

UNIVERSIDAD POLITÉCNICA DE MADRID

**ESCUELA TÉCNICA SUPERIOR
DE INGENIEROS DE TELECOMUNICACIÓN**



**MÁSTER UNIVERSITARIO EN INGENIERÍA
DE TELECOMUNICACIÓN**

TRABAJO FIN DE MÁSTER

**DESARROLLO DE ENTORNOS DE
SIMULACIÓN PARA EL ANÁLISIS DE
ALGORITMOS DE SEGUIMIENTO EN
RADARES MULTIESTÁTICOS**

PABLO GARCÍA PACHECO

2025

MÁSTER UNIVERSITARIO EN INGENIERÍA DE TELECOMUNICACIÓN

TRABAJO FIN DE MÁSTER

Título: Desarrollo de entornos de simulación para el análisis de algoritmos de seguimiento en radares multiestáticos

Autor: D. Pablo García Pacheco

Tutor: D. Rodrigo Blázquez García

Departamento: Señales, Sistemas y Radiocomunicaciones

MIEMBROS DEL TRIBUNAL

Presidente: D.

Vocal: D.

Secretario: D.

Suplente: D.

Los miembros del tribunal arriba nombrados acuerdan otorgar la calificación de:
.....

Madrid, a de de 20...

UNIVERSIDAD POLITÉCNICA DE MADRID

ESCUELA TÉCNICA SUPERIOR

DE INGENIEROS DE TELECOMUNICACIÓN



**MÁSTER UNIVERSITARIO EN INGENIERÍA
DE TELECOMUNICACIÓN**

TRABAJO FIN DE MÁSTER

**DESARROLLO DE ENTORNOS DE
SIMULACIÓN PARA EL ANÁLISIS DE
ALGORITMOS DE SEGUIMIENTO EN
RADARES MULTIESTÁTICOS**

PABLO GARCÍA PACHECO

2025

RESUMEN

El creciente uso de vehículos aéreos no tripulados (UAVs), especialmente en entornos urbanos, ha generado nuevas necesidades en materia de vigilancia y seguridad. Estos sistemas, de bajo coste y alta maniobrabilidad, representan una amenaza tanto en el ámbito civil como en el militar, como evidencian conflictos recientes. En paralelo, la expansión de infraestructuras de telecomunicaciones, en áreas metropolitanas abre la posibilidad de aprovechar señales existentes como iluminadores de oportunidad. En este contexto, los radares pasivos y las arquitecturas multiestáticas se presentan como una alternativa prometedora, al permitir detectar y seguir objetivos sin necesidad de emisores propios, reduciendo costes, consumo energético y requisitos legales de espectro.

El objetivo principal de este trabajo es el diseño, implementación y análisis de entornos de simulación para algoritmos de seguimiento de objetos en arquitecturas radar multiestáticas, con especial atención a su aplicación en escenarios urbanos y a la evaluación del desempeño de los algoritmos. Para ello, se aborda la fase de procesado de datos tras la detección, asumiendo que el procesado de señal se realizó en una etapa previa, y centrándose en técnicas de seguimiento capaces de asociar medidas y estimar trayectorias con precisión en configuraciones multiestáticas.

En primer lugar, se ha llevado a cabo un estudio del estado del arte en torno a los radares pasivos y multiestáticos, así como de sus aplicaciones emergentes en defensa y seguridad urbana. Se han analizado iniciativas industriales y programas europeos como el *Future Combat Air System* (FCAS) o el proyecto iFURTHER, que refuerzan la relevancia de la arquitectura distribuida frente a amenazas modernas. Asimismo, se ha destacado el papel de los UAVs de bajo coste en la guerra de Ucrania, lo que ilustra la necesidad de soluciones capaces de hacer frente a este tipo de amenazas.

Posteriormente, se ha desarrollado un entorno de simulación en MATLAB que permite reproducir configuraciones multiestáticas, incorporando transmisores y receptores distribuidos. Este entorno incluye modelización geométrica, trayectorias múltiples de blancos, generación de detecciones y la implementación de diferentes algoritmos de seguimiento, con el fin de

evaluar su rendimiento en escenarios con ruido, incertidumbre y ambigüedad en la asociación de medidas.

Los resultados muestran que la geometría de despliegue influye de manera decisiva en la precisión de localización: las configuraciones con mayor diversidad espacial ofrecen mejores resultados. En cuanto a los algoritmos de seguimiento, se ha constatado que los filtros que consideran modelos lineales como el filtro de Kalman no resultan adecuados en radares multiestáticos debido a la no linealidad entre el espacio de medida (distancias biestáticas, velocidades biestáticas y, potencialmente, ángulo de llegada) y el espacio de estado (posición y velocidad en coordenadas cartesianas). En contraste, filtros no lineales como el *Extended Kalman Filter* (EKF), el *Unscented Kalman Filter* (UKF) y el filtro de partículas ofrecen estimaciones más robustas y precisas, siendo los dos primeros preferibles en términos de coste computacional. Además, se ha desarrollado un algoritmo de asociación de detecciones a pistas que, reforzado con el ángulo de llegada, mejora la discriminación frente a blancos fantasmas y múltiples objetivos.

SUMMARY

The growing use of unmanned aerial vehicles (UAVs), especially in urban environments, has created new surveillance and security needs. These low-cost, highly maneuverable systems represent a threat in both the civilian and military spheres, as recent conflicts have shown. At the same time, the expansion of telecommunications infrastructure, with densely deployed networks in metropolitan areas, opens up an opportunity to leverage existing signals as illuminators of opportunity. In this context, passive radars and multistatic architectures present a promising alternative, as they allow targets to be detected and tracked without the need for their own transmitters, reducing costs, energy consumption, and legal spectrum requirements.

The main objective of this work is the design, implementation and analysis of simulation environments for tracking algorithms in multistatic radar architectures, with special attention to their application in urban scenarios and the assessment of their performance. To this end, the data processing phase following target detection is addressed, assuming that signal processing has already been carried out at a previous stage and focusing on the evaluation of tracking techniques capable of associating measurements and accurately estimating trajectories in multistatic configurations.

First, a state-of-the-art study was conducted on passive and multistatic radars, as well as their emerging applications in defense and urban security. Industrial initiatives and European programs such as the Future Combat Air System (FCAS) and the iFURTHER project have been analyzed, reinforcing the relevance of distributed architecture for the detection of modern threats. Likewise, the role of low-cost UAVs in the war in Ukraine has been highlighted, illustrating the necessity of technological solutions capable of addressing this type of threat.

Subsequently, a simulation environment has been developed in MATLAB that allows passive multistatic configurations to be reproduced, incorporating distributed transmitters and receivers. This environment includes geometric modeling, incorporating multiple target trajectories, the detection generation, and the implementation of different tracking algorithms in order to evaluate their performance in operational scenarios under conditions of noise, uncertainty, and ambiguity in the association of measurements.

The results show that the deployment geometry has a decisive influence on location accuracy: configurations with greater spatial diversity offer better results. Regarding tracking algorithms, it has been found that linear filters such as Kalman filters are not suitable for multistatic configurations due to the non-linearity between the measurement space (bistatic range, velocity, and, potentially, angle of arrival at the receiver) and the state space (position and velocity in Cartesian coordinates). In contrast, nonlinear filters such as the Extended Kalman Filter (EKF), the Unscented Kalman Filter (UKF), and the particle filter offer more robust estimates, with the first two being preferable in terms of computational cost. In addition, a detection-to-track association algorithm has been developed which, reinforced with additional measures such as the angle of arrival, has been shown to improve discrimination against ghost targets and multiple targets.

PALABRAS CLAVE

Radar, biestático, multiestático, simulación, filtro, localización, multilateración, Kalman, seguimiento y asociación.

KEYWORDS

Radar, bistatic, multistatic, simulation, filter, localization, multilateration, Kalman, tracking and association.

ÍNDICE DEL CONTENIDO

| | |
|---|-----------|
| 1. INTRODUCCIÓN Y OBJETIVOS | 1 |
| 1.1. Introducción | 1 |
| 1.2. Motivación y Objetivos..... | 5 |
| 1.3. Estructura y metodología | 7 |
| 1.3.1. Método Monte Carlo..... | 8 |
| 2. ESTADO DEL ARTE | 10 |
| 3. FUNDAMENTOS DEL SISTEMA | 15 |
| 3.1. Principios de los radares biestáticos..... | 15 |
| 3.1.1. Arquitectura biestática | 15 |
| 3.1.2. Geometría..... | 16 |
| 3.1.3. Extensión Multiestática..... | 20 |
| 3.1.4. Procesamiento de la señal en Radar biestático..... | 22 |
| 3.1.5. Localización del blanco | 23 |
| 3.2. Sistema RADAR..... | 31 |
| 3.2.1. Extractor de datos..... | 32 |
| 3.2.2. Procesador de datos..... | 33 |
| 3.2.3. Filtros de seguimiento..... | 35 |
| 3.3. Modelos dinámicos | 47 |
| 3.3.1. Movimiento rectilíneo uniforme (MRU) | 47 |
| 3.3.2. Movimiento rectilíneo uniformemente acelerado (MRUA)..... | 47 |
| 3.3.3. Modelo de giro constante (Constant Turn-Rate)..... | 48 |
| 4. DISEÑO, IMPLEMENTACIÓN Y RESULTADOS | 50 |
| 4.1. Localización..... | 53 |
| 4.1.1. Ángulo de llegada | 55 |

| | | |
|---|---|-----------|
| 4.1.2. | Configuraciones con múltiples transmisores y receptores | 59 |
| 4.2. | Filtros de seguimiento | 62 |
| 4.2.1. | Trayectoria rectilínea | 62 |
| 4.2.2. | Trayectoria no lineal | 65 |
| 4.3. | Asociación en escenarios multiobjetivo..... | 70 |
| 5. | CONCLUSIONES Y LÍNEAS FUTURAS | 80 |
| 5.1. | Conclusiones | 80 |
| 5.2. | Líneas futuras..... | 81 |
| 6. | BIBLIOGRAFÍA..... | 83 |
| ANEXO A: ASPECTOS ÉTICOS, ECONÓMICOS, SOCIALES Y | | |
| AMBIENTALES | | 87 |
| A.1 | INTRODUCCIÓN | 87 |
| A.2 | DESCRIPCIÓN DE IMPACTOS RELEVANTES RELACIONADOS CON EL PROYECTO | 88 |
| A.3 | ANÁLISIS DETALLADO DE ALGUNO DE LOS PRINCIPALES IMPACTOS | 89 |
| A.4 | CONCLUSIONES | 89 |
| ANEXO B: PRESUPUESTO ECONÓMICO | | 91 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| Figura 1-1 Evolución del número de estaciones base por tecnología [18]..... | 5 |
| Figura 2-1 Hensoldt Twinvis - Passive Radar [21]..... | 10 |
| Figura 2-2 Arquitectura conceptual de la red cooperativa de sensores del FCAS [23] | 11 |
| Figura 2-3 Esquema conceptual de la red multiestática de radares HF en el proyecto iFURTHER [24] | 12 |
| Figura 3-1 Arquitectura general de un sistema radar biestático pasivo | 16 |
| Figura 3-2 Geometría biestática [30] | 17 |
| Figura 3-3 Esquema de la geometría biestática en dos dimensiones | 18 |
| Figura 3-4 Ejemplo de intersección de elipses biestáticas en un escenario multiestático..... | 21 |
| Figura 3-5 Localización del blanco mediante la intersección de elipsoides biestáticos | 23 |
| Figura 3-6 Geometría de localización del objetivo para $M = 3$ transmisores y $N = 1$ receptor..... | 24 |
| Figura 3-7 Simulación que ejemplifica la problemática de blancos fantasma | 30 |
| Figura 3-8 Diagrama de bloques de procesador y extractor datos radar | 31 |
| Figura 3-9 Arquitectura general de un procesador de datos radar | 34 |
| Figura 3-10 Diagrama de flujo de un sistema de seguimiento..... | 35 |
| Figura 3-11 Error de predicción según el ruido de proceso | 37 |
| Figura 3-12 Error de predicción según el ruido de medida considerado para el filtro de seguimiento. | 38 |
| Figura 3-13 Error de predicción según el tiempo de refresco (asociado al tiempo de integración en radares pasivos)..... | 39 |
| Figura 3-14 Distribución de las partículas en el filtro de partículas según la posición del blanco | 44 |
| Figura 3-15 Distribución de las partículas en el filtro de partículas según el ruido de proceso considerado | 45 |
| Figura 3-16 Distribución de las partículas en el filtro de partículas según el ruido de medida considerado | 45 |

