



Universidad
Carlos III de Madrid

Departamento de Teoría de la Señal y de la
Comunicación

PROYECTO FIN DE CARRERA

Localización de Múltiples Blancos mediante Interpolación con Funciones de Base Radial

Autor: Sergio Miguel Pacheco

Tutor: Francisco Javier González Serrano

Leganés, junio de 2015

Título: Localización de Múltiples Blancos mediante Interpolación con Funciones de Base Radial

Autor: Sergio Miguel Pacheco

Director: Francisco Javier González Serrano

EL TRIBUNAL

Presidente: Carlos Bousoño Calzón

Vocal: Marcos Vera Coello

Secretario: José Luis Vázquez Roy

Realizado el acto de defensa y lectura del Proyecto Fin de Carrera el día 25 de junio de 2015 en Leganés, en la Escuela Politécnica Superior de la Universidad Carlos III de Madrid, acuerda otorgarle la CALIFICACIÓN de

VOCAL

SECRETARIO

PRESIDENTE

Agradecimientos

En primer lugar agradecer especialmente a mis padres, Juan Pablo y Angelina, que me han apoyado siempre sin condiciones y siempre me han dado y me darán los mejores consejos.

A Lidia, mi amiga, novia, y ahora esposa, en definitiva, la mujer de mi vida, que me soporta todos los días y que sin ella esto no habría sido posible. Gracias por estar siempre a mi lado.

Agradecer también a mi hermano, Alberto, el apoyo incondicional que siempre he tenido de su parte. Más que un hermano ha sido un segundo padre.

A las grandes personas que conocí en la Universidad y ahora son mis amigos, Alberto, Mijarra, María, Iván, Kiko, Nacho, Pablo y Mari. Sois unos fenómenos, no cambiéis.

Mención especial merecen Pedro y Charly. Nos conocimos con seis añitos y todavía nos queremos.

Y por supuesto, a mi tutor Francisco Javier, siempre disponible para ayudarme y mejorar este proyecto. Gracias por tu paciencia.

Resumen

En este proyecto se estudiará e implementará una técnica de estimación de la posición de uno o más blancos a partir de observaciones recogidas por un conjunto de sensores desplegados aleatoriamente por un terreno. Para ello emplearemos una técnica de localización basada en interpolación de funciones con base radial (RBFs).

Para ello, se parte de la hipótesis de que la función que estamos aproximando presenta máximos en las posiciones de los blancos a localizar. Por tanto, si la calidad de la función interpolada es lo suficientemente buena, sus máximos coincidirán también con los de la función original, por lo que la determinación de dichos máximos proporcionará una estima de las posiciones de los blancos.

Para reducir la complejidad del método, las RBFs se distribuirán sobre una rejilla predefinida, por lo que, sólo será necesario calcular el ancho y peso asociados. Como las RBFs son funciones de base local (sólo toman valores significativos en torno a su centro), el peso asociado estará relacionado con el valor de la función a interpolar en su entorno, de forma similar a la que tendría un “sensor virtual” ubicado en su misma posición.

El despliegue de las RBFs sobre la rejilla tiene el inconveniente de que su número aumenta de forma exponencial cuando aumenta el tamaño de la región a controlar. Para mantener controlado el número de RBFs que participan en la interpolación, en este PFC se empleará el método de optimización LASSO. Con este método, se puede optimizar un vector de parámetros (los pesos de las RBFs), de forma que se minimice una determinada función de coste, reduciendo así el número de elementos no nulos en dicho vector.

En este PFC, se ha aplicado el método RBF+Lasso a problemas de localización. Mediante una serie de simulaciones, se han podido ajustar los parámetros del método RBF+Lasso (ancho y número de funciones RBFs activas) y se han obtenido medidas de la calidad de las posiciones estimadas.

Palabras clave: Funciones de base radial, RBF, LASSO, Localización, Rescate, Estimación, Optimización, Localización múltiple, Regresión

Abstract

In this PFC we're going to study and implement a technique for estimating the position of a target from observations collected by a group of sensors deployed randomly. To do this we use a technique based on location interpolation with radial basis functions (RBFs).

To do this, we begin with the assumption that the function we are approximating, exhibits maximum at the positions of the targets to locate. Therefore, if the quality of the interpolated function is good, their maximums will coincide with the maximums of the original function, so that the determination of those maximums provides an estimate of the positions of the targets.

With the aim to reduce the complexity of the method, the RBFs will be distributed on a predefined grid, so it will only be necessary to calculate the width and weight associated. As the RBFs are functions that only take significant values around of its center, the weight associated is related to the value of the function to interpolate in their environment, simulating a "virtual sensor" located in the same position.

The deployment of RBFs on the grid has the disadvantage that their number increases exponentially when increase the size of the control region. To have controlled the number of RBFs involved in the interpolation, in this PFC we use the optimization method called LASSO. This method can optimize a vector of parameters (the weights of the RBFs) so that the cost function is minimized, minimizing the number of nonzero elements in this vector.

This PFC was applied RBF + Lasso method for localization issues. Through several simulations, we've established the method parameters of RBF + Lasso (width and number of functions RBFs active) and we've obtained quality measures of estimated positions.

Keywords: Radial Basis Function, RBF, LASSO, Multitargets, Localization, Rescue, Regression.

Índice general

1. INTRODUCCIÓN Y OBJETIVOS	16
1.1 Introducción	16
1.2 Error en el modelo de observación.....	17
1.3 Escenarios aplicables.....	18
1.3.1 <i>Técnicas de Rescate</i>	19
1.3.1.1 Rescate en alta montaña (Medio Terrestre).....	19
1.3.1.2 Recuperación Caja Negra de avión (Medio Aéreo)	19
1.3.1.3 Localización Submarina (Medio Marítimo).....	19
1.3.2 <i>Localización Francotirador</i>	20
1.3.3 <i>Localización de Contaminantes</i>	20
1.4 Organización del Proyecto	20
2. DESCRIPCIÓN DEL PROBLEMA Y ESCENARIO	23
2.1 Localización con redes de sensores.....	23
2.2 Tipos de medidas y sensores	24
2.2.1 <i>Sensores de medición de distancias</i>	24
2.2.2 <i>Técnicas de estimación de distancias</i>	24
2.2.2.1 Tiempo de llegada (ToA)	24
2.2.2.2 Diferencia de tiempos de llegada (TDoA)	25
2.2.2.3 Potencia de la señal recibida (RSS).....	25
2.2.3 <i>Técnicas de localización existentes</i>	26
2.2.3.1 Trilateración	26
2.2.3.2 Multilateración	27
2.2.3.3 Localización mediante estimación por Least Squares.....	27
2.3 Limitaciones de las técnicas de localización.....	29
2.4 Descripción del escenario “tipo”	30
2.4.1 <i>Sensores sin visión directa</i>	30
2.5 Redes de sensores e interpolación	32
3. DESCRIPCIÓN DE LA SOLUCIÓN	35
3.1 Introducción	35
3.2 Tipos de interpolación.....	37
3.2.1 <i>Globales</i>	37

3.2.1.1 Polinomiales	37
3.2.2 Locales	38
3.2.2.1 Lineal a trozos (piecewise linear interpolation)	38
3.2.2.2 Bi-lineal	39
3.2.2.3 Spline	40
3.2.2.4 Funciones de Base Radial (RBFs)	40
3.3 Interpolación con RBFs	41
3.3.1 Tipos de RBFs	41
3.3.2 Optimización de parámetros	42
3.3.2.1 K-means	42
3.4 Solución propuesta	43
3.4.1 Parámetros de la red y optimización	44
3.4.1.1 Centros de las RBF	44
3.4.1.2 Anchos de las RBFs (σ)	45
3.4.1.3 Pesos de las RBFs (LASSO)	45
4. RESULTADOS EXPERIMENTALES	49
4.1 Elección de parámetros	49
4.1.1 Optimización del parámetro sigma (σ)	49
4.1.2 Optimización del número de sensores de la red	51
4.1.3 Optimización de LASSO (parámetro λ)	52
4.1.4 Optimización de la red de RBF	52
4.1.5 Comparación con localización convencional Least Squares	53
5. SIMULACIÓN DE RESULTADOS EN ESCENARIO REAL	56
5.1 Introducción	56
5.2 Localización de un blanco	57
5.3 Localización de múltiples blancos	70
6. CONCLUSIONES Y FUTURAS LÍNEAS DE TRABAJO	74
6.1 Conclusiones	74
6.2 Futuras líneas de Trabajo	75
7. PRESUPUESTO	77
7.1 Presupuesto	77

Índice de figuras

Figura 1. Representación de la potencia recibida en un escenario real con tres fuentes de señal.....	17
Figura 2. Propagación de señal según el factor de pérdidas n	18
Figura 3. Sensor de aparcamiento (ToA)	25
Figura 4. Esquema Diferencia RSS	26
Figura 5. Trilateración.....	27
Figura 6. Ejemplo de distribución aleatoria de sensores en 2D	30
Figura 7. Ejemplo de distribución aleatoria de sensores en 3D	31
Figura 8. Ejemplo de escenario real	32
Figura 9. Función interpolada obtenida.....	32
Figura 10. Localización mediante interpolación	36
Figura 11. Ejemplo de Interpolación Polinómica.....	38
Figura 12. Cálculo de la interpolación lineal	39
Figura 13. Ejemplo de Interpolación lineal	39
Figura 14. Comparativa de las diferentes interpolaciones	40
Figura 15. Función Gaussiana	41
Figura 16. Función Multicuadrática	41
Figura 17. Función Multicuadrática Inversa	41
Figura 18. Función Spline de placa delgada	41
Figura 19. Distribución de centros de la RBF en la rejilla.....	44
Figura 20. LASSO aplicado a la formación de pesos de RBF.....	46
Figura 21. Variación de RMSE dependiendo del valor de σ para 30 sensores.....	50
Figura 22. Variación de RMSE dependiendo del valor de σ para 50 sensores.....	50
Figura 23. RMSE dependiendo del número de sensores.....	51
Figura 24. Número de RBF activas según el parámetro λ seleccionado	52
Figura 25. Evolución de RMSE con respecto al parámetro λ	53
Figura 26. Comparación entre LS y el método propuesto.....	54
Figura 27. Distribución de sensores	57
Figura 28. Software SPLAT!	58

Figura 29. Interfaz de usuario de la herramienta SPLAT!	58
Figura 30. Mapa y situación del terreno descargado.....	59
Figura 31. Configuración de parámetros en la herramienta SPLAT!	60
Figura 32. Distribución de potencia - Simulación 1	61
Figura 33. Distribución de potencia - Simulación 2	62
Figura 34. Distribución de potencia - Simulación 3	62
Figura 35. Distribución de potencia - Simulación 4	63
Figura 36. Mapa de sensores distribuidos en el terreno	64
Figura 37. Mapa de sensores distribuidos en el terreno en 3D	64
Figura 38. Mapa de sensores activos e inactivos (un blanco)	66
Figura 39. Posicionamiento de la red de RBFs	67
Figura 40. Simulación para localización de un blanco (eje xy)	68
Figura 41. Simulación para la localización de un blanco (eje xz).....	69
Figura 42. Comparativa de nuestro algoritmo con localización usando LS	70
Figura 43. Mapa de sensores activos e inactivos (múltiples blancos).....	71
Figura 44. Simulación para la localización de más de un blanco (eje xy)	72
Figura 45. Simulación para la localización de más de un blanco en 3D.....	72

Índice de tablas

Tabla 1. Equivalencia dB con escala de colores	61
--	----

Capítulo 1

Introducción y objetivos

1.1 Introducción

La localización de fuentes de señales juega un rol muy importante en diversos problemas de ingeniería. Habitualmente, la localización se realizará partiendo de diferentes observaciones recogidas por una serie de sensores de una determinada magnitud física generada por las fuentes de señal (o blancos). Estas observaciones junto con el algoritmo desarrollado, nos permitirán averiguar la posición de cada una de ellas.

En este proyecto se va a enfocar el problema de localización cuando el modelo de las observaciones no es exacto, es incompleto o simplemente se desconoce. Las hipótesis de partida son, en primer lugar, suponer que la función que describe la variación de la magnitud observada presenta máximos (o mínimos) locales justamente en las posiciones de las fuentes, y, en segundo lugar, suponer que dicha función tiene un comportamiento “suave”.




Figura 1. Representación de la potencia recibida en un escenario real con tres fuentes de señal.

A modo de ejemplo de lo anterior, en la Figura 1 se muestra el nivel de señal (radio) recibida en un escenario real cuando hay tres fuentes de señal. Como se puede observar, los máximos (locales) de la función (marcados con \square) coinciden con las posiciones de las fuentes (*).

Partiendo de estas hipótesis y de las medidas proporcionadas por un determinado número de sensores, el algoritmo propuesto en este PFC interpola la función sin suponer un modelo específico y realiza una búsqueda de sus máximos (o mínimos) locales que, verosímilmente, coincidirán en posición con los de los objetos a localizar.

1.2 Error en el modelo de observación

Para entender los efectos causados por un conocimiento incompleto o erróneo del modelo de propagación [2] en un problema de localización, a continuación se presenta un ejemplo basado en el nivel de potencia de señal recibida (RSS, Received Signal Strength).

En ciertos escenarios, la potencia recibida a una distancia $d > d_0$ puede expresarse como:

$$P_R(d)[W] = P_R(d_0)[W] \left(\frac{d_0}{d}\right)^n \quad (1)$$

Donde $P_R(d_0)$ es la potencia recibida a la distancia d_0 (también denominada distancia de referencia; típicamente en escenarios “outdoor”, $d_0 = 1 \text{ Km}$) y n es el factor de pérdidas (en espacio libre $n=2$). Si empleamos unidades logarítmicas, la expresión (1) se transforma en:

$$P_R(d)[dBW] = P_R(d_0)[dBW] - 10n \log \left(\frac{d}{d_0}\right) \quad (2)$$

Supongamos que se quiere localizar la distancia a la que se encuentra un transmisor y que se dispone del valor de la potencia recibida a una distancia $d_0 = 1 \text{ Km}$, que como ejemplo, supondremos igual a -55 dBW . Supondremos, además, que se desconoce el factor de pérdidas. Si a una distancia $d > d_0$ se midiese una RSS de -73 dBW , el modelo de espacio libre ($n=2$) determina que el blanco está a una distancia de 7 Km . Sin embargo, si el modelo de propagación real tiene un factor de pérdidas $n=4$ (este factor de pérdidas se corresponde con un escenario de 2 rayos y reflexión especular), estaríamos cometiendo un error de más de 4 km (Figura 2).

