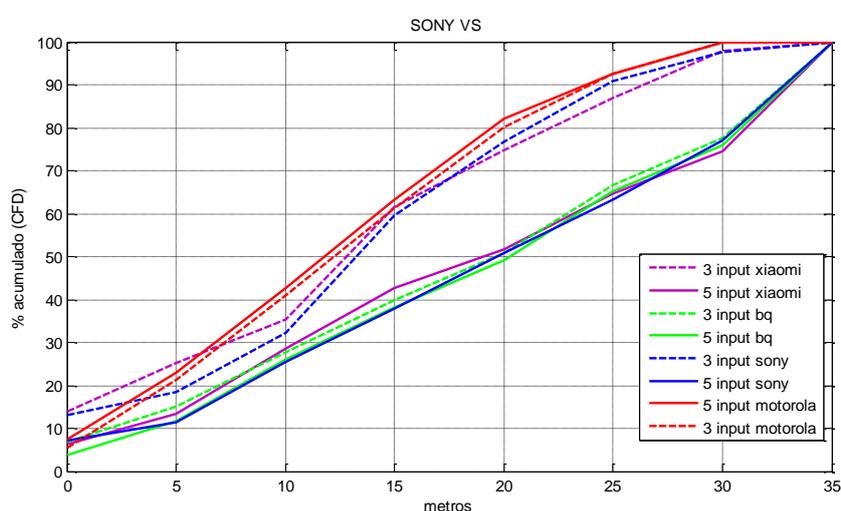


Figura 107. CDF del error en metros. Entorno con multipath. Sony calibrado con el resto de terminales

Los resultados para Xiaomi son:

Teléfono training NN	Teléfono validación	Input	Layers	Nodes	Epoch	Learning Rate	Porcentaje acierto	Error medio
Xiaomi	Motorola	3	2	40	20000	0.0001	13.0747	13.6861326
Xiaomi	BQ	3	2	40	20000	0.0001	12.3821	15.07069
Xiaomi	Sony	3	2	40	20000	0.0001	22.6272	10.8304
Xiaomi	Huawei	3	2	40	20000	0.0001	12.9466	12.90442
Xiaomi	Motorola	5	2	40	20000	0.0001	12.3755	13.89176
Xiaomi	BQ	5	2	40	20000	0.0001	17.2896	11.976023
Xiaomi	Sony	5	2	40	20000	0.0001	22.0768	10.9327634
Xiaomi	Huawei	5	2	40	20000	0.0001	16.4573	12.42041749

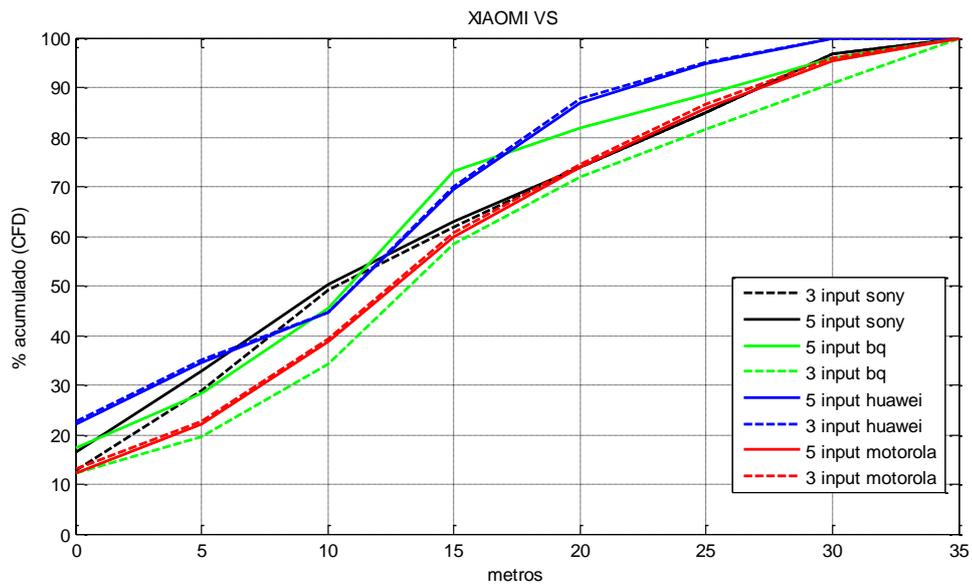


Figura 108. CDF del error en metros. Entorno con multipath. Xiaomi Mi5 calibrado con el resto de terminales

De resultados de las tablas anteriores se pueden extraer las siguientes conclusiones:

- En general, para cada smartphone que es calibrado con otros terminales distintos a los usados en la calibración, la diferencia de error en metros es bastante similar.
- La diferencia de error en metros aumenta para todos los terminales ya que el smartphone es calibrado con terminales distintos a los usados en la calibración.
- La mejora que se obtiene al usar 5 input en la red en lugar de 3 no es muy notable para la mayoría de los escenarios.