| | |
|--|----|
| Figura 3-17 Convergencia de las partículas en el filtro de partículas según el número de partículas... | 46 |
| Figura 4-1 Diagrama de clases de un escenario multiestático | 51 |
| Figura 4-2 Portal “Infoantenas” (Área de Ciudad Universitaria) [39] | 52 |
| Figura 4-3 Mapa cartográfico de la posición de los transmisores y el receptor | 53 |
| Figura 4-4 Mapa de error de multilateración por resolución analítica y optimización numérica, respectivamente..... | 54 |
| Figura 4-5 Mapa de error de multilateración por optimización numérica | 54 |
| Figura 4-6 Esquema para el cálculo de incertidumbre en <i>cross-range</i> | 57 |
| Figura 4-7 Mapa de error de multilateración empleando la medida del ángulo de llegada | 58 |
| Figura 4-8 Mapa de error de multilateración con 4 transmisores | 59 |
| Figura 4-9 Mapa de error de multilateración con 4 transmisores y 2 receptores | 61 |
| Figura 4-10 Trayectoria rectilínea del blanco para un tiempo de integración de 10 segundos sobre un mapa cartográfico..... | 62 |
| Figura 4-11 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 10 segundos en un escenario con trayectoria rectilínea..... | 64 |
| Figura 4-12 Trayectoria rectilínea del blanco reducida para un tiempo de integración de 1 segundo sobre un mapa cartográfico..... | 64 |
| Figura 4-13 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 1 segundo en un escenario con trayectoria rectilínea | 65 |
| Figura 4-14 Trayectoria no lineal y estimaciones obtenidas con distintos filtros de seguimiento para una simulación del escenario | 66 |
| Figura 4-15 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 10 segundos en un escenario con trayectoria no lineal..... | 67 |
| Figura 4-16 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 1 segundo en un escenario con trayectoria no lineal | 67 |
| Figura 4-17 Error medio de la predicción de los filtros con un modelo dinámico de giro constante y tiempo de integración de 10 segundos en un escenario con trayectoria no lineal..... | 68 |

| | |
|---|----|
| Figura 4-18 Error medio de la predicción de los filtros con un modelo dinámico de giro constante y tiempo de integración de 1 segundo en un escenario con trayectoria no lineal | 69 |
| Figura 4-19 Diagrama de flujo del algoritmo de un sistema de asociación y seguimiento en radar multiestático..... | 71 |
| Figura 4-20 Probabilidad de asociación en una distribución normal según la desviación..... | 74 |
| Figura 4-21 Esquemático de asociación por el método de <i>Nearest Neighbor</i> para dos instantes de medida consecutivos..... | 75 |
| Figura 4-22 Resultado en mapa cartográfico de un proceso de asociación y seguimiento en radar multiestático..... | 76 |
| Figura 4-23 Error medio de la predicción de los filtros para cada blanco | 77 |
| Figura 4-24 Diagrama de flujo del algoritmo de asociación y seguimiento en radar multiestático con medidas de ángulo de llegada | 78 |
| Figura 4-25 Error medio de la predicción de los filtros para cada blanco con medida de AoA | 79 |

ÍNDICE DE TABLAS

| | |
|---|----|
| Tabla 4-1 Resultados de error de medida y tiempo de computación | 61 |
| Tabla 9-1 Presupuesto económico | 91 |

1. INTRODUCCIÓN Y OBJETIVOS

1.1. INTRODUCCIÓN

La palabra RADAR proviene del acrónimo en inglés “Radio Detection and Ranging” que puede traducirse como “Detección y Medición de Distancia por Radio”. Los radares son sistemas que utilizan ondas electromagnéticas para detectar y medir la distancia a la que se encuentra un objeto, también llamado habitualmente blanco. Generalmente, estos sistemas cuentan con una cadena completa de transmisión y recepción, utilizando el espacio libre como medio de transmisión de las ondas. En función del tipo de sistema, los radares pueden tener distintas arquitecturas (p. ej. arquitecturas coherentes o no coherentes), emplear distintos tipos de formas de onda (p. ej. pulsadas o continuas) e incluir diferentes etapas de procesado de la señal y de datos.

Los radares se pueden clasificar en función de dónde se encuentren ubicados sus componentes de transmisión y recepción. En primer lugar, los sistemas más comunes son los radares monoestáticos en los que el transmisor y el receptor están integrados en el mismo sistema, es decir, en la misma ubicación física. En segundo lugar, existen sistemas emergentes basados en la tecnología de radar biestático que se caracterizan por tener su transmisor y receptor físicamente separados. Por último, el radar multiestático es una generalización del radar biestático que incorpora múltiples transmisores y receptores distribuidos en diferentes localizaciones espaciales que operan de forma coordinada fusionando los datos medidos.

Se considera que el primer sistema radar data del año 1904, creado por el alemán Christian Hülsmeyer, que permitía la detección de objetos metálicos por medio de ondas electromagnéticas y se patentó bajo el nombre de “Telemobiloscope”. Sin embargo, este primer sistema, en configuración monoestática, solo permitía la detección, pero no era capaz de calcular la distancia a la que se encontraba el objeto.

En cambio, los primeros radares operativos, capaces de detectar objetos y medir distancias, fueron del tipo biestáticos. Antes y durante la Segunda Guerra Mundial varios radares biestáticos de onda continua fueron desarrollados y desplegados por países como Reino Unido, Estados Unidos, Unión Soviética, Japón, Francia, Alemania e Italia. El primero de todos fue el “Davenport Experiment” desarrollado en 1935 por el ejército británico, dirigido por Robert Watson-Watt, en el que se pudo detectar un bombardero Heyford, debido a la reflexión de las ondas electromagnéticas que se producían en el avión [1].

Con el descubrimiento y desarrollo del diplexor y su empleo en sistemas radar, que permite el uso de formas de onda pulsadas con una sola antena común para recepción y transmisión, los estudios se

centraron en estos radares monoestáticos debido a las ventajas que introducía la operación en un único lugar. En la década de 1950 resurge el interés por los radares biestáticos y multiestáticos para aplicaciones de defensa aérea y alerta de lanzamiento de misiles balísticos, y desde entonces, ha habido múltiples resurgimientos en este tipo de radares en las décadas de 1980 y 1990 [2] y actualmente, por ejemplo, con el programa FCAS (*Future Air Combat System*).

El avance tecnológico militar ha marcado las líneas de investigación en las diferentes tecnologías radar para poder hacer frente a las diferentes amenazas surgidas por tierra, mar y aire, así como en el dominio del espectro electromagnético. Por tanto, es importante analizar las diferentes bondades y debilidades de los diferentes tipos de arquitecturas radar que se han mencionado.

En el caso de los radares monoestáticos, la ubicación en el mismo lugar físico del receptor y el transmisor confiere una de sus principales ventajas, la simplicidad de su diseño y operación dentro de las diferentes combinaciones que pueden existir dependiendo de la forma de onda, el tipo de transmisión (onda continua u onda pulsada), antena rotatoria o estática, etc. Al compartir un único sistema con cadenas de transmisión y recepción se elimina la necesidad de sincronización externa y se simplifica la implementación. Sin embargo, presentan la desventaja del acoplamiento entre el transmisor y el receptor. Los radares de vigilancia son normalmente dispositivos que transmiten una alta potencia por lo que el aislamiento entre transmisor y receptor debe ser suficientemente bueno para proteger al receptor de recibir una alta potencia acoplada que podría provocar la detección de falsos objetivos, su saturación y ocultamiento de blancos, o incluso dañar sus componentes. Por otra parte, la principal amenaza que presentan estos sistemas en los entornos actuales es la facilidad en la localización del dispositivo. A través de la detección y análisis de la señal transmitida se puede identificar el punto en el que se encuentra y se pueden aplicar más fácilmente contramedidas electrónicas como el *jamming*, que consiste en aplicar una señal de interferencia en la dirección dónde se localiza el radar, o directamente la neutralización del sistema.

Los sistemas radar biestáticos [3] se caracterizan por tener el transmisor y el receptor separados por una distancia notable (es decir, no despreciable respecto de las distancias al blanco) denominada línea base, tanto como que los ángulos y las distancias a los objetivos pueden ser significativamente diferentes. Un aspecto positivo de esta configuración es el gran aislamiento que proporciona entre receptor y transmisor ya que sus antenas se encuentran separadas. Por tanto, el problema del acoplamiento de las señales transmitidas, importante en los sistemas monoestáticos, se reduce o desaparece en esta configuración. Además, la geometría biestática permite generalmente incrementar la capacidad de detección de blancos *stealth*, ya que estos suelen estar diseñados con formas determinadas para reducir su RCS (*Radar Cross Section*) monoestática. Por ejemplo, estas formas diseñadas pueden reducir la RCS cuando se observa el objeto desde la parte frontal utilizando un radar monoestático, sin embargo,

lo habitual es que la onda se disperse en otras direcciones, lo que proporciona una mayor RCS en determinadas direcciones biestáticas y el blanco deje de tener baja visibilidad para los sistemas radar biestáticos.

Como generalización de los sistemas biestáticos surgen los radares multiestáticos [4] como combinación de múltiples transmisores y receptores, que permite la fusión de datos de diferentes nodos o pares biestáticos. De esta forma, proporcionar un rendimiento de geolocalización sustancialmente mejorado como resultado de la combinación de las diversas mediciones del objetivo mediante algoritmos de multilateración. Además, estos sistemas al tener una diversidad espacial mayor a los sistemas meramente biestáticos se pueden emplear para minimizar el desvanecimiento del objetivo, mejorando la detección y el reconocimiento de los objetivos.

Una de las principales amenazas que se mencionaba con respecto a los radares monoestáticos en el contexto militar es la relativamente fácil identificación y localización del sistema mediante equipos de guerra electrónica que monitorizan el espectro electromagnético. En cambio, en el caso de los sistemas multiestáticos, al estar separados el transmisor y el receptor, aumenta la dificultad de inutilizar el sistema por la no posibilidad de localizar a los receptores y emitir interferencias dirigidas. Además, si se cuenta con múltiples transmisores, estos serían los únicos detectables, y se deberían neutralizar todos ellos para dejar sin eficacia el sistema.

Por último, los radares pasivos [5] son en cuanto a configuración radares biestáticos o multiestáticos en función de si se considera un único transmisor y receptor o múltiples pares. Sin embargo, los transmisores considerados no son dedicados ni cooperativos, sino que se emplean iluminadores de oportunidad que forman parte de otros sistemas de comunicaciones y emiten señales electromagnéticas, como: torres de radio FM [6], estaciones de televisión DVB-T (*Digital Video Broadcasting – Terrestrial*) [7], torres de telefonía móvil GSM (*Global System for Mobile communications*) [8] o LTE (*Long-Term Evolution*) [9], satélites DVB-S (*Digital Video Broadcasting by Satellite*) [10], de navegación GNSS (*Global Navigation Satellite Systems*) [11] o de comunicaciones [12], o incluso otros radares activos [13]. Estas señales no son cooperativas por lo que los parámetros de la señal no están diseñados ni optimizados para maximizar las medidas radar, por lo tanto, los esfuerzos se centran en los receptores que son el único elemento bajo control del diseñador radar. Por estos motivos, el comportamiento esperado es subóptimo respecto al que tendría un radar multiestático con transmisores dedicados y diseñados para este fin.

Una ventaja que hace muy atractivo este tipo de sistemas pasivos respecto a los radares activos es que no requieren de una compleja infraestructura o licencias para la emisión de energía electromagnética y que no contribuyen a la actual congestión del espectro electromagnético [14]. Además, se pueden implementar utilizando componentes COTS (*Commercial Off-The-Shelf*), como radios definidas por

software (SDR, *Software Defined Radio*), lo que disminuye típicamente el coste del sistema y la complejidad de desarrollo [15].

Los equipos SDR representan un cambio de paradigma desde los sistemas de radio dominados por el diseño de hardware hacia sistemas donde la mayor parte de la funcionalidad se define en software [16]. El objetivo ideal de la tecnología SDR es poder recibir y procesar una señal en cualquier frecuencia, ancho de banda o modulación simplemente cargando el software apropiado. Aunque este ideal no es completamente alcanzable, las SDR modernas ofrecen una gran flexibilidad, permitiendo que las características de recepción (p.ej. frecuencia central, ancho de banda, ganancia, etc.) y de la adaptación y digitalización de las señales se definan en software, lo que facilita la capacidad de operar en múltiples bandas y con múltiples tipos de modulación.

Esta flexibilidad se logra gracias a la evolución de tecnologías clave como los conversores analógico-digitales (AD) y digital-analógicos (DA), los procesadores de señales digitales (DSP), las FPGAs (*Field Programmable Gate Arrays*) y los procesadores de propósito general (GPPs). En una SDR, la señal recibida se digitaliza lo antes posible en la cadena receptora para que casi todo el procesamiento se realice en el dominio digital. Esto permite que el sistema pueda ser actualizado o reconfigurado para adaptarse a nuevas señales de oportunidad o para implementar algoritmos de detección y seguimiento más avanzados sin necesidad de cambiar el hardware [17]. La complejidad que se quiera añadir al sistema también queda abierta al diseñador y a los requisitos ya que se pueden implementar medidas para mejorar el desempeño del sistema, como antenas de apuntamiento electrónico con diferentes haces para realizar una sectorización del espacio de vigilancia y facilitar la detección y seguimiento.