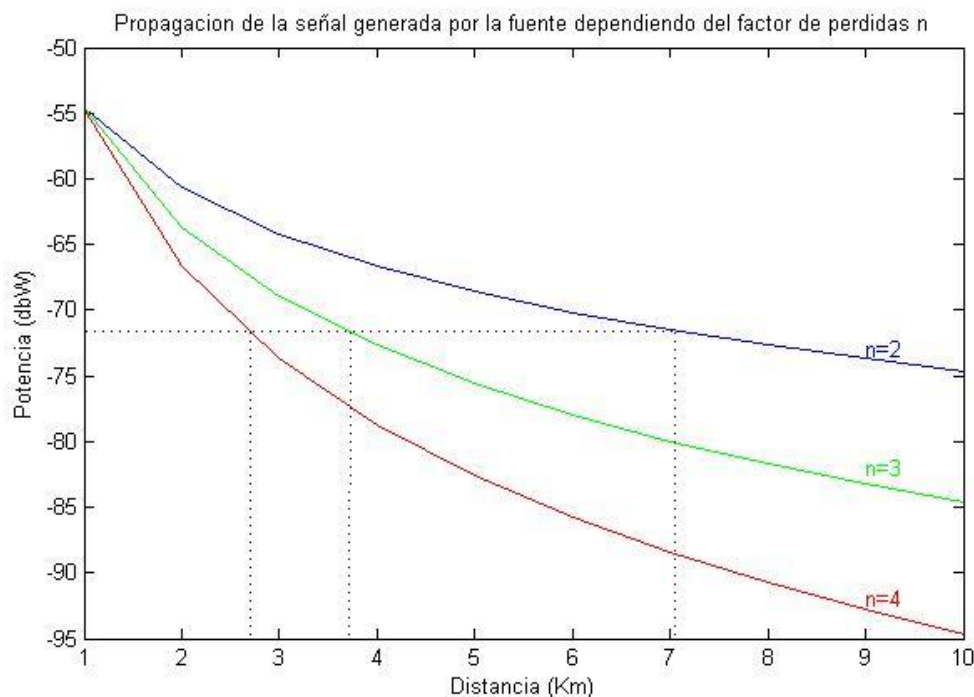


Figura 2. Propagación de señal según el factor de pérdidas n

Este error viene provocado por el desconocimiento de las condiciones de propagación, es decir, se desconoce el factor de pérdidas, n .

Es muy habitual en escenarios de localización, que nos encontremos con esta situación, provocando que la estimación del blanco pueda ser poco precisa.

1.3 Escenarios aplicables

A continuación se detallan posibles escenarios y situaciones donde puede existir un conocimiento incompleto del modelo de las medidas.

1.3.1 Técnicas de Rescate

El poder localizar con exactitud un individuo o un objeto es fundamental e incluso en la mayoría de los casos vital, a la hora de resolver con éxito un rescate o salvamento.

Hay casos donde la localización no es necesaria debido a que el sujeto a rescatar no está oculto y es parcial o completamente visible, pero hay muchos otros casos donde la dificultad del rescate radica en localizar primero al sujeto.

Comúnmente, las llamadas de socorro se suelen realizar mediante radiobalizas de emergencia. Consisten en un aparato transmisor de radio que cuando se activa, envía señales que sirven de ayuda para la localización. Las radiobalizas [3] emiten en la llamada frecuencia de rescate (406 MHz) y pueden ser de tres tipos, dependiendo del medio:

- Medio Marítimo: Radiobaliza con indicador de posición de emergencia (EPIRB).
- Medio Terrestre: Baliza personal de localización (PLB).
- Medio Aéreo: Transmisores de localización de emergencia (ELT).

Algunos ejemplos de escenarios de técnicas de rescate son:

1.3.1.1 Rescate en alta montaña (Medio Terrestre)

Puede ser ocasionado por diferentes circunstancias, por ejemplo por un alud de nieve que deje sepultado a personas o un accidente de un montañero que le deje inmóvil.

En ambos casos, la persona queda incomunicada en la montaña a la espera de ser rescatada.

El poder localizar a la persona lo antes posible juega un papel vital para que el rescate tenga éxito.

1.3.1.2 Recuperación Caja Negra de avión (Medio Aéreo)

Cuando se produce un accidente aéreo, una de las mayores fuentes de datos para investigar las causas del siniestro es la caja negra del propio avión siniestrado.

En numerosas ocasiones, la búsqueda y la localización de la caja negra es algo muy complicado debido a la amplitud de la zona a buscar. En este caso, igual que en el caso anterior, el éxito de la misión está en usar técnicas de localización eficientes para gastar los menos recursos posibles en la búsqueda.

1.3.1.3 Localización Submarina (Medio Marítimo)

En el ámbito marino, la localización también es muy importante, no sólo enfocada al rescate de otros submarinos o barcos sino a la hora de poder detectar mediante sonidos (sonar) qué hay alrededor del buque. Se trata de localización acústica que consiste en emplear los impulsos sonoros para detectar lo que le rodea.

1.3.2 Localización Francotirador

En los últimos años, se ha visto que el enfrentamiento con francotiradores ha sido una amenaza importante. Un francotirador es un soldado de infantería altamente especializado, entrenado para disparar desde una posición oculta y a distancia superior a la de la infantería regular. Sus objetivos suelen ser de alto valor y de oportunidad [1].

En este entorno, incluso con escasos recursos, un único hombre puede causar daños importantes.

Mediante el método que proponemos, la manera de detectar y localizar al francotirador sería desplegando una red de sensores acústicos, en el cual cada sensor percibe el sonido de la eyección de la bala desde el rifle, calcula el tiempo de llegada de dicho sonido y lo envía a un nodo central que obtiene la posición. Teniendo en cuenta que cuanto menor sea el tiempo de llegada, más cerca estará el blanco, si utilizamos el método RBF+Lasso propuesto se podría estimar la posición del francotirador.

1.3.1 Localización de Contaminantes

Otro escenario donde se puede aplicar nuestro sistema de localización con sensores es en el medioambiente.

Consistiría en el despliegue de sensores capaces de evaluar las medidas tanto meteorológicas como contaminantes de las nubes, con la posibilidad de detectar si alguno de los contaminantes superara un cierto umbral. En caso de ser superado, se podría generar alertas para avisar de que los niveles de esos contaminantes pueden ser nocivos para el ser humano e indicar el foco o el punto de la nube donde la contaminación es más densa.

1.4 Organización del Proyecto

La memoria de este PFC se ha estructurado del siguiente modo:

Capítulo 1. Introducción

En este capítulo, se explicará en qué consiste este proyecto así como los posibles escenarios en los que se puede aplicar.

También detallaremos la estructura del proyecto.

Capítulo 2. Descripción del Problema y Escenario

En él, se explicará el escenario en el que se ha desarrollado este proyecto. Se explicarán los elementos utilizados y los distintos tipos de sensores de distancia existentes.

Se mencionarán las posibles limitaciones que existen con la localización basada en modelo para la observación.

Capítulo 3. Descripción de la solución

En este capítulo, se explica el algoritmo que se ha utilizado para estimar la localización de la fuente.

Se explicará el modelo de interpolación realizada al igual que el método de optimización de parámetros elegido para reducir el error.

Capítulo 4. Resultados Experimentales

En él, se argumentará los parámetros elegidos en nuestro algoritmo que optimizan los resultados.

Capítulo 5. Simulación de resultados en escenario real

En este capítulo, se exponen los resultados que se han obtenido al aplicar nuestro algoritmo de localización en escenarios reales, tanto para una o más fuentes de señal.

Capítulo 6. Conclusiones y Líneas Futuras

En este capítulo, se explicarán las conclusiones que se han obtenido tras analizar los resultados de las simulaciones. También se expondrán futuras líneas de trabajo para mejorar las posibles limitaciones de nuestro algoritmo.

Capítulo 7. Presupuesto

En este capítulo, se mostrará el presupuesto para el sistema de localización desarrollado. En él se detallarán todos los costes asociados.

Referencias

Se indicará la bibliografía que se ha utilizado en la elaboración de este proyecto.

Capítulo 2

Descripción del problema y escenario

2.1 Localización con redes de sensores

Una red de sensores (Sensor Network) es un sistema compuesto por numerosos dispositivos (sensores), que están distribuidos espacialmente y se utilizan para controlar diversas condiciones ambientales, como por ejemplo, la potencia, la temperatura, el sonido, la vibración, la presión, el movimiento o los contaminantes.

En los últimos años, las redes de sensores gozan de un gran interés, tanto por parte de la comunidad científica como del sector industrial. Los avances en las comunicaciones inalámbricas y en la electrónica, han hecho viable el desarrollo de redes de sensores multifuncionales de bajo coste y bajo consumo.

Estos pequeños sensores son capaces de medir parámetros físicos, procesar información y comunicarla a otros dispositivos, generalmente, a través de un canal de radio-frecuencia (RF).

Los campos de aplicación de las redes de sensores para problemas de localización son innumerables. Algunas de estas aplicaciones son las descritas en el [capítulo 1](#): técnicas de rescate, localización y detección de contaminantes, monitorización sanitaria y médica, etc.

2.2 Tipos de medidas y sensores

Las redes de sensores, con su capacidad de medir parámetros físicos, permiten la detección de eventos de cualquier tipo, proporcionando así información al usuario sobre cuándo o dónde se está produciendo el evento que interesa monitorizar.

Este proyecto se va a centrar en la localización de blancos, por lo que los sensores que utilizaremos serán capaces de darnos información que dependerá de las posiciones relativas entre el blanco o blancos a detectar con ellos mismos.

Para llevar a cabo la localización, supondremos que el objetivo a localizar emite una señal de cualquier tipo (señal de potencia, pulso de tiempo, etc.) que será captada por los sensores que componen la red y posteriormente será procesada [4].

2.2.1 Sensores de medición de distancias

Debido a la multitud de sensores existentes en la actualidad, realizar una clasificación única de ellos es muy complicado. Pueden clasificarse según el principio de funcionamiento, según el tipo de señal eléctrica que generan, según el rango de valores que proporcionan, según el nivel de integración, según el tipo de variable física que miden, etc.

En nuestro problema de localización, nos centraremos en los sensores que se utilizan para la medición de distancias entre dos puntos.

Dependiendo de qué técnicas de estimación de distancia se utilice, los sensores podrán ser sensores de potencia, sensores de ultrasonido, etc.

2.2.2 Técnicas de estimación de distancias

Las principales técnicas de estimación de distancia se muestran a continuación.

2.2.2.1 Tiempo de llegada (ToA)

La medición del ToA de una señal es un método robusto para estimar distancias. Esta técnica mide el tiempo que tarda una señal en viajar de un nodo a otro a una velocidad conocida.

Un sistema muy usado en la actualidad que usa esta técnica para medir distancias, son los sensores de aparcamientos de los vehículos. Se basan en ultrasonidos (frecuencias superiores a 20 KHz)

Cada sensor de aparcamiento emite un pulso de ultrasonido que rebota sobre un determinado objeto y la reflexión de ese pulso es detectada por el receptor del sensor (Figura 3).




Figura 3. Sensor de aparcamiento (ToA)

De tal forma que, midiendo el tiempo que transcurre entre la emisión del sonido y la percepción del eco, se puede establecer la distancia a la que se encuentra el obstáculo que ha producido la reflexión de la onda sonora, mediante la fórmula:

$$d = \frac{1}{2} V \cdot t \quad (3)$$

Donde V es la velocidad del sonido en el aire y t es el tiempo transcurrido entre la emisión y recepción del pulso.

2.2.2.2 Diferencia de tiempos de llegada (TDoA)

Aunque la técnica anterior es muy precisa, se necesita una estricta sincronización entre los sensores que intervienen en el proceso.

Para solucionar este problema, existen otros sistemas que utilizan una técnica llamada diferencia de tiempos de llegada (TDoA) que emplea dos señales, generalmente una señal radio y otra acústica. Estos sistemas utilizan la diferencia de tiempos de llegadas de ambas señales y la velocidad de propagación de cada una de ellas para estimar la distancia.


También se podría resolver el problema de la sincronización calculando las diferencias de tiempos de llegada respecto a un sensor de referencia.

2.2.2.3 Potencia de la señal recibida (RSS)

Esta técnica utiliza las propiedades de atenuación de la señal de radio para modelar la distancia entre dos nodos como una función del indicador de la potencia de la señal recibida (RSSI – Received Signal Strength Indicator). Los sistemas que se basan en el RSSI como parámetro de entrada, tienden a ser muy precisos en distancias cortas si se emplea un extenso post-procesamiento, pero pueden llegar a ser muy imprecisos cuando la distancia aumenta debido a problemas como el desvanecimiento de múltiples trayectorias (multipath fading) y el shadowing (bloqueos)

A demás de estas pérdidas, en las redes con múltiples sensores, las condiciones de propagación pueden variar de sensor a sensor.

Cabe destacar que para calcular la Potencia recibida existe una modo en el cual no es necesario conocer la Potencia transmitida (P_{TX}), tal y como se muestra en la siguiente figura.



Siendo d_j y d_k la distancia del sensor j y k se puede obviar la P_{TX} , de tal forma que:

$$\Delta_{jk} = 10n \log_{10} \left(\frac{d_k}{d_j} \right)$$

Figura 4. Esquema Diferencia RSS

2.2.3 Técnicas de localización existentes

Una vez estimadas las distancias entre el blanco a localizar y los sensores de la red, cuyas posiciones son conocidas, se procederá al cálculo de la posición del blanco.

A continuación se muestran varios ejemplos de técnicas de localización basadas en distancias:

2.2.3.1 Trilateración

La técnica de trilateración calcula la posición de un blanco midiendo las distancias desde él hasta varios sensores de referencia. Para calcular la posición de un blanco en dos dimensiones, es necesario conocer como mínimo la distancia desde tres sensores no colineales como se muestra en la Figura 5.




Figura 5. Trilateración

2.2.3.2 Multilateración

Esta técnica consiste en la localización de un blanco por medio del cómputo de la diferencia de tiempo de llegada (TDoA) de la señal emitida por el blanco a tres o más receptores.

2.2.3.3 Localización mediante estimación por Least Squares

El método Least Squares es una técnica para la estimación y/o ajuste de los parámetros desconocidos mediante un modelo de regresión lineal.

Para poder llevar a cabo este método, es necesario encontrar un modelo matemático que aproxime lo “mejor posible” la relación entre las observaciones (medidas), las posiciones de los sensores (que se suponen conocidas) y las posiciones de los blancos (que son las variables a estimar) [5,6,7].