Capítulo 6

CONCLUSIONES

En la campaña de medidas realizada en Fuente Álamo se vio cómo era posible cubrir hasta 38 metros cuadrados con un único dispositivo. Al tener en cuenta el multipath, se ha podido observar que el sistema es capaz de cubrir 800 metros cuadrados en las instalaciones de la ETSIT ya que en el primer escenario donde se intentó cubrir hasta 1200 metros cuadrados habían zonas donde el sistema no era capaz de tomar muestras.

En entorno sin multipath, se ha comprobado como la función monopulso ha determinado con éxito el DoA. Además, también se puede estimar de forma precisa la posición usando un segundo sniffer. Pero, a la vista de los resultados, en entorno multipath sería necesario utilizar redes neuronales y otras técnicas de procesamiento para poder obtener la posición exacta ya que el multipath afecta a la obtención del DoA. En los entornos reales como universidades, centros comerciales u hospitales se tienen paredes y suelos/techos de muy diversas características que provocan multipath. Aunque como se ha mencionado el multipath afecta en el DoA, sí que es interesante observar que el multipath afecta de manera similar a los valores de RSSI. Esto infiere en que puedan utilizarse como input de la red neuronal de un algoritmo de posicionamiento.

En cuanto a la heterogeneidad del hardware a localizar, se ha comprobado cómo la utilización de distintas antenas, chipset o smartphones pueden afectar a los niveles de RSSI. Se producen variaciones de hasta 10dB entre distintos terminales que se están midiendo en las mismas condiciones pero gracias a la función monopulso, el sistema responde y se puede obtener de forma correcta el DoA. Por lo tanto, se puede concluir que la función monopulso es robusta ante distinto hardware de medida.

Por último se ha visto que se puede emplear la función monopulso como entrada de un algoritmo de posicionamiento basado en machine learning. De esta forma, los resultados obtenidos son mucho más precisos que empleando solamente el DoA

Capítulo 7

LÍNEAS FUTURAS

La localización en interiores se trata de un problema que todavía no cuenta con una técnica que sea tomada como referencia, al contrario que sucede en exteriores con el GPS. Por esta razón, la línea de investigación en este campo es muy amplia. En el caso particular de este trabajo, el cual está basado en la técnica del ángulo de llegada (DoA), se ha visto cómo este mejora su performance al contar con la función monopulso como entrada de un algoritmo de posicionamiento de una red neuronal. Sería muy interesante realizar experimentos en distintos lugares donde se pueda comparar cómo afecta el multipath y utilizar nuevos modelos de redes neuronales. Cuando se realizó este trabajo, la cámara anecoica tenía averiado la mesa posicionadora que fue usada para caracterizar el sniffer 1. Por esta razón, antes de realizar nuevas campañas de medidas, habría que obtener el diagrama de radiación, la función monopulso y el factor de corrección de una forma precisa para el sniffer 2.

Una vez obtenidos estos datos, será interesante comprobar cómo se comporta el sistema de forma dinámica, es decir, realizar pruebas en movimiento. Sería un experimento parecido al de las clases. En este caso, la idea sería que una persona se vaya desplazando con el Smartphone mientras este va emitiendo tramas. Una vez recogidos los datos, se procesarían tomando la función monopulso y los valores de RSSI como input de una red neuronal. El objetivo es que la red determine con precisión en qué zona se encuentra en cada momento. Como parte del procesado, se implementarían técnicas que comprueben qué en el caso de error, no sea en zonas que se encuentren lejanas como por ejemplo, las cadenas de Markov.

En este trabajo sólo se ha hecho uso de los datos proporcionados por un único sniffer como input de un algoritmo de posicionamiento basado en machine learning. Con el fin de aumentar la precisión, sería muy interesante meter cómo entrada los datos del sniffer 2 funcionando de forma simultánea con el fin de mejorar la precisión al estimar la posición exacta.

BIBLIOGRAFÍA

- [1] A. Duque de Quevedo, F. Ibáñez Urzaiz, J. Gismero Menoyo y A. Asension López, *X-band ubiquitous radar system: First experimental results*.
- [2] J. L. Gomez-Tornero, D. Canete-Rebenaque, J. A. Lopez-Pastor, and A. S. Martinez-Sala, "Hybrid Analog-Digital Processing System for Amplitude-Monopulse RSSI-Based MIMO WiFi Direction-of-Arrival Estimation," *IEEE J. Sel. Top. Signal Process.*, vol. 12, no. 3, 2018.
- [3] Juan Miguel Marín Diazaraque, *Introducción a las Redes Neuronales Aplicadas*, Universidad Carlos III de Madrid, 2012.
- [4] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," pp. 1–15, Dec. 2014.
- [5] Y. Álvarez López, M. E. de Cos Gómez, and F. Las-Heras Andrés, "A received signal strength RFID-based indoor location system," *Sensors Actuators, A Phys.*, vol. 255, pp. 118–133, 2017.