Por otra parte, en el ámbito militar, los radares pasivos presentan un gran atractivo ya que al utilizar señales ya presentes en el espectro y que no se consideran hostiles o dedicadas a la teledetección, hace casi imposible a los objetivos saber que están siendo detectados y aplicar contramedidas electrónicas, aunque cuenten con equipos de guerra electrónica y monitorización del espectro electromagnético.

El amplio despliegue en infraestructura de comunicaciones que se ha llevado a cabo en las últimas décadas favorece especialmente este tipo de sistemas radar por la gran variedad de transmisores desplegados especialmente en las grandes ciudades. Los datos del sector de las comunicaciones móviles en España a cierre de 2024 ilustran perfectamente esta realidad: el territorio nacional contaba con una infraestructura masiva compuesta por 63.862 estaciones base con tecnología 4G, más de 45.500 con tecnología 3G y más de 50.000 con 2G. Más relevante aún es el rápido crecimiento de las redes de quinta generación (5G). En tan solo un año, el número de estaciones base 5G activas se incrementó en un 30,8%, alcanzando un total de 31.007. Este despliegue se apoya en 47.165 nodos radio que emiten en múltiples bandas de frecuencia (principalmente 700 MHz, 2100 MHz y 3,5 GHz), lo que demuestra no solo la cantidad, sino también la diversidad de las señales disponibles. El esfuerzo inversor se ha

centrado especialmente en la modalidad más avanzada, 5G SA (*Standalone*), que ha visto quintuplicado su número de estaciones base en el último año [18].

Esta evolución se puede observar claramente en la Figura 1-1, que muestra una extensa infraestructura instalada de tecnología 4G y el crecimiento de la infraestructura de 5G.




Figura 1-1 Evolución del número de estaciones base por tecnología [18]

Esta densa malla de transmisores, a menudo instalados en emplazamientos compartidos para reducir costes, garantiza una cobertura electromagnética casi continua en los núcleos urbanos. Para un sistema de radar pasivo, esta situación es extremadamente ventajosa. No solo garantiza el funcionamiento del sistema al disponer de múltiples iluminadores de oportunidad, sino que también abre la puerta a técnicas avanzadas de fusión de datos que combinan la información de varios transmisores para mejorar la precisión y la fiabilidad de la detección.

1.2.MOTIVACIÓN Y OBJETIVOS

Según la Agencia Estatal de Seguridad Aérea (AESA) en el año 2024 se registraron más de 25.500 nuevos operadores de UAS, llegando a un total de casi 120.000 operadores de sistemas de aeronaves no tripuladas, lo que supone un incremento del 20% en un año. Al ser este el número de operadores registrados, se estima que el número de UAS es notablemente mayor, a pesar de las restricciones y normativas impuestas por las autoridades en los últimos años. Estos sistemas suponen una amenaza real para la seguridad en determinados escenarios, especialmente donde existen aglomeraciones de personas, por su posible uso hostil o negligente. Además, en el ámbito de la defensa, ha quedado patente la letalidad de estos sistemas de bajo coste en la guerra de Ucrania y la necesidad de su temprana detección para la adopción de medidas de protección y defensa contra ellos.

La necesidad e interés por la detección de objetos en el entorno ha sido una constante a lo largo de la historia, especialmente en contextos donde la vigilancia, la defensa y la seguridad juegan un papel fundamental. En el último siglo, el desarrollo de tecnologías cada vez más avanzadas, con blancos dotados de mayor maniobrabilidad y características *stealth* que reducen su firma electromagnética, ha impulsado la búsqueda de nuevas arquitecturas radar capaces de superar estas limitaciones. En este sentido, los sistemas radar pasivos y multiestáticos parecen ser una alternativa prometedora. Además, el crecimiento tan notable en el despliegue de infraestructuras de telecomunicaciones, como redes móviles, especialmente en entornos urbanos, ha abierto una oportunidad única para aprovechar estas señales como iluminadores de oportunidad. Esto permite diseñar sistemas de detección pasivos, de bajo coste y altamente adaptables a escenarios civiles.

El estudio de estos escenarios y posibles despliegues reales en ciudades motiva el análisis de diferentes configuraciones que optimicen su operación. Así mismo, la detección de objetivos no es suficiente, sino que es imprescindible realizar un seguimiento de los objetivos detectados para asegurar su identificación y neutralización en caso de resultar una amenaza. Esto se consigue a través de algoritmos de seguimiento capaces de estimar y predecir la trayectoria de los objetivos. Además, facilitan la discriminación de múltiples objetivos y descartar blancos fantasmas que se producen por la complejidad debida a la configuración multiestática y las múltiples detecciones que se obtienen en cada par transmisor-receptor. Estos filtros se hacen indispensables en casos con varios objetivos donde la asociación de pistas y detecciones se convierte en una tarea mucho más compleja y la predicción del siguiente estado del objeto reduce significativamente la incertidumbre de asociación.

Las ecuaciones que modelan la localización de objetivos en escenario multiestáticos no siguen una relación lineal entre el espacio de medida y el espacio del estado del objetivo, por lo tanto, el empleo de filtros de seguimiento lineales, como el de Kalman, no aseguran una óptima operación en estos escenarios. Otros filtros de seguimiento como el filtro extendido de Kalman (EKF) o el filtro de partículas se pueden aplicar en estos escenarios. Dada la geometría especial de los sistemas multiestáticos y el interés emergente en el desarrollo de sistemas de vigilancia pasivos basados en las redes de comunicaciones móviles en entornos urbanos, se considera relevante el análisis y evaluación de estos algoritmos de seguimientos en estos escenarios de aplicación.

Por ello, el objetivo principal de este trabajo es el diseño e implementación de un entorno de simulación que permita evaluar el desempeño de algoritmos de seguimiento en sistemas radar multiestáticos pasivos, con especial énfasis en escenarios de vigilancia urbana. A diferencia de otros estudios centrados en el procesamiento de señal, aquí se parte de detecciones ya extraídas, de modo que el foco se sitúa en la fase de procesamiento de datos y seguimiento: localización, predicción, corrección y asociación de medidas en entornos complejos y con múltiples objetivos. Este planteamiento busca responder a la

creciente necesidad de soluciones de vigilancia, localización y seguimiento en ciudades, donde el despliegue masivo de infraestructura de telecomunicación ofrece una oportunidad única para aprovechar señales de oportunidad como iluminadores.

A partir de este objetivo general, se plantean los siguientes objetivos específicos:

- Revisar el estado del arte de los radares pasivos y multiestáticos, con especial atención a sus aplicaciones en vigilancia urbana.
- Implementar un entorno de simulación en MATLAB que reproduzca arquitecturas multiestáticas urbanas, considerando estaciones base de comunicaciones móviles como transmisores, receptores distribuidos, múltiples dinámicas de blancos y diferentes configuraciones geométricas.
- Analizar el impacto de la geometría del despliegue en la precisión de la localización.
- Implementar y comparar distintos algoritmos de seguimiento, incluyendo la aplicación del filtro de Kalman lineal, filtros no lineales (EKF y UKF) y el filtro de partículas en configuraciones multiestáticas, evaluando su precisión, convergencia y coste computacional.
- Evaluar el efecto de parámetros clave del sistema, como el ruido de proceso, el ruido de medida o el tiempo de integración, sobre el rendimiento global de los algoritmos de seguimiento.
- Estudiar el comportamiento de los algoritmos frente a problemas de asociación de medidas, como la aparición de blancos fantasma y escenarios multiobjetivo, incorporando criterios adicionales como el ángulo de llegada para mejorar la robustez.
- Extraer conclusiones sobre la viabilidad de arquitecturas radar pasivas multiestáticas para la vigilancia aérea en entornos urbanos y proponer posibles líneas futuras de investigación.

1.3. ESTRUCTURA Y METODOLOGÍA

El trabajo se ha estructurado en cinco capítulos. El primer capítulo recoge la introducción, los objetivos y la metodología general empleada, mientras que el segundo capítulo presenta una revisión del estado del arte, estableciendo así el marco de referencia necesario para contextualizar el estudio. El tercer capítulo presenta los fundamentos del sistema, centrándose en la comprensión de los radares biestáticos, en la arquitectura del procesado de datos radar y en el análisis de los diferentes filtros de seguimiento considerados, además de los modelos dinámicos asumidos para la estimación y predicción de trayectorias. El cuarto capítulo aborda el desarrollo del entorno de simulación implementado en MATLAB, donde se incluye tanto la localización en sistemas multiestáticos como el seguimiento de objetivos y, finalmente, el proceso de asociación de detecciones; en esta sección también se analizan los resultados obtenidos para los distintos escenarios de simulación. El quinto y último capítulo está

dedicado a la exposición de las conclusiones extraídas del trabajo y a la propuesta de posibles líneas de investigación futura.

La metodología que se ha seguido para este trabajo ha sido comenzar por el estudio de los radares biestáticos a través de referencias bibliográficas para revisar los fundamentos de este tipo de sistemas. Una vez analizada la configuración y problemática de los radares multiestáticos, se implementó un marco de trabajo con varios programas en MATLAB para el desarrollo de entornos de simulación y evaluación de errores en diferentes escenarios multiestáticos basándose en el método de Monte Carlo. Posteriormente se analiza en estos escenarios el seguimiento de objetivos simulados y sus trayectorias, para poder analizar el comportamiento de los distintos algoritmos de seguimiento. Por último, se presentan las conclusiones extraídas.

1.3.1. MÉTODO MONTE CARLO

El método de Monte Carlo [19] constituye un conjunto de técnicas numéricas fundamentadas en la generación de variables aleatorias para la resolución de problemas matemáticos y de ingeniería. Su origen se remonta a los trabajos realizados durante la década de 1940 en el laboratorio de Los Álamos, en el contexto del desarrollo de armas nucleares. Fue en ese entorno donde científicos como Stanislaw Ulam y John von Neumann comenzaron a explorar el uso de juegos de azar simulados como herramientas para analizar fenómenos complejos. El nombre "Monte Carlo" se inspiró en la famosa ciudad europea asociada al juego y el azar, reflejando la esencia aleatoria del método.

A pesar de su naturaleza aparentemente poco rigurosa, basada en el muestreo aleatorio, los métodos Monte Carlo ofrecen una aproximación potente y generalizada para resolver problemas que involucran integrales, propagación de incertidumbre o evolución de sistemas estocásticos. Su eficacia se incrementa notablemente con el uso de ordenadores, que permiten realizar miles o millones de simulaciones independientes para obtener estimaciones precisas con control estadístico del error. Una característica distintiva del método Monte Carlo es su aplicabilidad a problemas de alta dimensionalidad, donde los métodos deterministas resultan ineficaces o computacionalmente inviables [20].

En este trabajo se abordan simulaciones de trayectorias de objetivos móviles y su estimación mediante filtros de seguimiento en un entorno de radar multiestático. En este contexto, tanto las mediciones como el modelo dinámico del sistema están sujetos a incertidumbres. Las distancias biestáticas observadas están afectadas por ruido de medición, y el comportamiento dinámico del objetivo puede presentar desviaciones respecto al modelo teórico.

Con el fin de evaluar de forma robusta el rendimiento de los algoritmos de seguimiento propuesto, se ha implementado una simulación Monte Carlo con múltiples iteraciones independientes. En cada

iteración, se introduce una nueva realización del ruido de medida en las distancias biestáticas, utilizando una función de generación de ruido gaussiano. Esta aleatorización busca reflejar el comportamiento estadístico realista del sistema bajo perturbaciones, permitiendo estimar el error de posicionamiento medio, la dispersión y la estabilidad del filtro.

Este enfoque adoptado permite evaluar el rendimiento de los algoritmos de seguimiento no sólo en un caso ideal, sino en múltiples condiciones. Esta metodología proporciona una medida más representativa del comportamiento del sistema ante variabilidad en las mediciones. Esta capacidad para modelar procesos estocásticos y cuantificar sus resultados mediante simulaciones repetidas es una de las razones clave por las que el método de Monte Carlo se ha convertido en una herramienta muy útil.

2. ESTADO DEL ARTE

Actualmente, existen en el mercado algunos productos y desarrollos basados en la tecnología de radar pasivo, y son cada vez más los proyectos en las empresas que buscan implementar arquitecturas multiestáticas en sus sistemas de detección radar. A continuación, se presentan algunos productos, iniciativas y proyectos relacionados con estas tecnologías.