Supondremos un escenario en el que se han desplegado $N + 1$ sensores situados en las posiciones x_{s_i} donde $i = 0, \dots, N$. Dichos sensores realizan medidas de la potencia emitida por una fuente situada en x_T .

Dicha potencia se relaciona con la distancia d_{s_i} por la ecuación:

$$RSS_{s_i} = P_{TX} - 10n \log_{10} (d_{s_i}) \quad (4)$$

Como se puede observar, para obtener el valor de d_{s_i} a partir de la observación de potencia hay que conocer el valor de la potencia transmitida y establecer el valor del parámetro del factor de pérdidas del medio (n).

Para eliminar la potencia transmitida en la ecuación (4), se pueden plantear el problema en función de la diferencia entre las observaciones obtenidas por pares de sensores. Tomando como referencia el sensor 0 (x_{s_0}) que se situará en el origen de

Capítulo 2: Descripción del problema y escenario

coordenadas ($x_{s_0} = 0$), la diferencia entre las distancias estimadas por el sensor i y el sensor 0, \tilde{d}_{s_i} , se puede expresar como:

$$\tilde{d}_{s_i} = \|x_{s_i} - x_T\| - \|x_T\| \quad (5)$$

Donde $\|\cdot\|$ es la norma euclídea e $i = 1, \dots, N$

Siguiendo la formula (5) se puede obtener:

$$\|x_{s_i} - x_T\|^2 = (\tilde{d}_{s_i} + \|x_T\|)^2 \quad (6)$$

Algebraicamente:

$$\tilde{d}_{s_i} \|x_T\| + x_{s_i}^T x_T = \frac{\|x_{s_i}\|^2 - \tilde{d}_{s_i}^2}{2} \quad (7)$$

Si definimos la variable b_{s_i} como:

$$b_{s_i} = \frac{\|x_{s_i}\|^2 - \tilde{d}_{s_i}^2}{2} \quad (8)$$

Se puede llegar a la expresión:

$$\tilde{d}_{s_i} \|x_T\| + x_{s_i}^T x_T = b_{s_i} \quad (9)$$

Por lo que se puede estimar x_T partiendo de la expresión anterior mediante la minimización de los siguientes mínimos cuadrados:

$$c_s = \sum_{i=1}^N (\tilde{d}_{s_i} \|x_T\| + x_{s_i}^T x_T - b_{s_i})^2 \quad (10)$$

De manera matricial se puede expresar como:

Siendo:

$$z(x_T) = \begin{bmatrix} \|x_T\| \\ x_T \end{bmatrix}; \quad \tilde{d}_s = \begin{bmatrix} \tilde{d}_{s_1} \\ \vdots \\ \tilde{d}_{s_N} \end{bmatrix}; \quad (11)$$

$$\phi = \begin{bmatrix} \tilde{d}_{s_1} & x_{s_1}^T \\ \vdots & \vdots \\ \tilde{d}_{s_N} & x_{s_N}^T \end{bmatrix}; \quad b_{s_i} = \begin{bmatrix} b_{s_1} \\ \vdots \\ b_{s_N} \end{bmatrix};$$

Se puede expresar Least Squares como:

$$c_s = \|\phi z(x_T) - b_{s_i}\|^2 \quad (12)$$

Siendo z_i el i -ésimo elemento de z

La estimación LS de z (y por lo tanto de x_T) se obtiene reduciendo al mínimo (11) con respecto a z . Pudiendo expresar del siguiente modo:

$$\tilde{z} = (\phi^T \phi)^{-1} \phi^T b_{s_i} \quad (13)$$

2.3 Limitaciones de las técnicas de localización

El éxito de las técnicas de localización mencionadas anteriormente dependen de lo precisas que hayan sido calculadas las distancias entre los sensores y el blanco.

En el caso de estimar las distancias usando la técnica de potencia de señal recibida (2.2.2.3), el cálculo de estas distancias no será sencillo, ya que intervienen en su obtención las pérdidas de trayecto (Figura 2). Esto provocará que debamos ajustar nuestra técnica de estimación de distancia a un modelo de pérdidas.

El principal problema de estas técnicas de estimación basadas en un modelo matemático para establecer la función de estimación es que si entre la magnitud física que emite la fuente y los receptores no existe un único modelo de propagación (diferente factor de pérdidas, n), el modelo matemático al que se aproxime puede no ser preciso.

Cuando la orografía del entorno de propagación es irregular y no se puede regir por un modelo matemático, utilizar esta técnica puede provocar situaciones no deseadas, ya que la fuente y los sensores pueden tener bloqueos o no tener visión directa al estar separados por un obstáculo.

Por lo tanto, aunque el sensor esté a corta distancia de la fuente, si existe una barrera entre ambos, el sensor no captará correctamente la señal emitida, provocando que las medidas captadas por el sensor no sean fiables y por consiguiente generarán errores de localización.

2.4 Descripción del escenario “tipo”

El escenario en el que se ha realizado el estudio está ubicado en un entorno abierto (outdoor) cuyo terreno presenta variaciones de altura.

El blanco a localizar estará situado en cualquier posición del escenario de búsqueda. La magnitud física que emitirá dicho blanco será una señal de potencia (RSS).

En la superficie a localizar, se distribuirá un número determinado de sensores de forma aleatoria que serán los encargados de recoger las observaciones de la señal de potencia generada por la fuente y que utilizaremos posteriormente para generar nuestra función de interpolación que nos ayudará a determinar la posición del blanco.

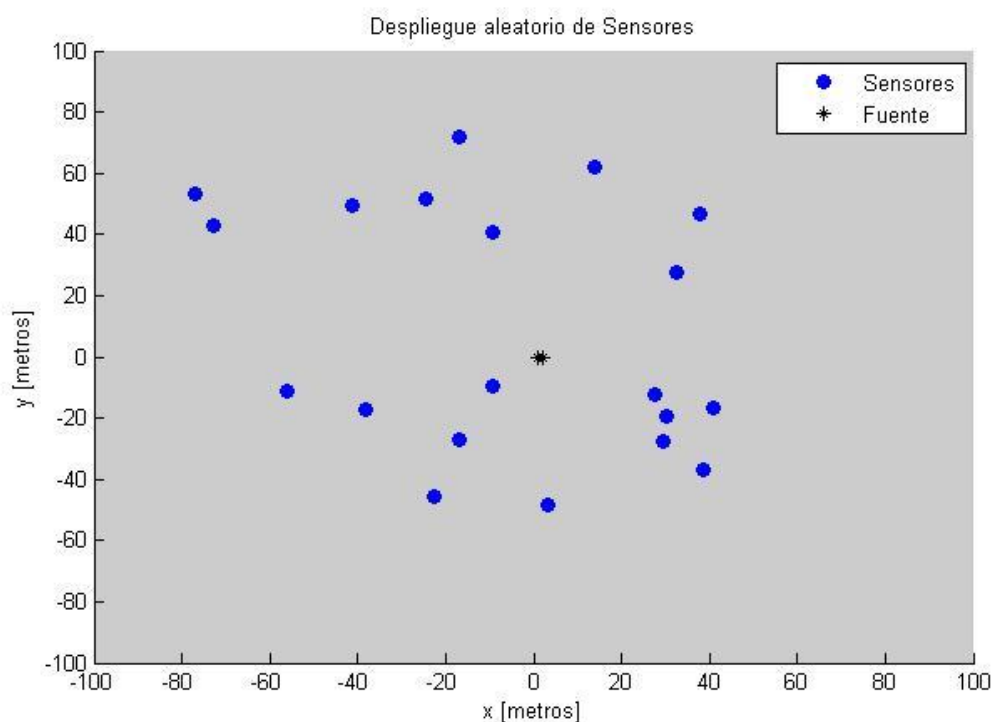


Figura 6. Ejemplo de distribución aleatoria de sensores en 2D

2.4.1 Sensores sin visión directa

Puede darse el caso de que no todos los sensores tengan visión directa con la fuente, por lo tanto, el modelo de propagación para cada sensor será diferente.




Figura 7. Ejemplo de distribución aleatoria de sensores en 3D

En la Figura 7, se muestra un ejemplo de distribución de sensores en un terreno montañoso no uniforme. Como se puede apreciar, existen sensores (color verde) que tienen visión directa con la fuente. Sin embargo, también existen sensores (color azul) que están ubicados en una posición en la cual existe un obstáculo entre la fuente y ellos mismos (no tienen visión directa).

Los sensores que están sufriendo un bloqueo, a pesar de que pueden estar más cercanos a la fuente que otros sensores que tienen visión directa, pueden llegar a recoger un nivel de potencia menor.

Tomando como referencia la Figura 2 del capítulo 1, puede existir un sensor que tenga un modelo de propagación $n = 4$ y que esté sufriendo un bloqueo, lo que provocará que la señal recibida por el sensor, sea aún menor que la que debería recibir según el modelo de pérdidas.

Si este aspecto no se tiene en cuenta puede provocar fallos en la localización.

En este escenario, si empleáramos un método de localización basándonos en un modelo para las observaciones, la función interpolada que obtendríamos no se ajustaría a la realidad, ya que estaríamos utilizando el mismo modelo de propagación para todos los sensores cuando realmente las condiciones de propagación para cada uno de ellos son distintas ya que existen sensores con y sin bloqueo.

Como se ha explicado en el capítulo 1, el algoritmo desarrollado en este PFC interpola la función sin suponer un modelo específico, es decir, no buscamos ajustar nuestras observaciones a un modelo de propagación determinado con una n concreta.

Al no tener que justificar todas las muestras obtenidas con un modelo, conseguimos que en el caso de que existan sensores que están sufriendo bloqueo no provoquen errores en la función de interpolación y, por lo tanto, en la localización.

2.5 Redes de sensores e interpolación

En cierta forma, se puede considerar que los sensores de una red muestrean la función que describe la variación de la magnitud física.




Figura 8. Ejemplo de escenario real

Como se puede comprobar en la Figura 8, los sensores más cercanos a la fuente reciben mayor nivel de potencia que los sensores más alejados de ésta.

Lo que se propone en este proyecto, es interpolar la función a partir de los valores obtenidos por los sensores (muestras), con el objetivo de encontrar el máximo que, como se ha comentado, coincidirá con la posición de la fuente de señal.




Figura 9. Función interpolada obtenida

La selección entre un máximo o un mínimo de la función interpolada depende del tipo de señal generada por la fuente. Por ejemplo, cuando la fuente emite una señal de potencia (RSS), donde la medida disminuye a medida que el sensor está más alejado de la fuente, el máximo de la función interpolada nos indicará la ubicación del blanco. Por el contrario, la ubicación del blanco se indicará con un mínimo de la función interpolada cuando la señal generada por la fuente sean pulsos de tiempo (ToA), para la cual la medición aumenta a medida que el sensor está más alejado de la fuente.

Obviamente, para cualquier caso, la dificultad estará en generar una interpolación adecuada para los objetivos del problema.

Capítulo 3

Descripción de la solución

3.1 Introducción

Como se ha mencionado en el capítulo anterior, en este proyecto se llevará a cabo la tarea de localización como un problema de interpolación espacial [8,9].

La interpolación consiste en el proceso de estimar valores desconocidos para ubicaciones específicas utilizando observaciones conocidas de otros puntos.

En nuestro caso, un conjunto de sensores, \mathbf{x}_{s_i} ,

$$\mathbf{x}_{s_i} = [x_{s_i}, y_{s_i}]^T, i = 1, \dots, N$$

Donde recogerán diferentes observaciones z_i de la función generada por la fuente, obteniendo los pares:

$$\{z_i, \mathbf{x}_{s_i}\}_{i=1}^N$$

Y seremos capaces de crear una función interpolada, \hat{z} que consiga recrear los máximos locales en la misma posición que en donde los tiene la función original que emite la fuente, obteniendo así su ubicación, \hat{x} .

$$\hat{x} = \arg \max_{x_p} \{\hat{z}(x_p)\} \quad (14)$$

De modo gráfico, un ejemplo del método de localización propuesto se ilustra en la siguiente figura:




Figura 10. Localización mediante interpolación

En esta figura, se muestra un transmisor o antena que emite una señal. Los sensores desplegados en la región son capaces de detectar el transmisor dependiendo de sus posiciones.

Por ejemplo, los sensores situados al otro lado de la elevación, marcados con líneas azules, recibirán una señal muy débil y por lo tanto no serán capaces de detectar la presencia del transmisor. Por otro lado, los sensores situados en la zona plana, marcados con líneas verdes, recibirán un alto nivel de señal, lo que les permitirá la detección del transmisor.

Por lo tanto, las medidas adoptadas por los últimos sensores permiten la reconstrucción de la señal medida (que se muestra en la parte superior de la figura).

Finalmente, se puede observar que el máximo de la función de interpolación coincide con el punto donde está situado el transmisor, logrando así el objetivo propuesto que es localizar su posición.

3.2 Tipos de interpolación

Existen dos tipos fundamentales en los que se pueden dividir los diferentes métodos de interpolación: globales y locales.

Su principal diferencia consiste en que los métodos globales utilizan toda la muestra para estimar el valor en cada nuevo punto, mientras que los métodos locales utilizan sólo los puntos de muestreo más cercanos. A continuación, se describe cada método.

3.2.1 Globales

Los interpoladores globales son muy útiles para establecer las tendencias generales de datos, pero el potencial que tiene para predecir variaciones locales es muy pobre, así como también es muy sensible a los valores atípicos. Un ejemplo de interpolador global es el siguiente:

3.2.1.1 Polinomiales

Es la interpolación de un determinado conjunto de datos por un polinomio.

La interpolación polinómica es un método usado para conocer, de un modo aproximado, los valores que toma cierta función de la cual sólo se conoce su imagen en un número finito de muestras.

El objetivo será hallar un polinomio que cumpla lo antes mencionado y que permita hallar aproximaciones de otros valores desconocidos para la función con la mayor precisión posible.

Para obtener dicho polinomio interpolador existen diferentes métodos posibles:

- Planteando directamente un sistema de ecuaciones lineales de la función a interpolar, la cual tendrá una única solución.
- Utilizando los polinomios de la Lagrange, los cuales permiten obtener una expresión explícita del polinomio de interpolación.
- Utilizando la forma de Newton del polinomio de interpolación, la cual es más fácil de obtener que los métodos anteriores y sobre todo se puede actualizar fácilmente si se añaden nuevos nodos de interpolación.