La compañía alemana HENSOLDT cuenta con un producto llamado “Twinvis”, que se muestra en la Figura 2-1 [21]. Es un sistema de radar pasivo diseñado para la vigilancia aérea de objetivos que utiliza múltiples transmisiones VHF y UHF existentes de radio analógica (FM) y digital (DAB, *Digital Audio Broadcasting*), así como de televisión DVB-T [22]. En cuanto a sus capacidades técnicas, Twinvis puede detectar hasta 200 objetivos simultáneamente con una cobertura de 360 grados en azimut y realizar su seguimiento en tres dimensiones. Su alcance depende del tipo de señal utilizada y del escenario operativo, aunque se han reportado detecciones de blancos aéreos a distancias biestáticas superiores a 100 km. A su vez, la distancia entre el sensor y los transmisores de oportunidad puede ir desde unos pocos kilómetros hasta más de cien kilómetros. El sistema proporciona una precisión horizontal mejor que 500 metros en el 90% de los casos, y una precisión en altitud mejor que 1.000 metros en el 70% de los casos. En términos de procesado es capaz de realizar fusión en tiempo real de hasta 16 transmisores FM, 5 DAB y 5 DVB-T, consiguiendo una tasa de actualización de las trazas inferior a 1 segundo [21].

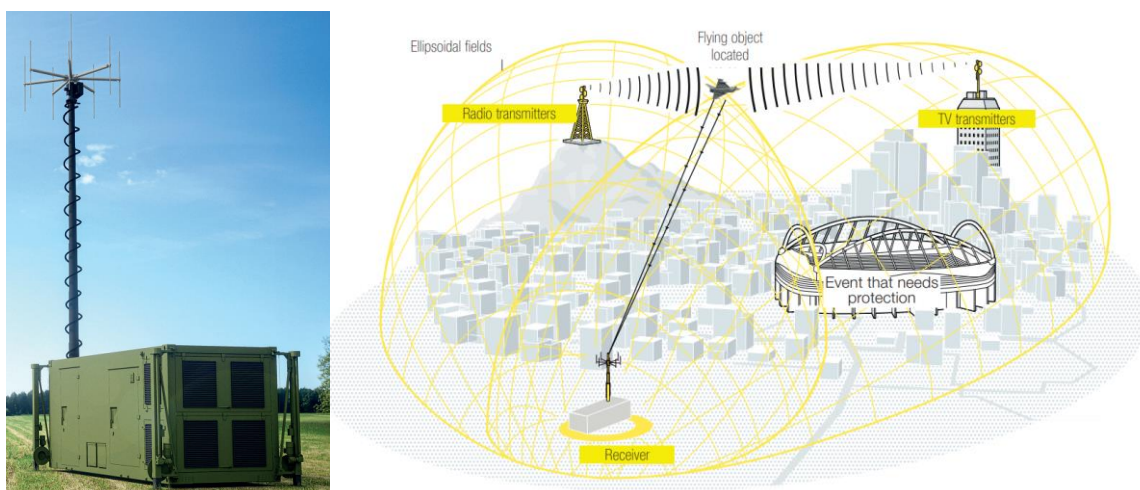


Figura 2-1 Hensoldt Twinvis - Passive Radar [21]

El programa *Future Combat Air System* (FCAS), desarrollado conjuntamente por Francia, Alemania y España, no solo constituye la apuesta europea por un sistema de combate aéreo de la llamada sexta generación, sino que también representa un ejemplo paradigmático del potencial de las arquitecturas radar multiestáticas. En su núcleo, el programa busca integrar cazas tripulados de nueva generación (NGF), vehículos aéreos no tripulados (*Remote Carriers*) y la infraestructura digital denominada *Combat Cloud*, que permite el intercambio de información y la fusión de datos en tiempo real. En este contexto, el pilar de sensores, liderado por Indra, Thales y el consorcio FCMS, se centra en el desarrollo de redes distribuidas de sensores y radares, concebidas explícitamente para operar en configuraciones multiestáticas. Este enfoque permite que múltiples plataformas, tanto aéreas como terrestres o navales, actúen simultáneamente como nodos de transmisión y recepción, generando una red cooperativa que incrementa de forma notable la redundancia, la cobertura angular y la resistencia frente a intentos de interferencia o detección enemiga [23].

La Figura 2-2 ilustra este concepto: aeronaves y nodos terrestres intercambian información y generan zonas de detección solapadas, lo que refleja cómo la configuración multiestática aumenta la robustez y la precisión del sistema frente a blancos de baja sección radar o en escenarios complejos. Esta capacidad de detección distribuida no solo mejora la conciencia situacional global, sino que también potencia la supervivencia de la red, ya que la pérdida de un nodo no compromete el funcionamiento del sistema en su conjunto. De este modo, el FCAS no se limita a ser un programa de desarrollo aeronáutico, sino que constituye una apuesta por llevar el concepto de radar multiestático a su máxima expresión, combinando plataformas heterogéneas en una arquitectura cooperativa orientada a los retos de la guerra electrónica y los entornos altamente disputados del futuro.



Figura 2-2 Arquitectura conceptual de la red cooperativa de sensores del FCAS [23]

Otro de los proyectos europeos más relevantes en el ámbito de radares multiestáticos es *iFURTHER* (*High Frequency over The Horizon sensors' cognitivE netwoRk*), financiado por la Unión Europea a través del Fondo Europeo de Defensa. Este programa tiene como objetivo desarrollar una red cognitiva de radares HF *Over-The-Horizon* (HF-OTH-R) interconectados, capaz de proporcionar una capacidad

disruptiva de detección y alerta temprana frente a amenazas aéreas y marítimas. A diferencia de los radares convencionales, cuya cobertura se limita a la línea de visión, los radares OTH en banda HF (3-30 MHz) aprovechan la propagación ionosférica y de onda superficial para detectar objetivos a cientos o miles de kilómetros, lo que permite cubrir vastas áreas del territorio europeo y su espacio marítimo asociado. El enfoque multiestático y distribuido del proyecto facilita no solo incrementar la cobertura, sino también mejorar la localización y el seguimiento de objetivos difíciles de detectar, como drones de baja firma radar, aeronaves *stealth* o misiles hipersónicos, cuya proliferación ha puesto de manifiesto la necesidad de sistemas de alerta temprana con capacidad de reacción suficiente. En la Figura 2-3, se muestra un esquema conceptual del funcionamiento de esta arquitectura: un transmisor HF emite una señal que, tras incidir en la ionosfera, es reflejada y recibida en múltiples nodos distribuidos a centenares de kilómetros de distancia.




Figura 2-3 Esquema conceptual de la red multiestática de radares HF en el proyecto iFURTHER [24]

Además, iFURTHER contempla escenarios híbridos que combinan propagación ionosférica y de superficie, ampliando así las capacidades de vigilancia tanto aérea como marítima. El consorcio, integrado por 17 socios de 9 países europeos entre los que se encuentran ONERA, Fraunhofer FHR, CNIT, INDRA o la Universidad de Alcalá, refleja la importancia estratégica de este proyecto y su vocación de convertirse en la base de una futura red paneuropea de radares OTH. Gracias a este carácter colaborativo, iFURTHER puede considerarse como un pilar esencial en la hoja de ruta europea hacia una vigilancia persistente, resiliente y de gran alcance, complementando programas como el FCAS o el AFSC (*Alliance Future Surveillance and Control*) de la OTAN (Organización del Tratado del Atlántico Norte) y reforzando la autonomía estratégica en materia de defensa [24].

Por otro lado, más enfocado al sector espacio, el sistema GESTRA (*German Experimental Space Surveillance and Tracking Radar*) es una plataforma de radar experimental desarrollada por el instituto Fraunhofer FHR por encargo de la Agencia Espacial Alemana DLR. Su objetivo principal es la

vigilancia y el seguimiento de objetos en la órbita terrestre baja (LEO), incluyendo satélites y basura espacial. Una de las características distintivas de GESTRA es su capacidad para operar en configuraciones multiestáticas, lo que representa un avance significativo en la observación espacial. Uno de los principales enfoques de su evolución es la transición de un sistema monoestático hacia el uso de redes cooperativas de radares *phased-array*, que permiten operar en configuración multiestática mediante múltiples caminos de señal biestáticos y monoestáticos. Este enfoque posibilita la observación simultánea de objetos desde distintos ángulos de aspecto, lo que proporciona una mayor diversidad de información y redundancia de detección [25].

Una de las tecnologías emergentes más prometedoras en el contexto de la próxima generación de redes móviles (6G) es la *Integrated Sensing and Communication* (ISAC), también conocida como *Joint Communication and Sensing* (JCAS). Esta tecnología permite reutilizar la infraestructura y el espectro ya desplegado para comunicaciones móviles para integrar funciones de teledetección (*sensing*), permitiendo que las redes móviles detecten, localicen y rastreen objetos pasivos y no cooperativos (es decir, que no están conectados a la red), extendiendo así su funcionalidad más allá de la mera transmisión de datos. En el ámbito de la vigilancia y la defensa, esto ofrece una ventaja significativa al permitir la detección encubierta de objetos mediante redes distribuidas que actúan como sistemas radar multiestáticos cooperativos. ISAC puede ser implementado en diferentes niveles de integración, desde el simple uso compartido de emplazamientos físicos hasta la reutilización total del espectro, hardware e incluso las formas de onda entre las funciones de comunicación y teledetección. A nivel de procesamiento, ISAC se basa en principios similares a los del radar *pulse-Doppler*, aplicando técnicas basadas en la correlación entre las señales transmitidas y recibidas implementadas mediante transformadas rápidas de Fourier (FFT) en dos dimensiones para estimar tanto la distancia como la velocidad de los objetos detectados. A su vez, la dirección en la que se encuentran los objetos detectados se determina a través de técnicas de procesamiento de señal como el *beamforming* (conformado de haces) digital [26] o algoritmos de estimación de ángulo de llegada [27].

En cuanto a las amenazas que se pretenden detectar en escenarios urbanos, en la última década, el uso de vehículos aéreos no tripulados (UAVs) pequeños y de alta maniobrabilidad, especialmente multirrotores de clase comercial y plataformas FPV (*first-person view*), ha pasado de ser un fenómeno marginal para convertirse en un factor central de la vigilancia, el reconocimiento y, cada vez más, del combate en entornos urbanos y semi-urbanos. Además, su detección es compleja debido a su baja firma acústica y térmica, su reducida RCS, y su vuelo estacionario con capacidad de volar entre obstáculos y por guiado visual directo por parte del operador (FPV), que los hace especialmente adecuados para operar en calles estrechas, patios interiores o entre edificaciones, donde los sensores tradicionales encuentran limitaciones geométricas y de línea de visión.

La guerra en Ucrania ha actuado como catalizador y laboratorio abierto de estas tecnologías. En el frente se observa un uso masivo y cotidiano de cuadricópteros comerciales modificados, drones FPV de bajo coste y municiones merodeadoras, con una gran velocidad de innovación. Informes periodísticos y de análisis [28] coinciden en que los FPV baratos, equipados con cámaras y cargas útiles ligeras, han alterado tanto la forma de maniobrar como la exposición de vehículos y personal, multiplicando la observabilidad del campo de batalla y forzando a la dispersión y a la cobertura constante.

Además, diversas fuentes apuntan a que los desarrollos han basculado a favor de sistemas COTS (*Commercial Off-The-Shelf*) y software reconfigurable explotando al máximo componentes comerciales, motores, cámaras, enlaces digitales, GNSS, e iterando rápidamente en la configuración de los drones para roles ISR (*Intelligence, Surveillance, Reconnaissance*), ataque FPV y guiado de artillería. Este carácter COTS y la modularidad del software explican tanto la rapidez de adaptación de los operadores como la obsolescencia acelerada de contramedidas, especialmente en radios y protocolos de control. Para los entornos urbanos, donde el espectro está congestionado y el multitrayecto es la norma, esta elasticidad tecnológica es crítica: pequeños cambios de frecuencia, potencia o modulación pueden alterar drásticamente la detectabilidad y el alcance de control [29]. En este contexto, los sistemas radar multiestáticos pasivos surgen como una solución especialmente prometedora, ya que al no depender de emisores propios aprovechan la infraestructura existente y no pueden ser detectados como una amenaza activa, lo que les otorga una mayor discreción frente a sistemas de contramedidas electrónicas. Además, su diversidad espacial incrementa la probabilidad de detección y mejora la precisión de localización en escenarios urbanos densos, donde otros sensores encuentran limitaciones significativas.

3. FUNDAMENTOS DEL SISTEMA

3.1. PRINCIPIOS DE LOS RADARES BIESTÁTICOS

Un radar biestático es un sistema radar en el que el transmisor y el receptor están ubicados en posiciones físicas separadas. Esta configuración introduce una geometría particular que impacta en las principales variables observables: distancia biestática, velocidad biestática, ángulo de llegada y sus respectivas resoluciones. Estos aspectos son fundamentales para interpretar correctamente las mediciones en radares biestáticos.