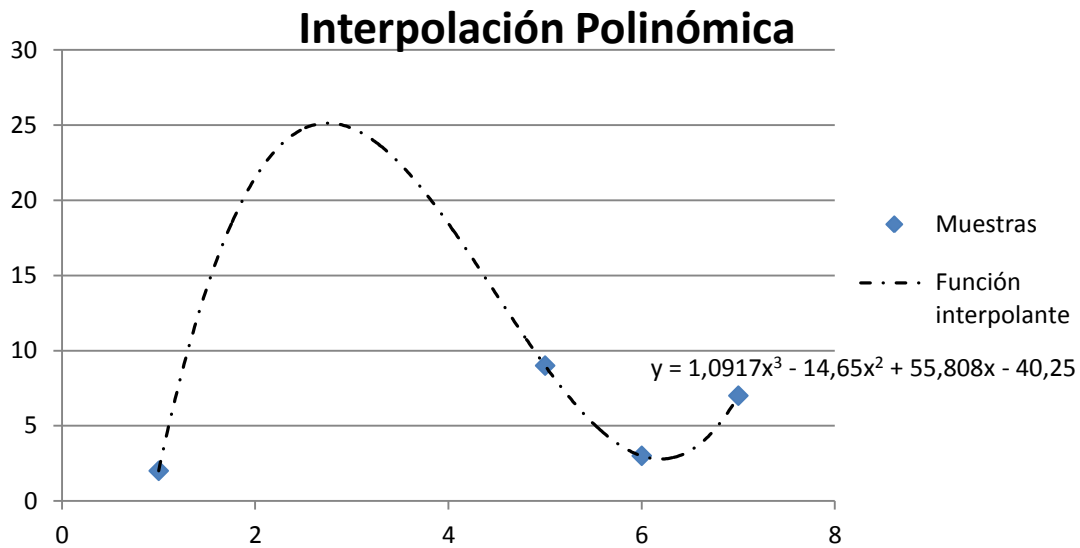


Figura 11. Ejemplo de Interpolación Polinómica

No resulta recomendable utilizar polinomios de grado mayor que tres ya que, a pesar de un ajuste cada vez mejor, se hacen cada vez más sensibles a los valores extremos con lo que cualquier error en los datos podría generar distorsiones importantes en el resultado final.

Una de las principal desventajas con respecto a al interpolación lineal, es que la modificación de un dato de la muestra afecta a todo el polinomio.

3.2.2 Locales

Los métodos locales se basan en la utilización de los puntos más cercanos al punto de interpolación para estimar la función interpolante. No utilizan toda la muestra, como es el caso del los interpoladores globales.

La utilización de los métodos locales de interpolación radica en la dificultad de calcular el polinomio de interpolación para un número no pequeño de puntos.

Destacar que, cuanto mayor sea el número de puntos, es decir, cuanto más difícil resulte el cálculo del polinomio de interpolación, mayor será la aproximación obtenida mediante los métodos de interpolación locales.

Hay muchos tipos de interpoladores locales, los más importantes se muestran a continuación:

3.2.2.1 Lineal a trozos (piecewise linear interpolation)

Es un método de ajuste de curva lineal con polinomios de grado 1. Esta interpolación es rápida y fácil, pero no es muy precisa.

Para ello, disponemos de pares de datos (x_{k+1}, y_{k+1}) y (x_k, y_k) con los que obtendremos un tercer punto interpolado (x, y) a partir de la siguiente formula:

$$y = y_k + (x - x_k) \frac{y_{k+1} - y_k}{x_{k+1} - x_k} \quad (15)$$

Gráficamente:




Figura 12. Cálculo de la interpolación lineal

Utilizando los mismos datos que en el ejemplo de la interpolación polinómica, la función interpolada sería la siguiente:

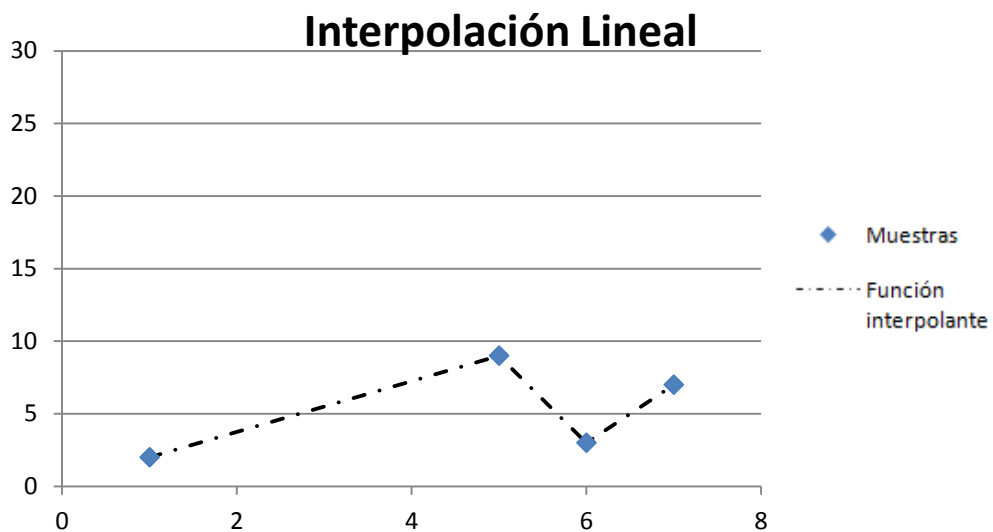


Figura 13. Ejemplo de Interpolación lineal

3.2.2.2 Bi-lineal

Es la extensión de la interpolación lineal para interpolar funciones de dos variables en una cuadrícula regular de dos dimensiones.

Consiste en realizar la interpolación lineal primero en una dirección y a continuación, en la otra. Si bien cada paso es lineal en los valores muestreados y en la posición, la interpolación en su conjunto no es lineal sino cuadrática.

3.2.2.3 Spline

Cuando el número de datos de interpolación es grande, la interpolación polinómica no suele ser muy adecuada. Una alternativa para subsanar este inconveniente es utilizar funciones polinómicas a trozos llamadas splines.

Una función spline está formada por varios polinomios, cada uno definido sobre un subintervalo, que se unen entre sí obedeciendo a ciertas condiciones de continuidad.

A continuación, se muestra una comparativa de las interpolaciones mencionadas:

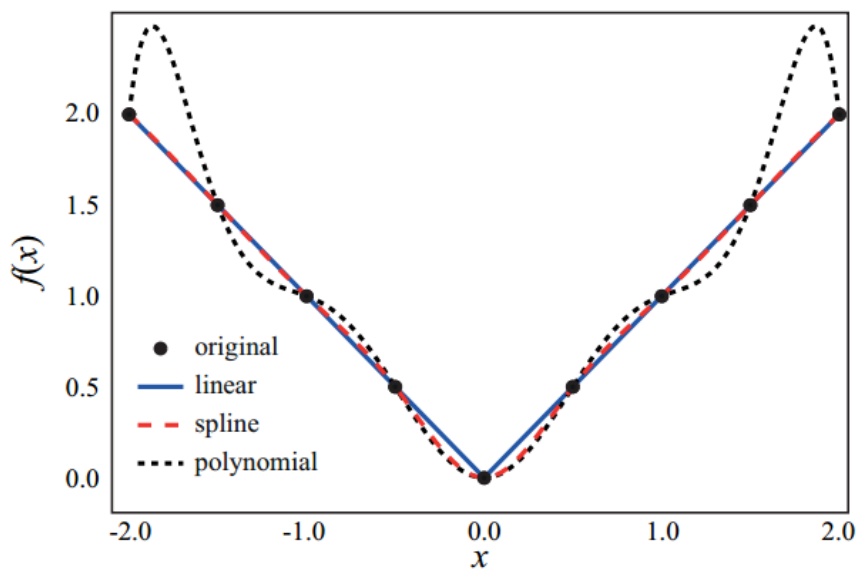


Figura 14. Comparativa de las diferentes interpolaciones

3.2.2.4 Funciones de Base Radial (RBFs)

Las RBFs son capaces de construir una función interpolante partiendo de combinaciones lineales de ellas mismas.

Para que la función interpolante sea lo bastante precisa es imprescindible un buen ajuste de los parámetros de dichas RBFs (la posición, el ancho y los pesos).

En el apartado siguiente, se entra en detalle en este tipo de interpoladores debido a que serán los que utilizemos en nuestra solución.

3.3 Interpolación con RBFs

3.3.1 Tipos de RBFs

Las principales funciones de base radial son las siguientes:

- Función Gaussiana: $\phi(r) = e^{-\frac{r^2}{2\sigma^2}}$




Figura 15. Función Gaussiana

- Función Multicuadrática: $\phi(r) = \sqrt{\sigma^2 + r^2}$




Figura 16. Función Multicuadrática

- Función Multicuadrática Inversa: $\phi(r) = \frac{1}{\sqrt{\sigma^2 + r^2}}$




Figura 17. Función Multicuadrática Inversa

- Función Spline poliarmónico: $\phi(r) = r^k \ln|r|$, $k = 2, 4, 6, \dots$
 $\phi(r) = r^k$, $1, 3, 5, \dots$
 - Función Spline de placa delgada ($k=2$): $\phi(r) = r^2 \ln(r)$




Figura 18. Función Spline de placa delgada

En todos los casos siendo $r = \|x - c\|$

3.3.2 Optimización de parámetros

La optimización del centro, el ancho y los pesos de cada RBF es la parte más delicada e importante para poder obtener una función interpolante lo más precisa posible.

La optimización de los centros de las RBFs es la parte más compleja del proceso. Existen soluciones heurísticas en las que se emplean algoritmos de clasificación. Uno de los algoritmos más usados es el K-means [12].

3.3.2.1 K-means

Dicho algoritmo divide el espacio de muestras en "K" clases o regiones. El representante de cada una de estas clases, "C_i", será el centro. Dichos centros se determinan con el objetivo de minimizar las distancias euclídeas entre las muestras y el centro más cercano.

Dado el número de clases "K", el conjunto de muestras y los centros de las clases, los pasos para la aplicación del algoritmo son los siguientes:

1. Se inicializan aleatoriamente los centros de los "K" clusters.
2. Se asignan "N_i" muestras a cada clúster "i".
3. Se calcula la nueva posición de los centros como la media de todos los patrones que pertenecen al clúster.
4. Se repiten los pasos 2 y 3 hasta que las nuevas posiciones de los centros no se modifiquen respecto a su posición anterior.

A pesar de ser un método fácil de implementar y que suele converger en pocas iteraciones hacia un mínimo local, tiene un gran inconveniente como es su dependencia de los valores iniciales asignados a cada centro.

Respecto a la optimización de la amplitud (ancho de la RBF) también existen números métodos para su obtención.

Estos métodos determinan la amplitud de la RBF basándose en la minimización del error cuadrático medio que se explicará en este capítulo.

Para calcular los pesos, el objetivo es minimizar las diferencias entre la función interpolada y la función original. Como la función interpolada depende linealmente de los pesos, se puede utilizar el método de mínimos cuadrados (Least Squares) para su minimización.

Adaptando el método de Least Squares (tratado en el capítulo 2) para la optimización de pesos de las RBFs se puede expresar del siguiente modo:

Se trata de encontrar una función $\hat{z}(x)$ que sea combinación lineal de las funciones de base radial (RBF), de modo que $\hat{z}(x)$ se aproxime a la función real, quedando la expresión como:

$$\hat{z}(\mathbf{x}_p) = \sum_{k=1}^I \omega_k \phi(\mathbf{x}_{s_i}, c_k) \quad (16)$$

Donde:

ω_i Son los pesos a optimizar.

$\phi(\mathbf{x}_{s_i}, c_k)$ Son las funciones RBF con los diferentes centros.

Trataremos de hallar los k coeficientes ω_k que hagan que la función aproximante $\hat{z}(\mathbf{x}_p)$ dé la mejor aproximación para las observaciones conocidas, minimizando el error cuadrático medio.

De manera matricial el modelo se puede expresar como:

$$Z = \phi \omega \quad (17)$$

Con:

$$Z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix}, \quad \phi = \begin{bmatrix} \phi(\mathbf{x}_{s_1}, c_1) & \dots & \phi(\mathbf{x}_{s_N}, c_1) \\ \vdots & \ddots & \vdots \\ \phi(\mathbf{x}_{s_1}, c_k) & \dots & \phi(\mathbf{x}_{s_N}, c_k) \end{bmatrix}, \quad \omega = \begin{bmatrix} \omega_1 \\ \omega_2 \\ \vdots \\ \omega_k \end{bmatrix} \quad (18)$$

Donde

Z es el vector que contiene la medición en los puntos de referencia.

$\phi(\mathbf{x}_{s_i}, c_k)$ Es una matriz de RBF de dimensiones $k \times n$.

ω Es un vector de dimensión $k \times 1$ de coeficientes de regresión.

De tal modo, que la ecuación para encontrar la solución de mínimos cuadrados del vector de pesos ω será:

$$\omega = (\phi^T \phi)^{-1} \phi^T Z \quad (19)$$

3.4 Solución propuesta

Para realizar la interpolación en nuestro algoritmo, utilizaremos RBFs de tipo Gaussiano que se distribuirán sobre una rejilla predefinida, por lo que será necesario calcular el número, la posición, el ancho y el peso asociado de cada RBFs.

El comportamiento de la interpolación dependerá de estos parámetros, por lo que será necesario optimizarlos de forma que, por un lado, se obtenga una buena calidad en la aproximación de los valores observados, y por otro lado, nos aseguremos de que la función interpolada tenga un máximo lo más cerca posible al máximo de la función real.

El problema de localización puede ser explicado matemáticamente de la siguiente forma:

$$\hat{z}(\mathbf{x}_p) = \sum_{i=0}^I \omega_i \phi(\|\mathbf{x}_p - \mathbf{c}_i\|) \quad (20)$$

Donde ω_i son los pesos, I son un conjunto de funciones base, \mathbf{c}_i es el centro de la RBF, \mathbf{x}_p es un punto del área de estudio, ϕ es una función base, en nuestro caso una función gaussiana y \hat{z} es la medida que toma la función interpolada en el punto \mathbf{x}_p

Por lo tanto, si usamos como función base ϕ la función gaussiana, la expresión de la función de interpolación quedaría:

$$\hat{z}(\mathbf{x}_p) = \sum_{i=0}^I \omega_i e^{-\frac{(\|\mathbf{x}_p - \mathbf{c}_i\|)^2}{2\sigma^2}} \quad (21)$$

3.4.1 Parámetros de la red y optimización

3.4.1.1 Centros de las RBF

Con el fin de evitar la complejidad computacional y los posibles errores de la colocación de los centros de las RBF mediante el algoritmo k-means, posicionaremos nuestra red de RBF en una rejilla uniforme.