3.1.1. ARQUITECTURA BIESTÁTICA

Los sistemas radar pasivos generalmente están equipados con al menos dos canales de recepción: el canal de referencia y el canal de vigilancia, como se representa en la Figura 3-1. Ambos canales adquieren señales provenientes de una misma fuente emisora, pero con trayectorias diferentes:

- El canal de referencia recibe la señal directa transmitida por el iluminador. Para ello, se utiliza una antena direccional apuntada hacia el transmisor, o bien se genera digitalmente un haz enfocado mediante técnicas de formación de haces (*beamforming*). Esta señal representa idealmente una muestra de la señal original transmitida sin ser afectada por multitrayectos. En radares biestáticos en los que el transmisor es cooperativo, se conoce la forma de onda transmitida y el transmisor y el receptor se encuentran sincronizados, el receptor podría generar localmente una copia de la misma sin necesidad de un canal de referencia.
- El canal de vigilancia capta la señal reflejada por los objetos presentes en la zona de observación. Es esta señal la que contiene la información sobre la presencia, posición y movimiento de los objetivos. En este canal, se emplea una antena orientada hacia la zona que se pretende vigilar y es la fuente de la señal reflejada.




Figura 3-1 Arquitectura general de un sistema radar biestático pasivo

La detección de objetivos se basa en comparar ambas señales de referencia y vigilancia mediante la correlación cruzada en base a la aplicación del filtro adaptado. Dado que la señal reflejada ha recorrido una mayor distancia (transmisor-objetivo-receptor), presenta un retardo respecto a la señal directa. Este retardo diferencial permite estimar la distancia biestática, que corresponde al exceso de recorrido respecto al trayecto directo. Además, si el blanco presenta movimiento, se produce un efecto Doppler que da lugar a un desplazamiento en la frecuencia del eco recibido respecto a la señal directa. Esta diferencia de frecuencia también puede medirse por comparación para estimar la velocidad biestática.

Esta comparación se realiza mediante el procesamiento de correlación en dos dimensiones (retardo y frecuencia Doppler) entre la señal de referencia y la señal de vigilancia. Este proceso se implementa habitualmente a través de la llamada función de ambigüedad cruzada (CAF, *Cross-Ambiguity Function*) [30].

3.1.2. GEOMETRÍA

La geometría biestática describe la configuración espacial entre el transmisor (T_x), el objetivo y el receptor (R_x). En este contexto, el objetivo se localiza en una posición $(x(t), y(t), z(t))$, mientras que el transmisor y el receptor se ubican respectivamente en (x_{tx}, y_{tx}, z_{tx}) y (x_{rx}, y_{rx}, z_{rx}) . Esta disposición genera dos trayectorias principales para la propagación de la señal:

- La trayectoria directa, entre transmisor y receptor (longitud de línea base R_b).

- La trayectoria indirecta, que involucra la señal que va del transmisor al objetivo y luego al receptor, con longitudes $R_1(t)$ y $R_2(t)$ respectivamente.

La distancia biestática o rango biestático $R(t)$ se define como:

$$R(t) = R_1(t) + R_2(t) - R_b$$

Las distancias mencionadas se ilustran en la Figura 3-2.

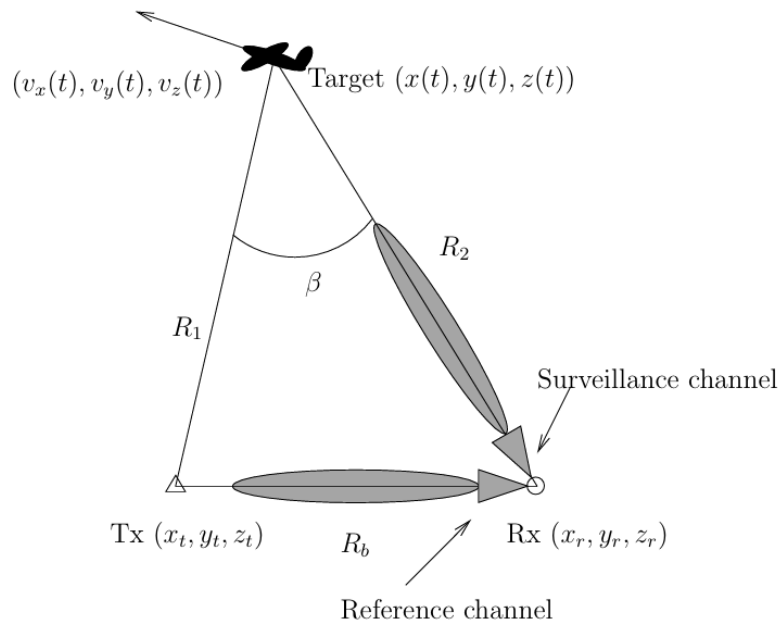


Figura 3-2 Geometría biestática [30]

Este rango representa el exceso de distancia que recorre la señal reflejada respecto a la señal directa, y es clave en la estimación de la posición del objetivo. Dado que las señales viajan a la velocidad de la luz (c), el retardo medido entre los canales de referencia y vigilancia está relacionado con la distancia biestática por:

$$\tau = \frac{R(t)}{c}$$

El conjunto de puntos que comparten la misma distancia biestática forma una elipse (en dos dimensiones) o un elipsoide (en tres dimensiones), cuyos focos están ubicados en el transmisor y el receptor. Esta familia de curvas o superficies se denominan elipses o elipsoides biestáticos, y cada uno representa un isorrango, es decir, una curva o superficie donde la diferencia de trayectorias es constante.

DISTANCIA BIESTÁTICA Y RESOLUCIÓN

La distancia biestática es la magnitud más directamente observable en un sistema radar biestático. Como se ha visto, se calcula como la suma de las distancias desde el transmisor al objetivo y del objetivo al receptor, menos la distancia directa entre el transmisor y el receptor. Estas distancias se ilustran en la Figura 3-3, que muestra específicamente la geometría biestática en dos dimensiones y la elipse biestática asociada a la posición del objetivo con sus respectivos focos localizados en el transmisor y el receptor.

$$R_{biestatico} = R_{Tx-Tgt} + R_{Tgt-Rx} - R_{Tx-Rx}$$




Figura 3-3 Esquema de la geometría biestática en dos dimensiones

La resolución en distancia biestática, o la capacidad del sistema para distinguir dos objetivos próximos en distancia, depende directamente del ancho de banda (B) de la señal utilizada:

$$\Delta R = \frac{c}{B}$$

No obstante, debido a la geometría elíptica del sistema, la resolución efectiva en distancia se proyecta en la dirección ortogonal al contorno de la elipse en el punto donde se encuentra el objetivo. Esto introduce un factor de corrección angular, relacionado con el ángulo biestático (β):

$$\Delta R_{efectiva} = \frac{c}{2 B \cos\left(\frac{\beta}{2}\right)}$$

Cuanto mayor es el ancho de banda y menor es el ángulo biestático, mejor será la capacidad del sistema para separar objetivos en el eje de distancias [31].

VELOCIDAD BIESTÁTICA Y RESOLUCIÓN DOPPLER

La velocidad biestática es la derivada temporal de la distancia biestática. Representa la rapidez con que cambia la trayectoria total que recorre la señal reflejada y, asumiendo que el transmisor y el receptor se encuentran estáticos, se calcula como:

$$v_{biestatico} = \vec{v}_{Tgt} \cdot \left(\frac{\vec{r}_{Tgt} - \vec{r}_{Tx}}{\|\vec{r}_{Tgt} - \vec{r}_{Tx}\|} - \frac{\vec{r}_{Rx} - \vec{r}_{Tgt}}{\|\vec{r}_{Rx} - \vec{r}_{Tgt}\|} \right)$$

Donde \vec{v}_{Tgt} es la velocidad del objetivo y \vec{r}_{Tx} , \vec{r}_{Rx} y \vec{r}_{Tgt} son los vectores de posición del transmisor, receptor y objetivo respectivamente.

Este valor se obtiene a través de la frecuencia Doppler, que en radares biestáticos se relaciona con la velocidad biestática por:

$$f_D = -\frac{v_{biestatico}}{\lambda}$$

donde λ es la longitud de onda de la señal portadora.

La resolución en frecuencia Doppler, es decir, la capacidad para discriminar objetivos que se mueven con velocidades biestáticas ligeramente diferentes, está determinada por el tiempo de integración coherente (T_{int}):

$$\Delta f_D = \frac{1}{T_{int}}$$

$$\Delta v_{biestatico} = \frac{\lambda}{T_{int}}$$

Un mayor tiempo de integración mejora la resolución en velocidad, pero introduce posibles distorsiones si los objetivos realizan maniobras bruscas o si se desplazan a gran velocidad, ya que durante el intervalo considerado para el procesamiento coherente se asume generalmente una velocidad constante del blanco y que se encuentra en una misma celda de resolución en distancia.

ÁNGULO DE LLEGADA

El ángulo de llegada (*Angle of Arrival*, AoA) representa una métrica complementaria, pero no fundamental, dentro de la arquitectura de un radar biestático. A diferencia de la distancia biestática o de la frecuencia Doppler, que son parámetros directamente derivados de la señal transmitida y reflejada, el AoA se estima exclusivamente en el receptor, y su incorporación proporciona una medida adicional

que permite refinar la localización del objetivo y resolver ambigüedades propias de la geometría elipsoidal de los radares biestáticos.

En particular, dado que el conjunto de puntos (en el espacio) que tienen el mismo retardo biestático forman una elipse (o un elipsoide en 3D), un objetivo puede hallarse en cualquier punto a lo largo de dicha curva si solo se dispone del retardo (distancia biestática). Sin embargo, si se estima el ángulo de llegada de la señal reflejada, se introduce una restricción angular que reduce el conjunto de soluciones posibles, contribuyendo así a una localización más precisa del objetivo.

Para obtener esta estimación angular, se emplean habitualmente *arrays* de antenas en el canal de vigilancia del receptor. Estos *arrays* permiten aplicar técnicas como el *beamforming* digital o algoritmos de estimación de dirección de llegada, que discriminan el ángulo con el que la señal reflejada alcanza el sistema. Este tipo de configuración convierte al receptor en un sistema espacialmente selectivo, capaz de identificar la dirección de las señales reflejadas.

3.1.3. EXTENSIÓN MULTIESTÁTICA

Una extensión natural de la arquitectura biestática es la configuración multiestática, en la que múltiples transmisores y/o receptores se emplean para observar simultáneamente una misma región. En este esquema, cada par transmisor-receptor genera su propio conjunto de elipses biestáticas (o elipsoides en 3D), determinadas por el conjunto de puntos de igual retardo entre la señal transmitida y la recibida tras la reflexión en el objetivo.

La localización del objetivo puede entonces realizarse mediante técnicas de multilateración basadas en la intersección de múltiples elipsoides definidos por distintos pares. Este enfoque no solo mejora la precisión y robustez de la estimación, sino que también permite evitar zonas de sombra o interferencias, ampliar la cobertura espacial y mejorar el seguimiento de objetivos móviles mediante la fusión de observaciones independientes.

Una configuración habitual en sistemas radar pasivos es contar con un único receptor y múltiples transmisores, lo que implica que todos los elipsoides generados comparten un foco común (la posición del receptor). En este caso, la intersección de tres o más elipsoides permite resolver de forma única la posición del objetivo, eliminando ambigüedades inherentes a soluciones con menos pares.

La Figura 3-4 ilustra el principio geométrico de localización multiestática mediante la intersección de elipses biestáticas. En este ejemplo, se emplea un único receptor y tres transmisores. Aunque dos elipses cualesquiera pueden intersecarse en más de un punto, solo la intersección común de las tres elipses

proporciona una solución consistente para la posición del objetivo. Esta única intersección representa el punto que satisface simultáneamente los retardos observados en los tres pares.