La distribución será la siguiente:

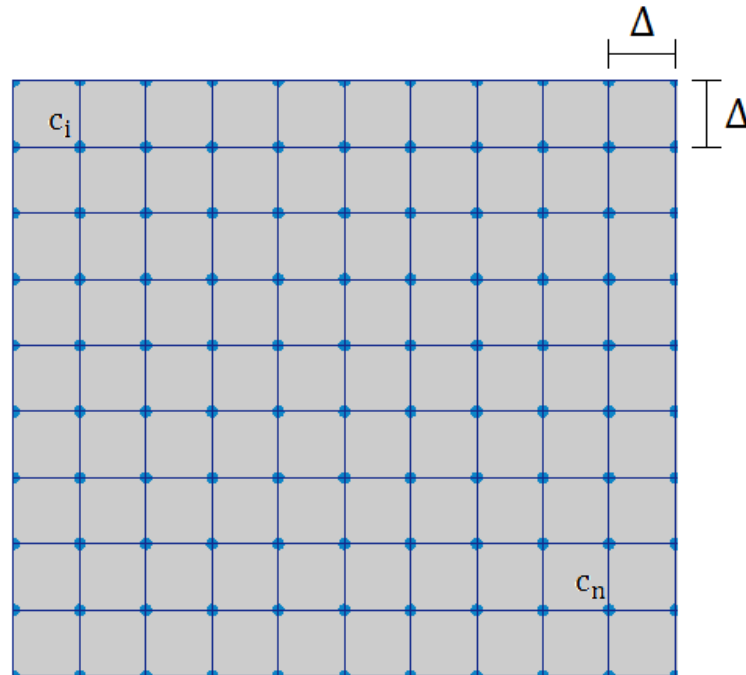


Figura 19. Distribución de centros de la RBF en la rejilla

Siendo c_i la posición de los centros de cada RBF y Δ el ancho de cada celda de la rejilla.

En función de la dimensión de la rejilla, el número de funciones base se incrementará exponencialmente.

Cuanto menor sea el espaciado entre cada RBF (Δ), la interpolación será más precisa pero disminuir este espacio también provocará que el número de RBFs aumente considerablemente y, por consiguiente, el cálculo computacional. Para resolver este problema, se llevará a cabo una etapa de optimización en donde los pesos de cada RBF se reducirán a cero, minimizando así el número de RBFs considerablemente.

3.4.1.2 Anchos de las RBFs (σ)

El ancho de las RBFs será el mismo para todas las RBFs de la red. Para que todas las RBFs puedan cubrir toda la zona de estudio, se establece una relación entre el valor de σ y el ancho de la rejilla utilizada (Δ), de tal modo que:

$$\sigma = \hat{\sigma} * \Delta \quad (22)$$

En el capítulo 4, se mostrarán las simulaciones realizadas para optimizar el valor de $\hat{\sigma}$.

3.4.1.3 Pesos de las RBFs (LASSO)

Una vez que están fijados los centros de las RBFs en la rejilla y se ha seleccionado el ancho óptimo que deben tener para cubrir toda la zona de búsqueda, se procede a calcular los pesos de cada RBF.

Un posible método de optimización podría ser mediante Least Squares, mencionado en el apartado 3.3.2 de este capítulo, pero no es un método muy práctico debido a que requiere la utilización de algoritmos que nos ayuden a escoger el número apropiado de RBF. Además, la interpolación obtenida con este método generalmente conduce a problemas de sobreajuste de la interpolación por lo que no generalizan bien.

Para superar este problema en nuestra solución, se propone calcular el valor de los pesos mediante otro método de regresión, denominado Least Absolute Shrinkage and Selection Operator (LASSO) [10,11].

Este método utiliza la norma L_1 , que minimiza la suma de los errores cuadráticos pero sujeto a una restricción que tiene como cota superior un valor constante l que controla la sumatoria de los valores absolutos de los coeficientes.

Debido a esta restricción, este método tiende a producir coeficientes (en nuestro caso, los pesos) de valor cero, reduciendo así considerablemente el número de RBFs en la interpolación.

La estimación LASSO aplicado a nuestro problema se puede definir de la siguiente manera.

$$\hat{w} = \arg \min_w \sum_{k=1}^N \left(z_k - \omega_0 - \sum_{i=1}^I \omega_i \phi(\|\mathbf{x}_{s_k} - c_i\|) \right)^2 \quad (23)$$

Siendo:

$$\sum_{i=1}^I |\omega_i| \leq l \quad (24)$$

Donde l debe ser mayor o igual a cero, y un parámetro a optimizar ya que controla la cantidad de pesos que se pondrán a cero.

Utilizando LaGrange el problema LASSO también se puede escribir como:

$$\hat{w} = \arg \min_w \frac{1}{2} \sum_{k=1}^N \left(z_k - \omega_0 - \sum_{i=1}^I \omega_i \phi(\|\mathbf{x}_{s_k} - c_i\|) \right)^2 + \lambda \sum_{i=1}^I |\omega_i| \quad (25)$$

Siendo λ el parámetro de ajuste que controla el número de pesos distintos a cero.

Existe una relación 1:1 entre los parámetros l y λ de tal forma que cuando $\lambda = 0$ la solución presentada \hat{w} es el método Least Squares, mientras que cuando λ se incrementa, más pesos se ponen a cero (menos RBFs estarán seleccionadas).

A modo de ejemplo presentamos la siguiente figura:




Figura 20. LASSO aplicado a la formación de pesos de RBF

La Figura 20 representa un ejemplo de LASSO aplicado a la formación de los pesos RBF. En este caso, la función a interpolar es un seno, que se denota por una línea azul en la figura. Al azar se realiza el muestreo de la función, a través del cual se obtienen las muestras para reconstruir la función original (marcado con estrellas rojas). La interpolación se lleva a cabo con RBFs igualmente espaciadas, que se denotan por círculos negros. Una vez aplicado LASSO, solo seguirán activas (los pesos serán distintos de cero) un número determinado de RBFs marcadas como triángulos verdes y serán estas RBFs las que se utilicen para crear la función interpolada.

Se puede observar que la función reconstruida coincide con la real, especialmente en aquellos puntos donde las muestras están disponibles.

Además, se observa que la función interpolada no es capaz de ajustar el valor mínimo real de la función, sin embargo no se considera un inconveniente para nuestro objetivo debido a que algoritmo propuesto sólo requiere el conocimiento de la posición del máximo o mínimo, y no su valor exacto.

Capítulo 4

Resultados Experimentales

4.1 Elección de parámetros

En este capítulo, se explicarán los motivos por el cual se han seleccionado los diferentes parámetros en el método propuesto y se realizará una comparativa con el algoritmo de localización convencional Least Squares.

Para llevar a cabo las simulaciones se ha utilizado el programa MATLAB.

El área donde se han desplegado los sensores es de 200 m^2 . En ella se han distribuido de manera aleatoria $N = 20$ sensores los cuales suponemos que todos ellos toman mediciones de potencia (RSS) con un ruido gaussiano de media nula y varianza 0.5 dB^2 .

El número de RBFs que se han desplegado para realizar la interpolación son 256, por lo que tendremos 16×16 RBFs distribuidas regularmente en toda el área.

Los resultados obtenidos son el promedio de 200 simulaciones [15].

4.1.1 Optimización del parámetro sigma (σ)

Tal y como se indicó en el capítulo anterior, la variable σ de cada RBF está relacionada con el ancho de la rejilla utilizada (Δ), para ello es necesario optimar $\hat{\sigma}$ (22) con el objetivo de que los resultados sean los más precisos posibles.

Capítulo 4: Resultados Experimentales

Las siguientes figuras muestran cómo evoluciona el error cuadrático medio (RMSE) en la estimación, si variamos el valor de $\hat{\sigma}$ de 0.2 a 4

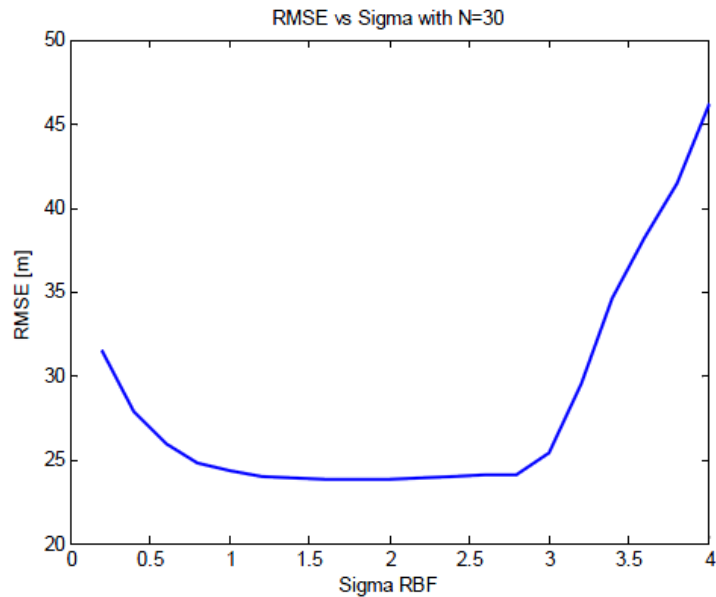


Figura 21. Variación de RMSE dependiendo del valor de $\hat{\sigma}$ para 30 sensores

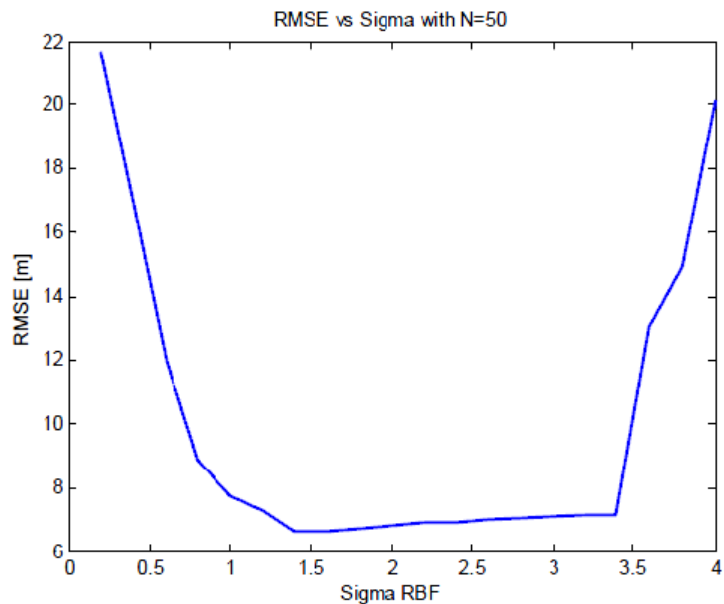


Figura 22. Variación de RMSE dependiendo del valor de $\hat{\sigma}$ para 50 sensores

Como se observa, se obtiene un valor de RMSE alto para pequeños valores de $\hat{\sigma}$ ($\hat{\sigma} < 1,5$). Esto es debido a que las gaussianas son demasiado estrechas y no pueden cubrir uniformemente toda el área a interpolar. Por lo que una interpolación poco precisa, provocará un alto RMSE y por consiguiente, una localización inexacta.

Para valores de $\hat{\sigma}$ mayores de 3 sucede lo contrario. Las RBF son más anchas, lo que provoca solapamiento entre ellas generando también errores de interpolación y por consiguiente, de localización.

Los valores óptimos se sitúan entre $1.5 < \hat{\sigma} < 3$ ya que como se aprecia el RMSE es más pequeño y constante.

Por lo tanto, se puede deducir de ambas simulaciones que el valor óptimo de $\hat{\sigma}$ donde el error cuadrático medio es menor tanto para 30 sensores como para 50 es de dos ($\hat{\sigma} = 2$)

4.1.2 Optimización del número de sensores de la red

La Figura 23 muestra la evolución de la RMSE con respecto al número de sensores desplegados.

Como se puede observar, se obtiene un error de estimación alto cuando se despliegan un número pequeño de sensores.

La explicación de este alto RMSE es porque al desplegar pocos sensores no hay suficientes muestras como para poder realizar una interpolación adecuada provocando así que la localización no sea lo suficientemente precisa.

Se puede visualizar cómo a medida que aumenta el número de sensores, mejora la RMSE. Un despliegue a partir de 20 sensores puede ser suficiente para que nuestro algoritmo funcione con garantía.

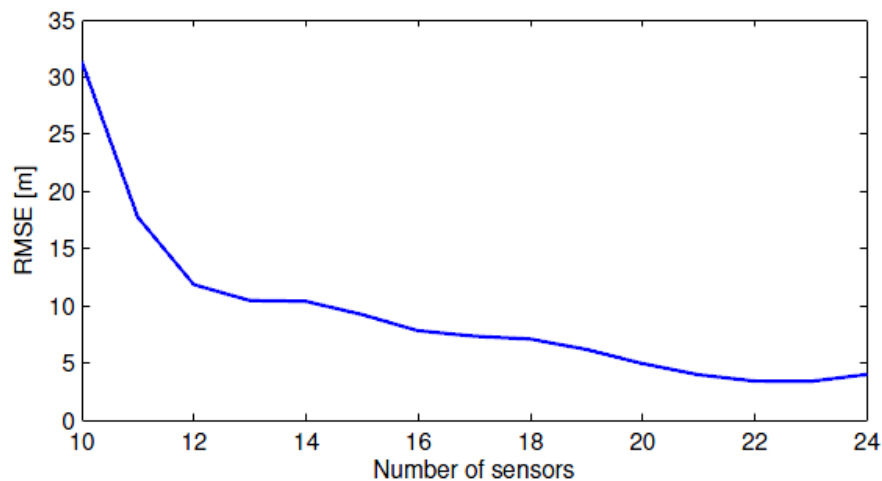


Figura 23. RMSE dependiendo del número de sensores

4.1.3 Optimización de LASSO (parámetro λ)

La Figura 24 presenta el número de RBF activas según el parámetro λ de LASSO que se escoja. Como se mencionó en (25), λ es el parámetro de ajuste que controla el número de pesos distintos a cero.

La simulación se realiza para diferentes tamaños de la red RBF.




Figura 24. Número de RBF activas según el parámetro λ seleccionado

Como se observa para todos los tamaños de la red, el número de RBFs seleccionadas permanece constante para valores bajos de λ . Esto es debido a que el volumen de los datos de entrenamiento es pequeño, el cual conduce a la selección de un subconjunto pequeño de RBFs desde el principio. A medida que aumenta, se puede ver una reducción en el número de RBFs, alcanzando valores muy bajos, hasta aproximadamente 4 RBFs.

4.1.4 Optimización de la red de RBF

La siguiente figura muestra la evolución del RMSE con respecto al parámetro λ de LASSO, para diferentes tamaños de la red RBF.