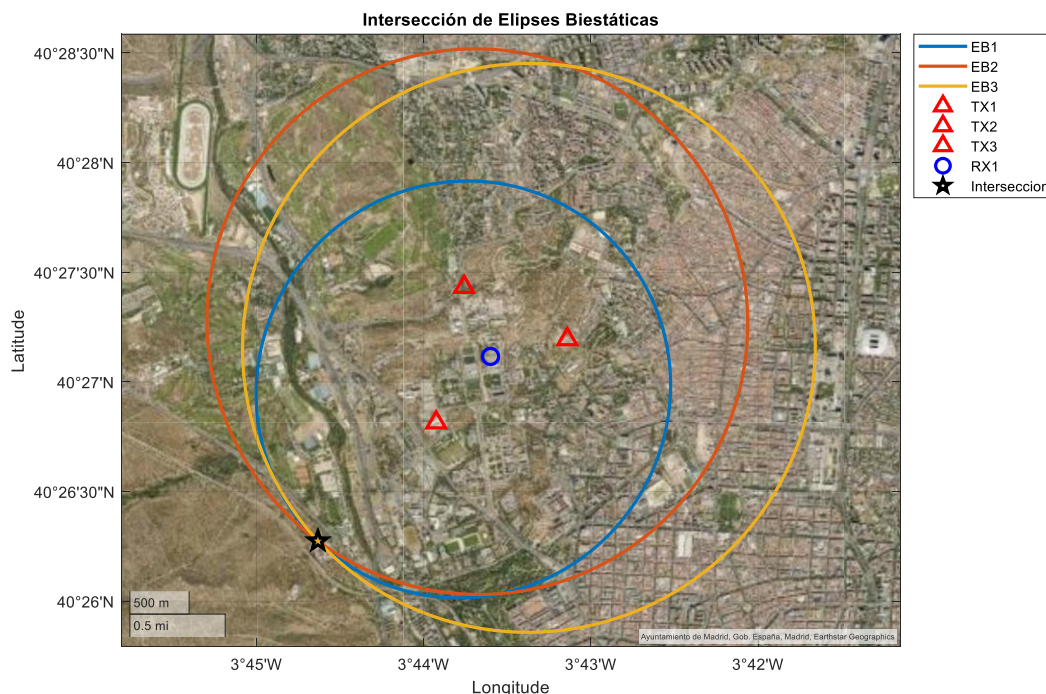


Figura 3-4 Ejemplo de intersección de elipses biestáticas en un escenario multiestático

En la práctica, los transmisores y el receptor suelen estar ubicados cerca del nivel del suelo, lo que genera una simetría aproximada respecto al plano terrestre. Como consecuencia, las intersecciones de los elipsoides suelen generar dos posibles soluciones: una correspondiente a la posición real del objetivo y otra a una solución espuria con altitud negativa, que puede descartarse por razones físicas. Además, la geometría relativa de los transmisores, el receptor y el objetivo impacta en la precisión alcanzable en su localización en relación con la denominada dilución de precisión geométrica (GDOP, *Geometric Dilution of Precision*) [32].

Adicionalmente, es posible aumentar este proceso con la estimación del ángulo de llegada (AoA) en el receptor. Esta medida angular permite restringir aún más la región de incertidumbre del objetivo al añadir una condición direccional. Combinando los elipsoides biestáticos con medidas de dirección, se reduce significativamente la ambigüedad geométrica especialmente en entornos densos o con múltiples objetivos.

3.1.4. PROCESAMIENTO DE LA SEÑAL EN RADAR BIESTÁTICO

En sistemas radar la forma estándar de evaluar las características de la señal en términos de resolución y nivel de lóbulos secundarios es la función ambigüedad. Esta puede interpretarse como la correlación de una señal consigo misma, desplazada en el tiempo y en frecuencia, y se define de la siguiente manera [5]:

$$\chi(\tau, f_d) = \int_{-\infty}^{+\infty} x(t)x^*(t - \tau)e^{j2\pi f_d t} dt$$

Por ello, el análisis de la función de ambigüedad permite evaluar distintos indicadores de desempeño del radar pasivo, tales como el nivel de lóbulos laterales, la resolución en rango y velocidad, y la presencia de posibles periodicidades.

Esta función está estrechamente relacionada con la función de ambigüedad cruzada, la cual se calcula entre la señal de referencia (x_{ref}) y la señal de vigilancia (x_{surv}) durante la operación normal de un radar pasivo con el objetivo de obtener un mapa en distancia y Doppler y detectar los objetivos a partir de los picos de esta función. Para facilitar su interpretación en contextos radar, es común expresar el retardo temporal τ y la frecuencia Doppler f_d en términos de la distancia biestática R y la velocidad relativa biestática V , utilizando las sustituciones:

$$\tau = \frac{R}{c}$$

$$f_D = -\frac{V}{\lambda}$$

Además, en aplicaciones prácticas, la función de ambigüedad se calcula sobre un intervalo de tiempo finito denominado tiempo de integración T . Considerando estas transformaciones, la expresión de la función de ambigüedad queda de la siguiente forma [30]:

$$\chi(R, V) = \int_{-T/2}^{+T/2} x_{surv}(t)x_{ref}^*\left(t - \frac{R}{c}\right)e^{-j2\pi\frac{V}{\lambda}t} dt$$

Esta limitación temporal introduce efectos que impactan directamente en el rendimiento del sistema, principalmente la aparición de lóbulos secundarios y un nivel de fluctuaciones residuales (*correlation noise floor*) incluso al considerar señales incorreladas.

El nivel medio de estas fluctuaciones, en relación con el pico principal, depende del producto tiempo-ancho de banda (BT) de la señal. A mayor BT , mejor es la relación entre el pico principal y los lóbulos secundarios, lo que se traduce en una mayor capacidad para discriminar objetivos cercanos en distancia y velocidad. No obstante, existe un compromiso: incrementar el tiempo de integración mejora la

resolución en frecuencia Doppler y la supresión de lóbulos secundarios, pero reduce la capacidad de detección y seguimiento de objetivos con maniobras rápidas, ya que su movimiento durante el intervalo T puede provocar migración entre celdas de distancia o velocidad, degradando la detección [30]. Por tanto, la elección de T constituye un compromiso de diseño clave entre resolución, sensibilidad y robustez frente a blancos con gran maniobrabilidad.

3.1.5. LOCALIZACIÓN DEL BLANCO

En los radares tradicionales de vigilancia (monoestáticos) con antena giratoria, la localización de los blancos se realiza en coordenadas cartesianas a partir de la combinación de las medidas de distancia y azimut. La medida de azimut se consigue utilizando una antena con un ancho de haz estrecho que apunta en una determina dirección y la medida de distancia se obtiene midiendo el retardo entre la transmisión y la recepción de un pulso. Este es uno de los esquemas más clásicos, aunque existen otras muchas arquitecturas en función de la forma de onda utilizada.

En el caso de la localización en sistemas multiestáticos, el proceso es más complejo. Por cada par transmisor-receptor y cada blanco detectado se obtiene una distancia biestática que se corresponde con un elipsoide con los focos situados en las posiciones de los transmisores y receptores. Como se ha comentado, en aquellos sistemas en los que receptor cuenta con un *array* de antenas es posible también determinar el ángulo de llegada, lo que permite reducir la incertidumbre de localización.

Existen múltiples configuraciones multiestáticas, aunque la más común en sistemas radar pasivos consiste en disponer de un único receptor y múltiples transmisores. Por cada par transmisor-receptor en el que se detecta un blanco, se puede formar un elipsoide biestático. Cada uno de estos elipsoides contiene posibles ubicaciones del objetivo y, por tanto, al intersecar diferentes elipsoides, es posible estimar la posición real del blanco, como se muestra en la Figura 3-5.

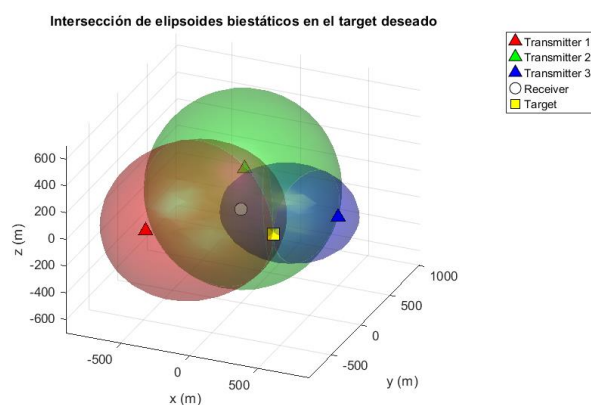


Figura 3-5 Localización del blanco mediante la intersección de elipsoides biestáticos

En general, cuando se disponen de medidas de distancia biestáticas obtenidas con más de tres pares transmisor-receptor, al estar afectadas por ruido de medida, no se producirá una intersección única de los elipsoides asociados. Por este motivo, es necesario aplicar algoritmos de localización para determinar la posición del objetivo a partir de las múltiples distancias biestáticas medidas. Estos algoritmos están normalmente basados en resolver problemas de minimización entre las distancias biestáticas medidas y las distancias biestáticas asociadas a la posición estimada.

ALGORITMOS

Para el análisis de los algoritmos de localización, se asume la geometría mostrada en la Figura 3-6, donde se puede disponer de M transmisores y N receptores distribuidos en el espacio.




Figura 3-6 Geometría de localización del objetivo para $M = 3$ transmisores y $N = 1$ receptor.

En general, para poder determinar de forma única la posición del blanco en 3D, es necesario contar con al menos tres pares transmisor-receptor con medidas independientes. Esto se debe a que la intersección de dos elipsoides no determina una única posición, sino una curva (generalmente una elipse o arco), lo que introduce ambigüedad en la localización. La incorporación de un tercer elipsoide permite resolver esta ambigüedad, al restringir la solución a un único punto (o a muy pocas soluciones posibles, dependiendo del ruido y la geometría).

Por motivos que se analizarán más adelante, en este trabajo se ha optado por restringir el análisis a un entorno bidimensional (2D).

Las posiciones de los transmisores y receptores se consideran conocidas, y se representan como:

$$\mathbf{x}_{t_i} = \begin{pmatrix} x_{t_i} \\ y_{t_i} \end{pmatrix}$$

$$\mathbf{x}_{r_i} = \begin{pmatrix} x_{r_i} \\ y_{r_i} \end{pmatrix}$$

La distancia entre el blanco y el transmisor i se calcula como:

$$R_{tx_i} = \sqrt{(x - x_{t_i})^2 + (y - y_{t_i})^2} = \|\mathbf{x} - \mathbf{x}_{t_i}\|$$

De igual forma, la distancia entre el blanco y el receptor i es:

$$R_{rx_i} = \sqrt{(x - x_{r_i})^2 + (y - y_{r_i})^2} = \|\mathbf{x} - \mathbf{x}_{r_i}\|$$

La línea base (*baseline*) del par transmisor-receptor i , denotada como R_{bi} , se define como la distancia entre el transmisor y el receptor:

$$R_{baseline_i} = \sqrt{(x_{t_i} - x_{r_i})^2 + (y_{t_i} - y_{r_i})^2}$$

Por último, se utiliza como medida la distancia biestática que es la diferencia entre el trayecto indirecto y directo, que es lo que realmente se mide en la cadena receptora cuando se mide la diferencia de tiempos de llegada entre la señal de referencia y las señales de vigilancia, y que corresponde a la diferencia entre el trayecto total y la longitud de la línea base (*baseline*):

$$R_{bistatic_i} = R_{tx_i} + R_{rx_i} - R_{baseline_i}$$

Asumiendo que la posición del blanco es una variable independiente representada por:

$$\tilde{\mathbf{x}} = \begin{pmatrix} \tilde{x} \\ \tilde{y} \\ \tilde{z} \end{pmatrix}$$

Se puede construir un vector de distancias biestáticas estimadas para todos los pares transmisor-receptor:

$$\tilde{\mathbf{r}}(\tilde{\mathbf{x}}) = \begin{pmatrix} \tilde{R}_{bistatic_{tx1-rx1}} \\ \tilde{R}_{bistatic_{tx2-rx1}} \\ \dots \\ \tilde{R}_{bistatic_{txN-rx1}} \\ \tilde{R}_{bistatic_{tx1-rx2}} \\ \dots \\ \tilde{R}_{bistatic_{txN-rxM}} \end{pmatrix}$$

La localización del objetivo se puede formular como un problema de minimización de la norma euclídea del vector de error entre las distancias biestáticas medidas \mathbf{r} y las distancias biestáticas $\tilde{\mathbf{r}}(\tilde{\mathbf{x}})$ correspondientes a la posición hipotética del objetivo $\tilde{\mathbf{x}}$. De esta forma, la localización del objetivo se plantea como un problema de optimización no lineal que consiste en encontrar la posición $\tilde{\mathbf{x}}$ que minimiza la suma de errores cuadráticos entre las medidas reales \mathbf{r} y las medidas esperadas $\tilde{\mathbf{r}}(\tilde{\mathbf{x}})$ [30]:

$$\tilde{\mathbf{x}} = \underset{\tilde{\mathbf{x}}}{\arg \min} \|\mathbf{r} - \tilde{\mathbf{r}}(\tilde{\mathbf{x}})\|^2$$

Existen distintas estrategias para abordar el problema de minimización no lineal. En este trabajo se analizarán dos enfoques: la optimización numérica y la resolución analítica.