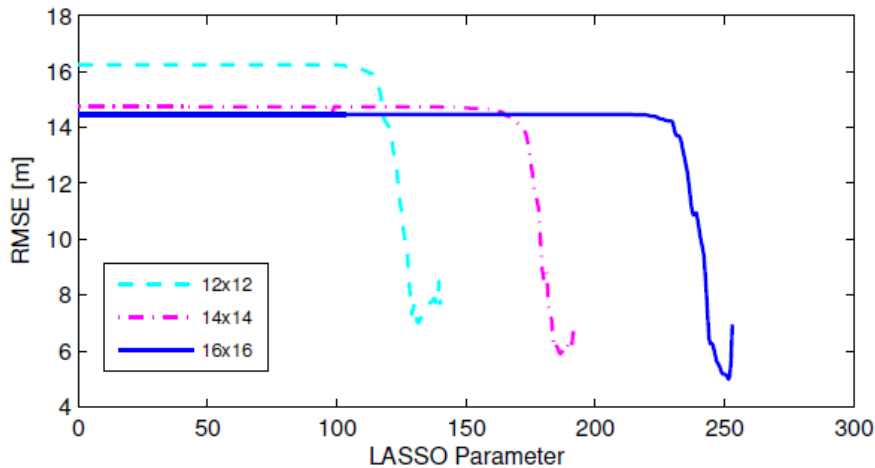


Figura 25. Evolución de RMSE con respecto al parámetro λ

Como se observa para todos los tamaños de la red, el RMSE se mantiene constante para valores bajos de λ . Sin embargo, cuando λ se incrementa, el valor del RMSE se reduce considerablemente hasta un valor inferior de 5 m.

También se puede observar cómo para valores muy altos de λ , ($\lambda > 250$) se produce de nuevo un incremento del RMSE.

Otro dato a destacar es que la red de RBF de 16 x 16 es la que nos proporciona un RMSE menor.

4.1.5 Comparación con localización convencional Least Squares

En la siguiente figura se presenta una comparación, en términos de RMSE, entre el método de localización propuesto y el algoritmo de Least Squares explicado en el apartado 2.2.3.3, el cual se basa en un modelo para llevar a cabo la localización, asumiendo así un conocimiento completo del modelo de observación.

Las simulaciones se han realizado bajo un modelo de RSS con un factor de pérdidas $n=2$ (espacio libre).

La figura muestra la variación del RMSE para ambos métodos, según varía el factor de pérdidas n (Figura 2) .

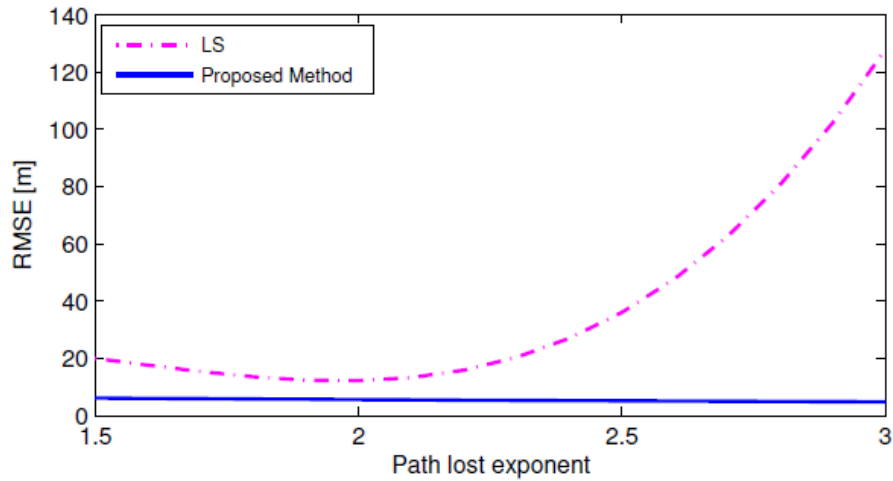


Figura 26. Comparación entre LS y el método propuesto

Como se observa, el RMSE del método propuesto es constante para todos los valores de n .

Esto explica, cómo el método de localización desarrollado es independiente del modelo de observación, por lo que no influye para estimar la posición de destino.

Por otra parte, el error de estimación del método LS aumenta a medida que el factor de pérdidas n , es distinto al factor de pérdidas real en el cual se ha llevado a cabo la simulación ($n=2$).

Capítulo 5

Simulación de resultados en escenario real

5.1 Introducción

En este capítulo se mostrarán los resultados que se han obtenido al simular en un escenario real el modelo de localización que se ha desarrollado de forma teórica en los capítulos anteriores.


Una situación en la que se puede emplear nuestro método desarrollado es en una operación de búsqueda y rescate, más en concreto, rescate en alta montaña (1.3.1.1).

El objetivo es encontrar la ubicación de una fuente la cual está emitiendo una señal radio de emergencia en medio de una región de alta montaña.

Suponemos que la fuente envía, hasta que se agoten sus baterías, una radiobaliza de 5W a una frecuencia de 406 MHz (1.3.1).

5.2 Localización de un blanco

La simulación se llevará a cabo en un escenario real y montañoso, más en concreto en la zona del pirineo aragonés. (Posición del blanco: Latitud: 42.7949N Longitud: 0.3728W)

Para localizar el blanco, se simula el despliegue de 80 sensores radio (marcados con el símbolo ) en el área de búsqueda.

Los sensores tienen un receptor radio sintonizado a la frecuencia de rescate con una sensibilidad de 95 dB.

La posición de los sensores serán generados aleatoriamente siguiendo una distribución gaussiana, tomando como media la posición del blanco.

De este modo, conseguiremos tener los sensores distribuidos en torno al blanco y reducirá significativamente el área de búsqueda.




Figura 27. Distribución de sensores

Una vez desplegada la red de sensores, debemos averiguar la potencia que recibe cada uno de ellos.

Para obtener la potencia que recibe cada sensor, utilizaremos un programa llamado SPLAT! [13] que es una herramienta para el análisis de Propagación de Señales RF, Pérdidas, y Características del Terreno, como indican sus siglas (Signal Propagation, Loss, And Terrain analysis tool SPLAT!).




Figura 28. Software SPLAT!

Esta herramienta es Software Libre y está diseñado para operar en escritorios Unix y basados en Linux y Windows. La redistribución y/o modificación está permitida bajo los términos de la licencia pública general GNU según lo publicado por la Fundación de Software Libre, versión 2.

La interfaz gráfica de dicha herramienta es la siguiente:

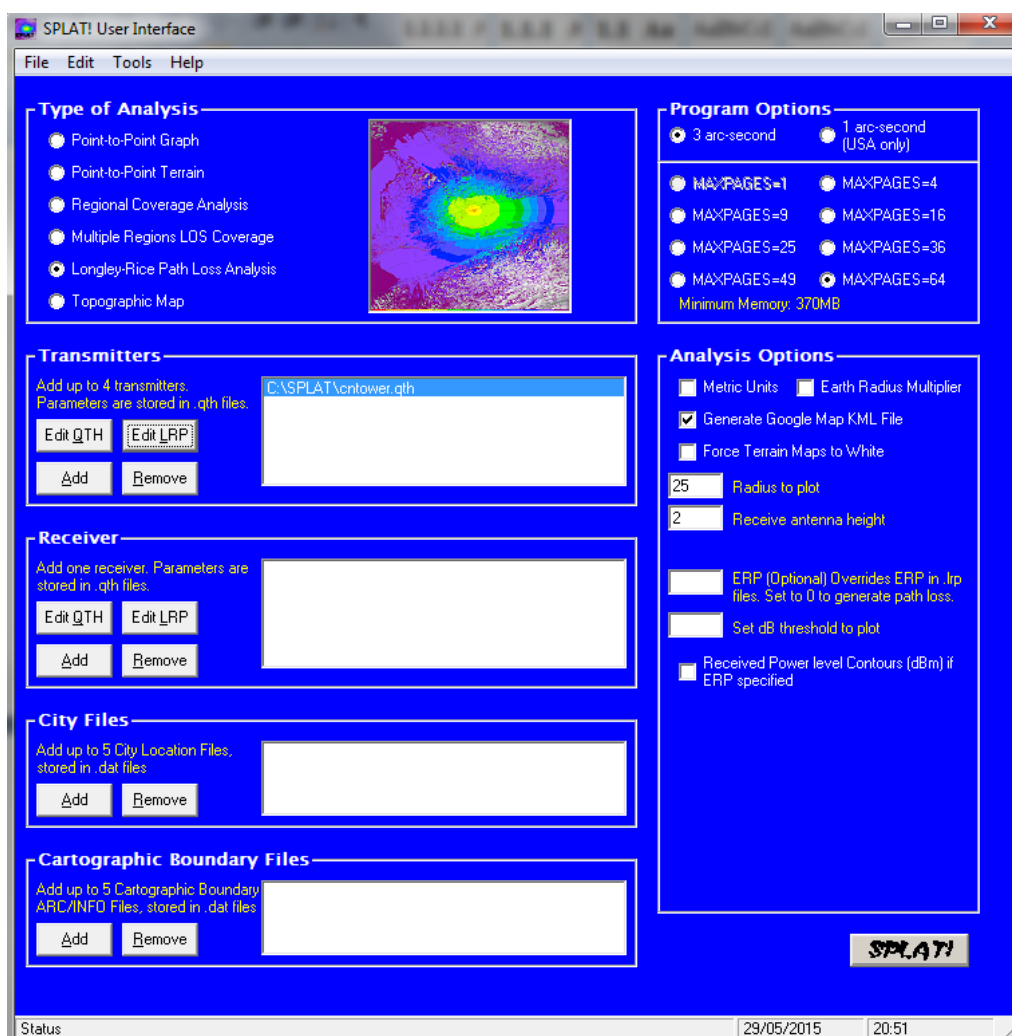


Figura 29. Interfaz de usuario de la herramienta SPLAT!

5.2 Localización de un blanco

En nuestro caso utilizaremos la herramienta para simular las pérdidas de trayecto que se producen entre la fuente y los sensores y obtener así el mapa de cobertura de nuestro escenario.

Para poder realizar el cálculo de coberturas, el programa necesita las alturas del terreno donde se va a trabajar.

Para ello, accederemos a la BBDD del departamento del interior estadounidense [14], el cual tiene dividida la orografía terrestre en latitudes y longitudes, y nos descargaremos el fichero .hgt del terreno deseado.

En nuestro caso, el terreno que nos descargaremos será el correspondiente a las coordenadas:

P1: Latitud: 43N Longitud: 359E

P2: Latitud: 43N Longitud: 000E

P3: Latitud: 42N Longitud: 359E

P4: Latitud: 42N Longitud: 000E



Figura 30. Mapa y situación del terreno descargado

Una vez descargado debemos convertirlo a un fichero .sdf. Esto se realiza mediante el menú Tools de la propia aplicación.

Posteriormente, seleccionaremos el tipo de análisis Longley-Rice. Este tipo de modelo, predice la posible propagación a larga-media distancia sobre un terreno irregular. Fue diseñado para frecuencias entre los 20MHz y 20GHz y para longitudes de trayecto de entre 1 y 2000 Km.

Capítulo 5: Simulación de resultados en escenario real

En la sección ‘Transmitters’ configuraremos las características de nuestro blanco encargado de emitir la señal como se muestran a continuación, al igual que las características del medio de propagación:

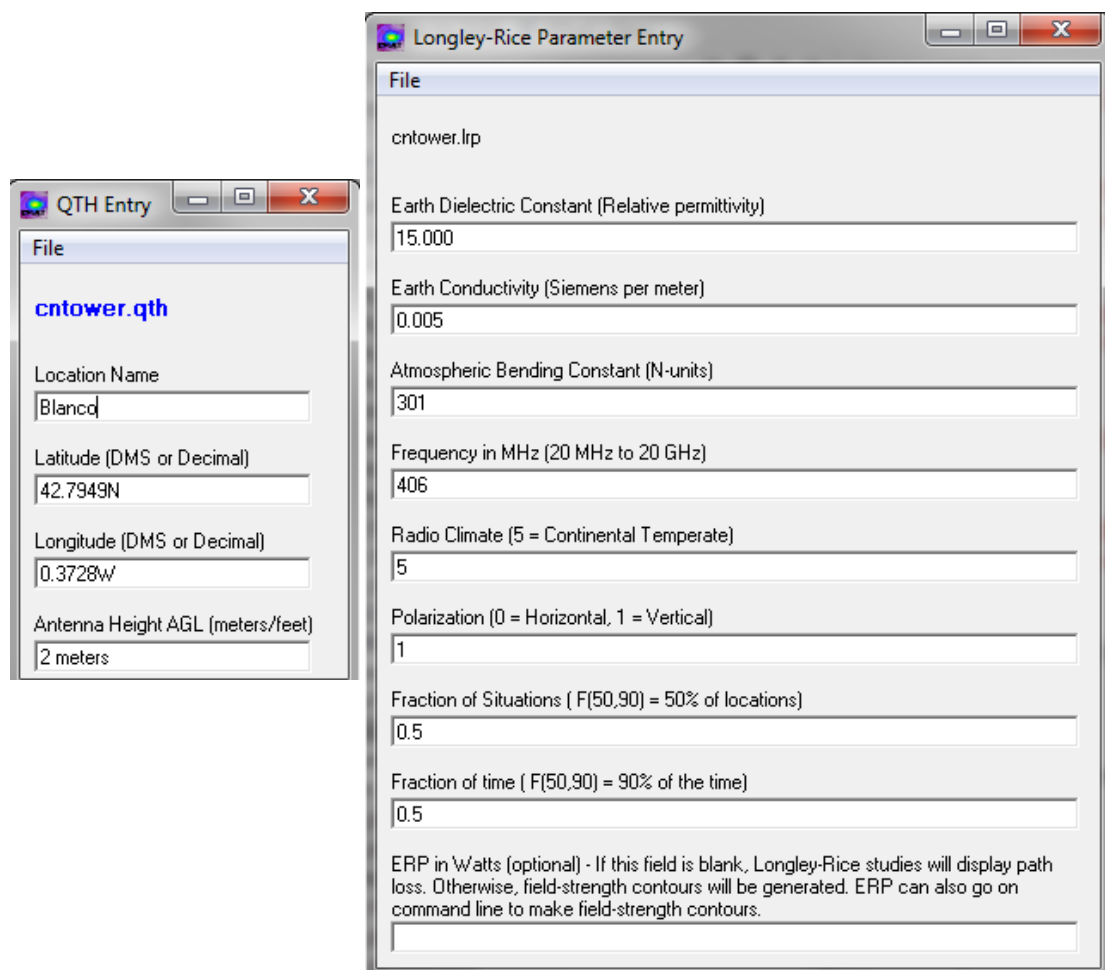


Figura 31. Configuración de parámetros en la herramienta SPLAT!