OPTIMIZACIÓN NÚMERICA BASADA EN MÍNIMOS CUADRADOS

Se implementa utilizando la función *lsqcurvefit* de MATLAB, que permite resolver el problema de forma iterativa ajustando la posición del blanco para minimizar el error cuadrático entre las distancias biestáticas medidas y las estimadas. En términos generales, este método se basa en resolver un problema de mínimos cuadrados no lineales, que busca los coeficientes x que resuelven el problema:

$$\min_x \|F(x, xdata) - ydata\|_2^2 = \min_x \sum_i (F(x, xdata_i) - ydata_i)^2$$

Donde $xdata$ son datos de entrada, $ydata$ son las salidas observadas, y $F(x, xdata)$ es una función (modelo de medida) que relaciona los parámetros a estimar x y los datos de entrada $xdata$ con los parámetros observados y devuelve valores vectoriales o matriciales del mismo tamaño que $ydata$ [33]. En este contexto, x representa la posición estimada del blanco, $xdata$ agrupa las posiciones conocidas de los transmisores y receptores, e $ydata$ son las distancias biestáticas medidas.

Esta técnica se emplea en el trabajo para simular y evaluar las capacidades de arquitecturas multiestáticas con más de un receptor. El principal problema que presenta este enfoque es la falta de eficiencia, ya que habitualmente se requiere de numerosas iteraciones para encontrar la solución. Además, su desempeño puede verse afectado por la presencia de mínimos locales, y la solución obtenida

depende notablemente del punto inicial de la optimización, lo que puede derivar en estimaciones erróneas si no se parte de una buena aproximación inicial.

RESOLUCIÓN ANALÍTICA BASADA EN EL MÉTODO DE INTERSECCIÓN ESFÉRICA (SX)

Esta técnica, reformula el problema de minimización de un sistema de ecuaciones lineales y cuadráticas que puede resolverse de manera analítica, sin necesidad de iteraciones. En particular, el método de Intersección Esférica (*Spherical Intersection, SX*) permite calcular directamente la distancia entre el receptor y el objetivo (R_{rx_i}), y con ella estimar la posición del blanco.

El punto de partida es la expresión general que relaciona las posiciones de los transmisores con la posición del objetivo:

$$R_{si} - (x^2 + y^2 + z^2) = (x_{ti} - x_t)^2 + (y_{ti} - y_t)^2 + (z_{ti} - z_t)^2$$

que, al ser desarrollada y reordenada, conduce a una formulación matricial más compacta. Para ello, se define la matriz de posiciones de los transmisores

$$\mathbf{S} = \begin{bmatrix} x_{t1} & y_{t1} & z_{t1} \\ x_{t2} & y_{t2} & z_{t2} \\ \vdots & \vdots & \vdots \\ x_{tN} & y_{tN} & z_{tN} \end{bmatrix}$$

así como el vector auxiliar

$$\mathbf{z} = \frac{1}{2} \begin{bmatrix} x_{t1}^2 + y_{t1}^2 + z_{t1}^2 - R_{s1}^2 \\ x_{t2}^2 + y_{t2}^2 + z_{t2}^2 - R_{s2}^2 \\ \vdots \\ x_{tN}^2 + y_{tN}^2 + z_{tN}^2 - R_{sN}^2 \end{bmatrix}$$

Con estas definiciones, el sistema puede expresarse de manera compacta como

$$\mathbf{S}\mathbf{x} = \mathbf{z} + \mathbf{r}R_t$$

donde \mathbf{S} y \mathbf{z} son conocidos, mientras que \mathbf{x} (la posición del blanco) y R_t son incógnitas. Si se asume que R_t puede determinarse, la solución en el sentido de mínimos cuadrados se expresa como

$$\hat{\mathbf{x}} = (\mathbf{S}'\mathbf{S})^{-1}\mathbf{S}'\mathbf{z} + (\mathbf{S}'\mathbf{S})^{-1}\mathbf{S}'\mathbf{r}R_t$$

siempre que la matriz $\mathbf{S}'\mathbf{S}$ sea invertible, lo que requiere que la geometría de los transmisores proporcione rango completo.

Para obtener una solución cerrada, se introducen los vectores auxiliares

$$\mathbf{a} = (\mathbf{S}'\mathbf{S})^{-1}\mathbf{S}'\mathbf{z} ; \quad \mathbf{b} = (\mathbf{S}'\mathbf{S})^{-1}\mathbf{S}'\mathbf{r}$$

de modo que la posición estimada puede reescribirse como

$$\mathbf{x} = \mathbf{a} + \mathbf{b}R_t$$

Sustituyendo esta expresión en la condición $\|\mathbf{x}\|^2$ y reorganizando, se obtiene una ecuación cuadrática en R_t :

$$(\mathbf{b}'\mathbf{b} - 1)R_t^2 + 2\mathbf{a}'\mathbf{b}R_t + \mathbf{a}'\mathbf{a} = 0$$

La solución de esta ecuación se calcula de forma directa:

$$\widehat{R}_t = \frac{-2\mathbf{a}'\mathbf{b} \pm \sqrt{4(\mathbf{a}'\mathbf{b})^2 - 4(\mathbf{b}'\mathbf{b} - 1)\mathbf{a}'\mathbf{a}}}{2(\mathbf{b}'\mathbf{b} - 1)}$$

Una vez obtenida la expresión general de la posición en función de la distancia R_t , esta puede reescribirse en forma lineal, donde los vectores auxiliares \mathbf{a} y \mathbf{b} dependen únicamente de la geometría de los transmisores y de los términos conocidos del sistema. Sustituyendo esta relación en la condición de norma $\|\mathbf{x}\|^2$, se obtiene una ecuación cuadrática en la incógnita R_t , cuya resolución proporciona dos posibles soluciones. A partir de estas, se selecciona la más coherente con el escenario físico, que en la mayoría de los casos corresponde al valor que conduce a una estimación de mayor altitud, dado que los objetivos de interés en radar pasivo son generalmente objetivos aéreos como drones.

Una vez hallada la distancia R_t , esta se sustituye en la expresión lineal para obtener la estimación de la posición del blanco. La principal ventaja de este método de intersección esférica radica en que ofrece una solución cerrada y analítica al problema de localización, evitando la aparición de mínimos locales que pueden afectar a los enfoques de optimización iterativos. Además, este método es aplicable incluso en configuraciones reducidas con tan solo tres transmisores, lo que lo hace especialmente útil en arquitecturas multiestáticas pasivas donde no siempre es posible desplegar un gran número de nodos. En conjunto, se trata de una técnica robusta, eficiente y particularmente adecuada para escenarios de radar pasivo, donde la geometría de los transmisores puede ser limitada o no estar controlada de forma directa [30].

BLANCOS FANTASMA

El fenómeno de los blancos fantasmas en los sistemas radar multiestáticos representa uno de los desafíos más significativos en la localización de objetivos. Este problema surge debido a la falta de información

a priori sobre qué objetivo generó cada medición biestática, lo que obliga a considerar todas las combinaciones posibles de intersección entre los elipsoides generados por los pares transmisor-receptor. Como resultado, es común que se produzcan intersecciones espurias entre elipsoides provenientes de diferentes objetivos reales, generando así objetivos falsos conocidos como blancos fantasmas [30].

Este problema se acentúa a medida que aumenta el número de objetivos y de pares transmisor-receptor, lo cual incrementa exponencialmente el número de combinaciones a evaluar. El número total de combinaciones que se deben considerar N_{comb} se calcula como:

$$N_{comb} = (N_{targ})^{N_{inter}} \binom{N_{par}}{N_{inter}}$$

Para un caso de 5 blancos, 3 pares transmisor-receptor y 3 elipsoides intersecados, se obtiene que se deberían evaluar 125 combinaciones posibles de intersección de elipsoides.

Para mitigar esta problemática, existen varias posibles estrategias:

- Emplear adicionalmente medidas de azimut, que, aunque no sean muy precisas, permiten reducir drásticamente el número de intersecciones falsas. Para ello, se puede emplear un receptor con un array digital para conseguir una medida de azimut que reduzca esta problemática.
- Descartar objetivos con parámetros físicamente irreales como altitudes negativas o altitudes excesivamente elevadas que excedan los límites operacionales esperados.
- Realizar la asociación propia del subsistema de procesador de datos radar para realizar un seguimiento. Esto permite la inicialización de trayectorias cartesianas tentativas que se confirman solo si mantienen un comportamiento coherente con el modelo de movimiento durante un período determinado. Los blancos fantasmas tienden a divergir con el tiempo por lo que pueden descartarse.

Se ha desarrollado una simulación en MATLAB para el caso de cinco blancos, tres pares transmisor-receptor y, por tanto, tres elipses cuya intersección define las posibles posiciones. El número de combinaciones a evaluar atendiendo a la fórmula anterior sería de 27. En la Figura 3-7 se muestran las intersecciones de las elipses biestáticas correspondientes a este escenario. Las intersecciones correctas, obtenidas tras un proceso de asociación, se han señalado con un asterisco rojo.

Es importante destacar la gran cantidad de intersecciones presentes. En particular, se han resaltado con una circunferencia morada dos zonas en las que las tres elipses no se cruzan en un único punto exacto, pero sí en posiciones muy próximas. Sin un proceso de asociación adecuado, estos puntos podrían

interpretarse erróneamente como soluciones válidas, actuando como mínimos locales en la resolución mediante mínimos cuadrados y, si además la inicialización no es adecuada, podrían ser seleccionados como resultado final.

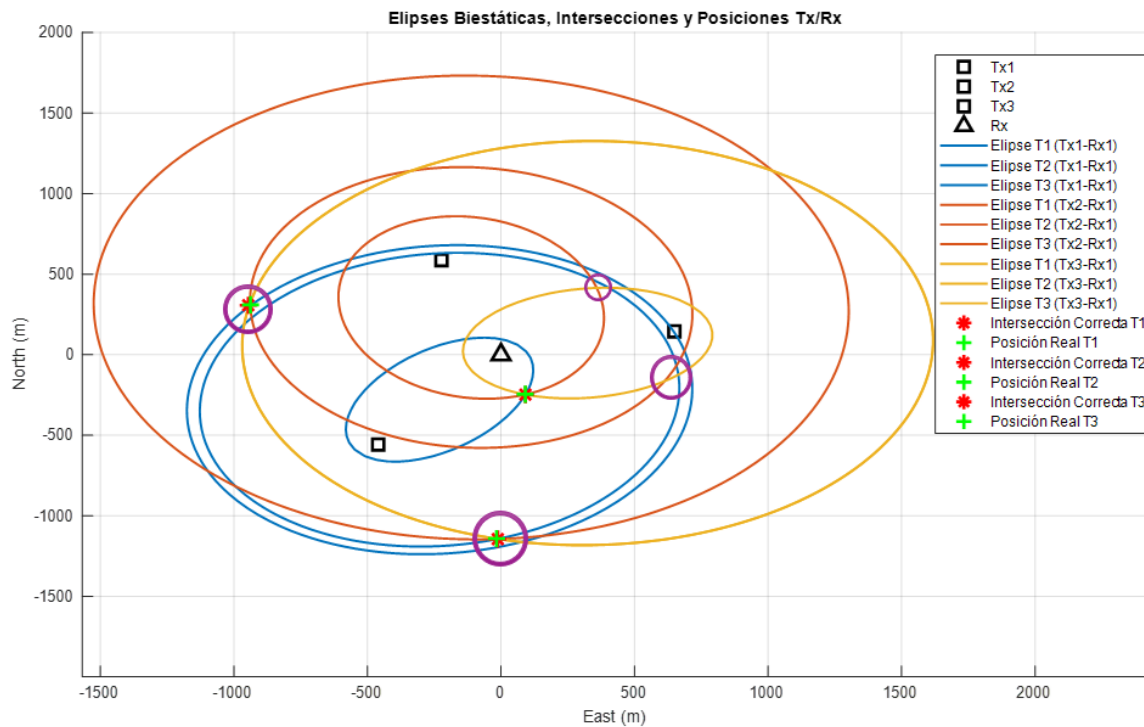


Figura 3-7 Simulación que ejemplifica la problemática de blancos fantasma

3.2. SISTEMA RADAR

Los sistemas radar están compuestos por diversos subsistemas, cada uno con funciones específicas que, en conjunto, permiten la detección, localización y seguimiento de objetivos. En primer lugar, se encuentra la cadena de transmisión y recepción, cuyo diseño depende de factores como la arquitectura del radar, ya sea monoestática o biestática, el tipo de señal utilizada, la forma de onda, entre otros parámetros de diseño. Estas señales, una vez recibidas, deben pasar por diferentes etapas de procesamiento hasta convertirse en información útil sobre los objetivos.

En primer lugar, los sistemas cuentan con el procesador de señal radar, encargado de transformar las señales recibidas en una representación más manejable para las siguientes etapas de procesamiento. La arquitectura de este procesador puede variar en función de las características del sistema, y su salida consiste en una matriz de detecciones que recoge la información básica sobre los posibles blancos identificados.