Se puede observar cómo en el campo dedicado para introducir la ERP en Watios, indica que si se deja en blanco se calcularán las pérdidas en el trayecto (path loss). Este será nuestro caso. Posteriormente, las relacionaremos con la potencia recibida para cada sensor.

Estableceremos también los parámetros de altura de los sensores y el radio de propagación que se quiere visualizar.

El programa permite modificar un fichero de configuración que se encarga de relacionar los colores (RGB) que mostrará, dependiendo de las pérdidas en el trayecto.

Sólo permite definir 32 contornos o colores por simulación, por lo que para resolver este problema y ampliar el rango de pérdidas realizaremos cuatro simulaciones con diferentes configuraciones de contorno cada vez.

Por comodidad, los colores los definiremos variando sólo la primera componente RGB, de tal modo que la tabla de equivalencias quedará:

Path loss (Db)				Color		
Simulacion 1	Simulacion 2	Simulacion 3	Simulacion 4	R	G	B
40	70	100	130	30	0	0
41	71	101	131	29	0	0
42	72	102	132	28	0	0
43	73	103	133	27	0	0
44	74	104	134	26	0	0
45	75	105	135	25	0	0
46	76	106	136	24	0	0
47	77	107	137	23	0	0
48	78	108	138	22	0	0
49	79	109	139	21	0	0
50	80	110	140	20	0	0
51	81	111	141	19	0	0
52	82	112	142	18	0	0
53	83	113	143	17	0	0
54	84	114	144	16	0	0
55	85	115	145	15	0	0
56	86	116	146	14	0	0
57	87	117	147	13	0	0
58	88	118	148	12	0	0
59	89	119	149	11	0	0
60	90	120	150	10	0	0
61	91	121	151	9	0	0
62	92	122	152	8	0	0
63	93	123	153	7	0	0
64	94	124	154	6	0	0
65	95	125	155	5	0	0
66	96	126	156	4	0	0
67	97	127	157	3	0	0
68	98	128	158	2	0	0
69	99	129	159	1	0	0
70	100	130	160	0	0	255

Tabla 1. Equivalencia dB con escala de colores

Los mapas obtenidos para cada simulación son los siguientes:

Simulación 1

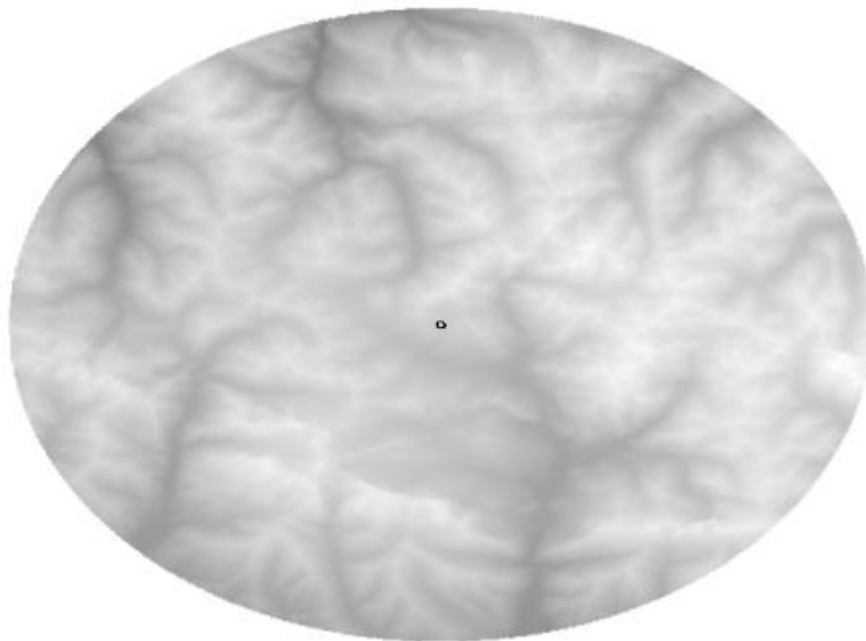


Figura 32. Distribución de potencia - Simulación 1

Simulación 2




Figura 33. Distribución de potencia - Simulación 2

Simulación 3




Figura 34. Distribución de potencia - Simulación 3


Simulación 4

Figura 35. Distribución de potencia - Simulación 4

Como se puede apreciar, los resultados de la simulación 1 muestra los puntos del mapa que reciben mayor potencia de señal, o lo que es lo mismo, existen menos pérdidas de trayecto.

En cambio para la Simulación 4, se observa que los puntos que reciben algo de señal están más alejados del centro que es donde se ubica el blanco, o están más cercanos pero tienen algún tipo de bloqueo.

Estas imágenes que nos devuelve el programa están en formato *.ppm por lo que nos permitirá leer los archivos en MATLAB para ubicar la posición de los sensores dentro de los mapas generados y poder asignar así la potencia que le corresponde a cada sensor.

Por lo tanto, mapeamos la posición de los sensores que las tenemos en coordenadas geográficas, dentro de la matriz que hemos obtenido al leer el archivo *.ppm de tamaño 2400x1200x3, posteriormente, mediante la función `readhgt(Lat, Lon)` obtenemos el modelo de elevación de la tierra para saber la altura del blanco y de cada sensor.

El mapa de sensores quedara del siguiente modo:




Figura 36. Mapa de sensores distribuidos en el terreno

En la vista en 3D (Figura 37) se puede apreciar como los sensores que están ubicados en la cima de las montañas tendrán habitualmente mejor cobertura que los sensores que están ubicados en las zonas de baja montaña, debido a que es más probable que se produzcan bloqueos entre el blanco y el sensor.




Figura 37. Mapa de sensores distribuidos en el terreno en 3D

Asignamos a cada sensor la potencia que recibe según su posición y la comparamos con la sensibilidad establecida de 95 db.

Si la potencia recibida por el sensor es menor que la sensibilidad ($RSS_{s_i} < 95$) indicará que ese sensor está recibiendo una potencia significativa y nos será útil para realizar la localización. Estos sensores serán denominados como sensores activos y se establecerá su valor de RSS_{s_i} como:

$$RSS_{s_i} = -RSS_{s_i} \text{ dbm} \quad (26)$$

En cambio, si la potencia que recibe un sensor es mayor que la sensibilidad ($RSS_{s_i} > 95$) serán sensores descartados que no intervendrán en la localización.

Estableceremos un número mínimo de sensores activos para poder llevar a cabo la localización con éxito. En nuestra simulación:

$$\text{Número sensores activos } (RSS_{s_i} < -95 \text{ dbm}) \geq 4 \quad (27)$$




Figura 38. Mapa de sensores activos e inactivos (un blanco)

El siguiente paso será establecer las posiciones de la red de RBFs que posteriormente realizarán la interpolación.

Como se ha señalado en el capítulo previo, el número de RBFs que utilizaremos será de 16 x 16, ya que es la que mejores resultados obtiene.

Para ello, reduciremos el área de búsqueda aplicando una reducción del 60% a las posiciones máximas y mínimas de los sensores en los dos ejes de coordenadas, quedando el área de localización aproximadamente en 68 Km²




Figura 39. Posicionamiento de la red de RBFs

Una vez conocidas las posiciones, crearemos la red RBFs.

Uno de los parámetros que hay que definir para la creación de la red es el parámetro σ , que tal y como se indicó en el apartado 3.4.1.2, está relacionado con el valor de la rejilla entre RBFs (Δ) según (22), donde $\hat{\sigma}$ tendrá el valor de dos, obtenido en las pruebas de optimización realizadas en el capítulo cuatro.

De tal modo que el valor de sigma que utilizaremos será:

$$\sigma = \hat{\sigma} * \max(\Delta x, \Delta y) \quad (28)$$

Otro parámetro a definir a la hora de la creación de las RBF es el parámetro de LASSO, que indicará el número máximo de RBF que queremos que sean distintas de cero y que por lo tanto, serán las únicas que participen en la interpolación.

Este parámetro lo variaremos, de 8 a 12 para comprobar cuál nos ofrece mejores resultados.

Después de crear la red de RBFs, procederemos a la utilización del algoritmo de LASSO. Destacar que como se ha indicado anteriormente, antes de utilizar el algoritmo de LASSO se comprueba que el número de sensores activos sea mayor de cuatro (27).

Utilizando el algoritmo de LASSO (25), conseguiremos optimizar y reducir nuestra red de RBFs que emplearemos en la interpolación. Como se ha indicado anteriormente, se define un parámetro que establecerá el número máximo de RBFs con peso no nulo.

Una vez obtenidas las RBF con pesos no nulos, se procede a crear la función de interpolación, que será la que nos ayudará a estimar la posición del blanco.

Cabe recordar que la estimación del blanco vendrá definida por el máximo de la función interpolada, pues si la interpolación es lo suficientemente buena sus máximos

coincidirán también con los de la función original, por lo que la posición de dichos máximos proporcionará la estimación de la posición del blanco.

En cada simulación también se realiza la estimación de la posición del blanco utilizando Least Squares. Para ello, utilizaremos un modelo de propagación con un factor de $n=2$ (pérdidas en espacio libre).

Una vez obtenida la estimación de la posición del blanco mediante Least Squares, calcularemos también el error medio entre la estimación y la posición real del blanco de todas las simulaciones, con el fin de poder compararlo con nuestro método desarrollado que utiliza el algoritmo LASSO.

Las siguientes figuras muestran gráficamente los resultados de la simulación:

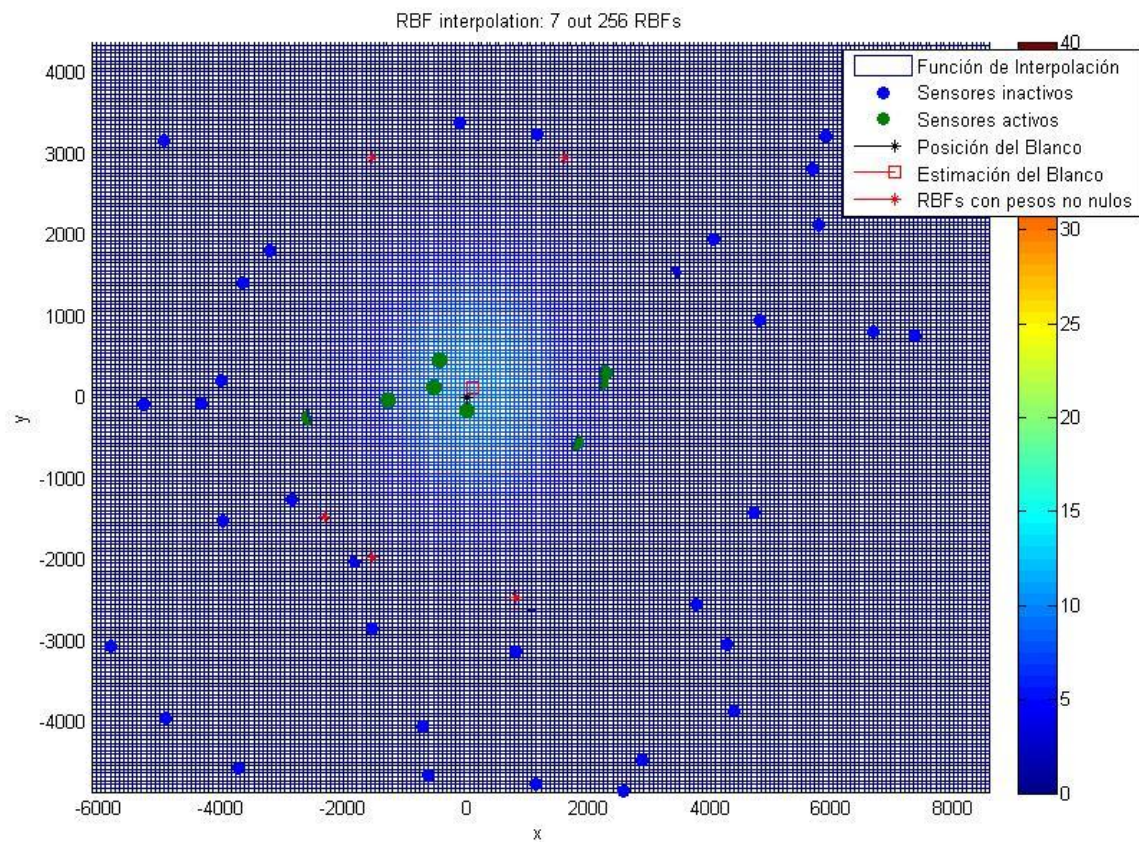


Figura 40. Simulación para localización de un blanco (eje xy)




Figura 41. Simulación para la localización de un blanco (eje xz)

En la Figura 40 y Figura 41, se muestra una simulación con el parámetro de LASSO establecido en ocho, a pesar de que el algoritmo sólo necesitó siete RBFs para crear la función de interpolación.

En las gráficas, se puede apreciar como la distancia entre la posición del blanco y la estimación obtenida están muy próximas.

En el ejemplo anterior, el error de precisión utilizando el algoritmo desarrollado es de 102.98m mientras que utilizando el algoritmo de Least Squares el error es de 768.79m.

Con el fin de obtener una media del error, se han realizado 100 simulaciones, resultando que para LS el error medio es de 393.15 m, mientras que con nuestro algoritmo es de 267.53 m.

Ilustramos los resultados en la Figura 38:




Figura 42. Comparativa de nuestro algoritmo con localización usando LS

Se puede comprobar que, independientemente de que el error medio utilizando nuestro algoritmo es inferior en el mayor número de veces, la localización utilizando Least Squares genera errores de estimación muy elevados de modo sistemático dependiendo de la configuración de los sensores.

En nuestro caso, donde estamos tratando una operación de rescate en alta montaña, no es aconsejable utilizar un estimador con tanta oscilación (varianza), pues esto provocará el fracaso de la misión.

5.3 Localización de múltiples blancos

Mediante una variante del código anterior podemos utilizar nuestro algoritmo para llevar a cabo localizaciones de más de un blanco simultáneamente.

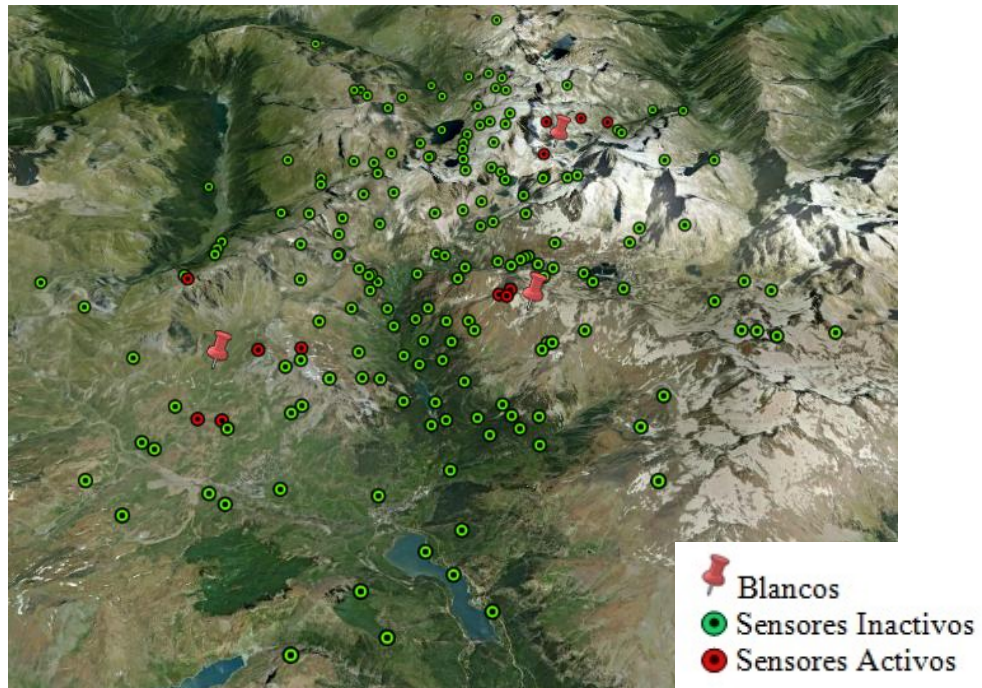


Figura 43. Mapa de sensores activos e inactivos (múltiples blancos)

El procedimiento será similar, con la diferencia de que ampliaremos nuestra red de RBFs (20×20) y deberemos desplegar un número mayor de sensores (en nuestro ejemplo 180).

Las siguientes figuras muestran gráficamente los resultados de la simulación:

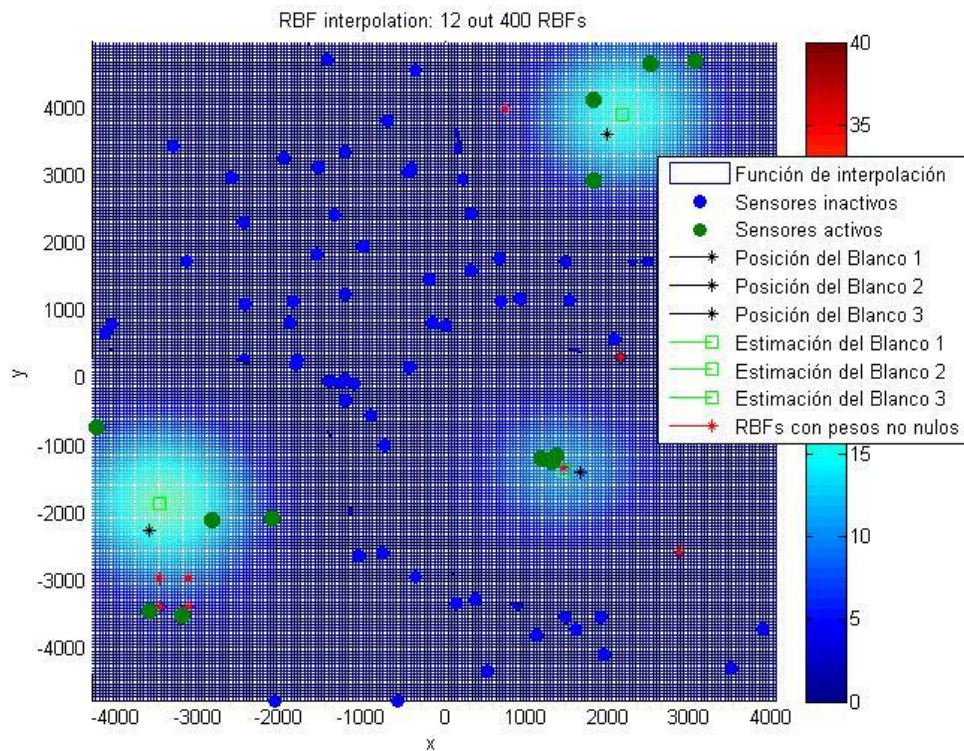


Figura 44. Simulación para la localización de más de un blanco (eje xy)




Figura 45. Simulación para la localización de más de un blanco en 3D

En ambas figuras, se puede apreciar como las posiciones estimadas de cada blanco están muy próximas a las posiciones reales.

El error en la localización para el blanco 1 es de 303.51 m, para el blanco 2 es 234.92 m y para el blanco 3 de 148.46 m.

Obteniendo una media aproximada de 200m de error.

Comparándolo con la localización con LS, el error en la localización para el blanco 1 es de 3.453 m, para el blanco 2 es 2.307 m y para el blanco 3 de 2.158 m.

Como se puede comprobar nuestro algoritmo de localización es aproximadamente diez veces más preciso que localizar usando LS.

5.3 Localización de múltiples blancos

Capítulo 6

Conclusiones y futuras líneas de trabajo

6.1 Conclusiones

La principal ventaja del algoritmo desarrollado es que la única presunción que hacemos para estimar la posición del blanco es que la señal que emite es una función gradual y “suave”, la cual tiene un máximo o mínimo en la posición del blanco.

De este modo, para llevar a cabo la localización, no necesitamos aproximar las observaciones a un modelo determinado, el cual pueda provocar errores de estimación ya que el modelo de observaciones del que se dispone está incompleto.

Otra gran ventaja a destacar es que para localizaciones de más de un blanco funciona con una alta precisión debido a que estamos utilizando un método de interpolación local, esto provoca que las funciones de base radial que tenemos desplegadas por el terreno se puedan ajustar dependiendo de si existe uno o más blancos.

En métodos de localización convencionales basados en Least Squares, la localización de múltiples blancos no sería posible.

Igualmente, al ser un algoritmo nuevo, aun existen características por mejorar.

Una de ellas, es el gran número de funciones de base radial que situamos en la rejilla para realizar la función de interpolación. A pesar de que mediante el algoritmo de LASSO este número de funciones se reduce considerablemente, los cálculos

computacionales para llevar a cabo esta optimización pueden ser muy elevados si se trabaja en escenarios de gran extensión.

Otro punto a mejorar de nuestro algoritmo es que para que la localización sea precisa se debe realizar una etapa previa donde se ajusten todos los parámetros que intervienen en el modelo de localización (parámetro $\hat{\sigma}$, número de RBFs, número de sensores a desplegar).

6.2 Futuras líneas de Trabajo

Sería interesante comparar el programa utilizado en este PFC para estimar la potencia que recibe cada sensor, SPLAT! [14] con otros sistemas o programas diferentes con el fin de comprobar si existen opciones más precisas y/o fiables.

Otra posible línea de trabajo sería el adaptar nuestro programa de localización para una fuente que no esté emitiendo una señal de potencia, sino por ejemplo, que emita una señal pulsada. En este caso, los sensores no calcularían la potencia recibida sino el tiempo de llegada del pulso emitido por la fuente.

Como ya se mencionó en el apartado 1.3.1, sería interesante implementar nuestro algoritmo para la localización de nubes contaminantes. Este caso sería muy similar al desarrollado en nuestro PFC, pues al igual que nuestra baliza emite una señal de potencia de modo continuo, las nubes contaminantes también emitirán una señal continua.

Capítulo 7

Presupuesto

7.1 Presupuesto

En este capítulo se van a detallar todos los costes asociados a la realización del proyecto.

Se desglosarán los costes de personal, los costes del material y los costes directos del proyecto obteniendo así el coste total.



UNIVERSIDAD CARLOS III DE MADRID
Escuela Politécnica Superior

PRESUPUESTO DE PROYECTO

1.- Autor: Sergio Miguel Pacheco

2.- Departamento: Teoría de la Señal y Comunicación

3.- Descripción del Proyecto:

- Título **Localización de Múltiples Blancos mediante Interpolación con Funciones de Base Radial**
 - Duración (meses) **12**
 Tasa de costes Indirectos: **20%**

4.- Presupuesto total del Proyecto (valores en Euros):

44.798 Euros

5.- Desglose presupuestario (costes directos)

PERSONAL

Apellidos y nombre	Categoría	Dedicación (hombres mes) ^{a)}	Coste hombre mes	Coste (Euro)	Firma de conformidad
Francisco Javier González Serrano	Ingeniero	0,65	5.118,75	10.031,25	
Miguel Pacheco, Sergio	Programador	1,89	3.720,94	11.422,50	
Miguel Pacheco, Sergio	Analista	1,2	3.150,00	7.800,00	
Hombres mes 0				Total	29.253,75

^{a)} 1 Hombre mes = 131,25 horas. Máximo anual de dedicación de 12 hombres mes (1575 horas)
 Máximo anual para PDI de la Universidad Carlos III de Madrid de 8,8 hombres mes (1.155 horas)

EQUIPOS

Descripción	Coste (Euro)	% Uso dedicado proyecto	Dedicación (meses)	Periodo de depreciación	Coste imputable ^{d)}
Ordenador	750,00	100	12	60	75,00
Total					150,00

^{d)} Fórmula de cálculo de la Amortización:

$$\frac{A}{B} \times C \times D$$

A = nº de meses desde la fecha de facturación en que el equipo es utilizado
 B = periodo de depreciación (60 meses)
 C = coste del equipo (sin IVA)
 D = % del uso que se dedica al proyecto (habitualmente 100%)

SUBCONTRATACIÓN DE TAREAS

Descripción	Empresa	Coste imputable
Total		0,00

OTROS COSTES DIRECTOS DEL PROYECTO^{e)}

Descripción	Empresa	Costes imputable
Internet		60,00
Microsoft Office 2010		89,00
Matlab 2012a		1.200,00
Material de Oficina		100,00
Total		1.449,00

e) Este capítulo de gastos incluye todos los gastos no contemplados en los conceptos anteriores, por ejemplo: fungible, viajes y dietas, otros,...

6.- Resumen de costes

Presupuesto Costes Totales	Presupuesto Costes Totales
Personal	29.254
Amortización	150
Subcontratación de tareas	0
Costes de funcionamiento	1.449
Costes Indirectos	6.171
Total sin IVA	37.023
Total con IVA	44.798

“El presupuesto total de este proyecto asciende a la cantidad de 44.798 EUROS”.

Leganés a X de Agosto de 2015

El ingeniero proyectista

Fdo. Sergio Miguel Pacheco

Glosario

RBF	<i>Radial Basic Functions</i>
LASSO	<i>Least Absolute Shrinkage and Selection Operator</i>
RSS	<i>Received Signal Strength</i>
RSSI	<i>Received Signal Strength Indicator</i>
RF	<i>Radio-frequency</i>
LS	<i>Least Squares</i>
ToA	<i>time of arrival</i>
TDoA	<i>time difference of arrival</i>
RMSE	<i>Root-mean-square deviation</i>
SPLAT!	<i>Signal Propagation, Loss, And Terrain analysis tool</i>

Referencias

- [1] *El futuro en Defensa: dirección y localización de francotiradores*. 2009. Disponible [Internet]: <<http://www.infodefensa.com/es/2009/05/18/opinion-el-futuro-en-defensa-deteccion-y-localizacion-de-francotiradores.php>> [23 de junio de 2015]
- [2] UC3M, *Modelos de propagación a gran escala*. Disponible [Internet]: <<http://www.tsc.uc3m.es/docencia/SyCT/Tema%203/Tema3.pdf>> [23 de junio de 2015]
- [3] *Corporación Centroamericana de Servicios de Navegación Aérea*. Disponible [Internet]: <<http://www.cocesna.org/subpagina.php?id=322&lng=0>> [23 de junio de 2015]
- [4] Universitat Jaume I de Castellón, *Sistema de Localización para redes inalámbrica de sensores mediante zigbee*. Disponible [Internet]: <file:///C:/Users/Sergio/Downloads/Memoria_revisada_Pallares_Gual_Sandra.pdf> [23 de junio de 2015]
- [5] Universidad de Cantabria, *Mínimos cuadrados ordinarios*. Disponible [Internet]: <<http://ocw.unican.es/ciencias-sociales-y-juridicas/econometria/econometria/apuntes/tema2.pdf>> [23 de junio de 2015]
- [6] Universidad Nacional de Colombia, *Métodos de Regresión*. Disponible [Internet]: <http://www.virtual.unal.edu.co/cursos/ciencias/2007315/html/un5/cont_02_42.html> [23 de junio de 2015]
- [7] P. Stoica and J. Li, “*Lecture notes - source localization from range-difference measurements*,” IEEE Signal Processing Magazine, vol. 23, no. 6, pp. 63–66, Nov 2006.

- [8] *Interpolación*. Disponible [Internet]: <<http://www.prof.uniandes.edu.co/~gprieto/classes/compufis/interpolacion.pdf>> [23 de junio de 2015]
- [9] Universidad de Granada, *Interpolación*. Disponible [Internet]: <<http://www.ugr.es/~mpasadas/ftp/Inter2.pdf>> [23 de junio de 2015]
- [10] Eric Iturbide, Jaime Cerda y Mario Graf, “*Aplicación de métodos de selección de variables para la predicción de series de tiempo*”. Disponible [Internet]: <<http://lsc.fie.umich.mx/~mgraffg/pdf/ropec2012c.pdf>> [23 de junio de 2015]
- [11] Fernando Tusell , “*Análisis de Regresión. Introducción Teórica y Práctica basada en R*”. Disponible [Internet]: <<http://www.et.bs.ehu.es/~etptupaf/nuevo/ficheros/estad3/nreg1.pdf>> [23 de junio de 2015]
- [12] *K-means clustering*. Disponible [Internet]: <<http://www.onmyphd.com/?p=k-means.clustering>> [23 de junio de 2015]
- [13] John A. Magliacane, KD2BD, *SPLAT!*, Disponible [Internet]: <<http://www.qsl.net/kd2bd/splat.html>> [23 de junio de 2015]
- [14] U.S. Department of the Interior, *U.S. Geological Survey*. Disponible [Internet]: <http://dds.cr.usgs.gov/srtm/version2_1/SRTM3/Eurasia > [23 de junio de 2015]
- [15] S. Pino, C. Bousoño, F.J. González, “*Radial Basis Function Interpolation for Model-Independent Localization*” enviado para su publicación en Julio 2014 [23 de junio de 2015]