Posteriormente, la mayoría de los sistemas radar incorporan un subsistema de extracción y procesamiento de datos, encargado de convertir las detecciones generadas por el procesador de señal radar en información de mayor valor añadido para la representación y gestión de blancos. Este subsistema se puede dividir funcionalmente en dos bloques principales: el extractor de datos y el procesador de datos. La Figura 3-8 ilustra de manera esquemática el papel del procesador y del extractor de datos radar dentro de la cadena de procesamiento de los sistemas radar.




Figura 3-8 Diagrama de bloques de procesador y extractor datos radar

El extractor de datos tiene como objetivo principal filtrar y consolidar las detecciones provenientes del procesador de señal. Esta etapa se encarga de aplicar criterios de umbralización del número de detecciones obtenidas de un mismo blanco mediante agrupación espacial y temporal, así como técnicas básicas de validación para generar lo que se conoce como *plots*. Estos *plots* contienen tanto la información medida como los parámetros relacionados con la posición y velocidad (por ejemplo, para radares biestáticos, la distancia y velocidad biestática), con la intensidad de la señal (por ejemplo, la SNR), y otros parámetros que caracterizan a un posible blanco (por ejemplo, el número de detecciones agrupadas espacialmente en el *plot* que pueden estar relacionadas con el tamaño físico del blanco). El

extractor también puede incluir mecanismos para la supresión de falsos blancos, detección de interferencias o control de calidad de los datos.

Por su parte, el procesador de datos actúa sobre estos *plots* con el fin de generar *tracks* o trazas, que representan la trayectoria estimada de cada blanco a lo largo del tiempo. Para ello, emplea técnicas como el filtrado de Kalman, algoritmos de asociación de datos, así como procesos de fusión de información en caso de disponer de múltiples fuentes o sensores. Este bloque permite mantener a partir de las sucesivas medidas una estimación continua y precisa de la posición, velocidad y otros parámetros dinámicos de cada objetivo, facilitando la interpretación de la escena radar y su explotación en aplicaciones de vigilancia, navegación o defensa.

Este trabajo se centrará en el impacto que tiene una arquitectura multiestática sobre el procesador de datos, analizando los principales algoritmos, así como las consideraciones prácticas para su implementación y evaluación, a partir de los *plots* proporcionados por el extractor de datos.

3.2.1. EXTRACTOR DE DATOS

En un sistema radar monoestático, el extractor de datos se encarga de generar los *plots* a partir de la matriz de detecciones proporcionada por el procesador de señal radar. En este contexto, se entiende por *plot* la estimación de la posición de un blanco detectado, habitualmente expresada en términos de azimut y distancia (o rango).

Para la generación de estos *plots*, el extractor aplica algoritmos específicos que permiten refinar la localización del blanco a partir de la matriz de detecciones. Entre las técnicas más utilizadas se encuentran la ventana deslizante o la técnica monopulso, que permite estimar con mayor precisión la dirección del blanco a partir de comparaciones entre las señales recibidas por haces contiguos. Otras técnicas pueden incluir métodos de interpolación, cálculo del centroide o estimación de máximos, dependiendo de la resolución angular y de la arquitectura del sistema.

Una vez estimada la posición del blanco, la información se expresa en un sistema de coordenadas que puede variar según la configuración del radar y las necesidades del sistema. Habitualmente, esta información se presenta en coordenadas esféricas (azimut, elevación y distancia), aunque también puede transformarse a coordenadas cartesianas (x, y, z) para su integración con otros sensores o sistemas de mando y control.

En una arquitectura biestática, esta información varía significativamente con respecto al caso monoestático. En este tipo de configuración, el par transmisor-receptor se encuentra físicamente separado, lo que implica que las mediciones disponibles difieren en naturaleza y contenido. En

particular, el sistema no es capaz de determinar directamente una posición espacial única del blanco, como en el caso monoestático, sino que estima la distancia biestática.

Como se ha comentado previamente, esta medición no define un punto único en el espacio, sino una elipse biestática para el caso 2D, cuyos focos están situados en las posiciones del transmisor y del receptor. El blanco, por tanto, se encuentra en algún punto de esta elipse, lo que introduce una ambigüedad espacial inherente a la geometría biestática. Como resultado, a la salida del extractor de datos no se obtiene directamente una posición en coordenadas espaciales, sino la información correspondiente a la distancia biestática y, en algunos casos, parámetros adicionales como el ángulo de llegada (AoA, *Angle of Arrival*) en el receptor o la velocidad biestática, si el sistema lo permite.

Dependiendo de las capacidades del receptor y de si se dispone de información angular (por ejemplo, en sistemas con *arrays* digitales en el receptor), es posible reducir esta ambigüedad y estimar una posición aproximada del blanco en el espacio. Sin embargo, en configuraciones básicas, la salida del extractor de datos consistirá principalmente en una lista de detecciones con sus respectivas distancias biestáticas, que serán procesadas posteriormente por el procesador de datos para la estimación de trayectorias mediante diferentes técnicas.

3.2.2. PROCESADOR DE DATOS

La función principal del procesador de datos radar es la generación de pistas (*tracks*), entendidas como un conjunto de *plots* pertenecientes a un mismo blanco a lo largo del tiempo. Además de agrupar las detecciones, las pistas incluyen información derivada, como la velocidad, el rumbo, la aceleración y, en general, los parámetros dinámicos del blanco.

Los algoritmos encargados de llevar a cabo la generación y mantenimiento de las trazas a partir de las secuencias de *plots* se engloban bajo el término sistemas de seguimiento (*tracking systems*). Estos sistemas permiten mantener una estimación continua y refinada del estado de cada blanco detectado, mejorando la coherencia temporal y reduciendo la incertidumbre asociada a las mediciones individuales. La Figura 3-9 muestra la arquitectura típica de un procesador de datos radar, sobre la cual se estructura el procedimiento de seguimiento.

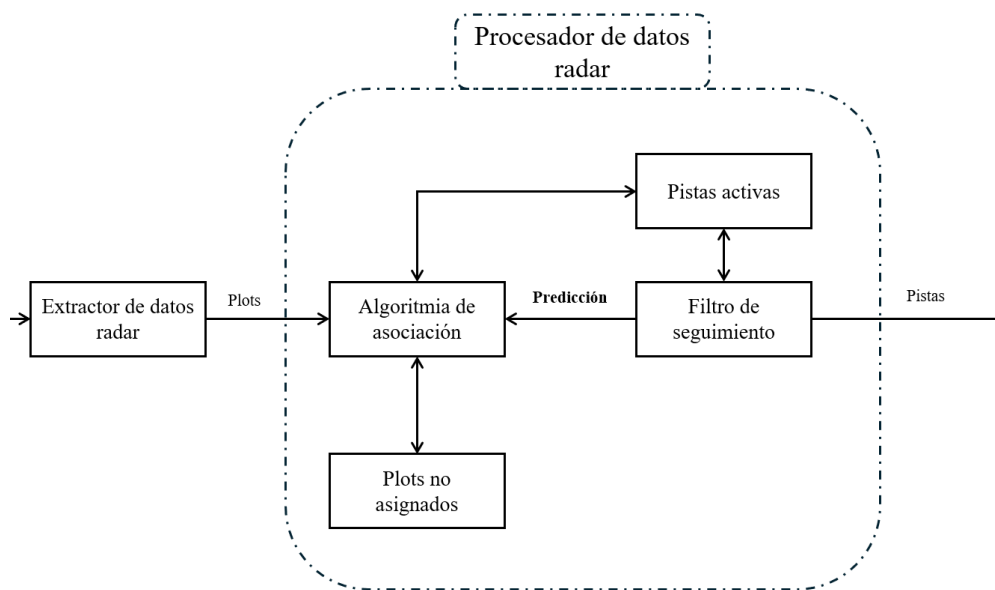
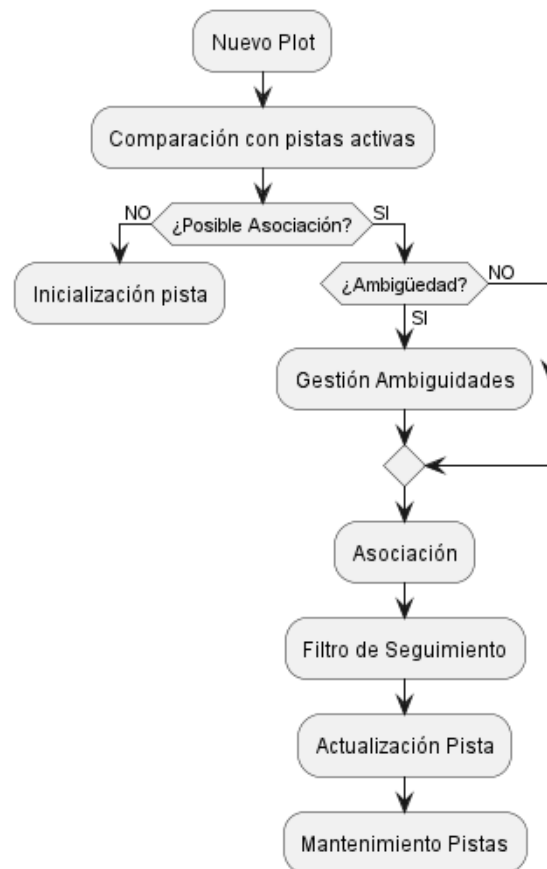


Figura 3-9 Arquitectura general de un procesador de datos radar

Los sistemas de seguimiento siguen un procedimiento compuesto principalmente por dos etapas:

1. Asociación de datos: cada vez que se recibe un nuevo *plot*, el sistema debe determinar a qué pista existente debe asociarse, o si, por el contrario, corresponde a un nuevo blanco que requiere la inicialización de una nueva pista. Esta etapa es crítica, especialmente en entornos con alta densidad de blancos o presencia de ruido
2. Filtrado: una vez asociado el *plot* a una pista, se emplea un filtro de seguimiento para actualizar la estimación del estado del blanco. El objetivo es combinar la nueva medida con estimaciones o predicciones previas para obtener una estimación más precisa, reduciendo el error y suavizando las trayectorias, además de realizar predicciones para el siguiente instante de medida.

En la Figura 3-10 se muestra el esquema general del algoritmo de seguimiento utilizado en sistemas radar. El proceso se inicia con la detección de un nuevo *plot*, que posteriormente se compara con las pistas activas existentes. En caso de no asociarse con ninguna pista activa, el *plot* se utiliza para inicializar una nueva pista de seguimiento. En caso de asociarse con una pista activa, la medida del *plot* se emplea para aplicar los algoritmos de seguimiento y actualizar la pista activa. Si una pista activa no recibe asociaciones durante múltiples instantes de medida consecutivos, por ejemplo, porque el blanco asociado ha salido de la zona de cobertura del radar, la etapa de gestión y mantenimiento de pistas se encargará de eliminarla. Además, los sistemas de seguimiento pueden incluir etapas de gestión de ambigüedades para evitar la aparición de pistas debidas a blancos fantasma.

Diagrama de Flujo de un Sistema de Seguimiento**Figura 3-10 Diagrama de flujo de un sistema de seguimiento**

3.2.3. FILTROS DE SEGUIMIENTO

El objetivo principal de los algoritmos de seguimiento es realizar una estimación de los parámetros de los blancos (por ejemplo, posición y velocidad en coordenadas cartesianas) contenidos en el llamado vector de estado a partir de observaciones pasadas y presentes y en base a la asociación de medidas en instantes de tiempo consecutivos [30]. Además, las predicciones realizadas por los filtros de seguimiento también facilitan la asociación de *plots* a pistas activas.

En sistemas radar monoestáticos, donde se dispone de la posición puntual del blanco (normalmente en azimut y distancia), la estimación del estado se lleva a cabo en coordenadas cartesianas, ya que la conversión desde las medidas polares a un sistema cartesiano es directa y precisa.

En cambio, en sistemas biestáticos, la situación es diferente. Dado que no se dispone directamente de una posición única del blanco, sino de una medida de distancia biestática, la estimación del estado solo

puede realizarse en coordenadas biestáticas, es decir, en función de las magnitudes directamente medibles, como la distancia biestática y , en algunos casos, el ángulo de llegada en el receptor.

Por otro lado, si se dispone de un número suficiente de medidas, por ejemplo, múltiples distancias biestáticas, asociadas a diferentes pares transmisor-receptor, es posible aplicar algoritmos de localización, como por ejemplo la multilateración, para obtener una estimación de la posición cartesiana del blanco. Una vez calculadas estas posiciones en el espacio tridimensional, se pueden utilizar como entrada para los algoritmos de seguimiento, permitiendo realizar la estimación del estado en coordenadas cartesianas.

En sistemas multiestáticos, una estrategia alternativa consiste en aplicar primero el seguimiento en coordenadas biestáticas a nivel de cada par transmisor-receptor, antes de llevar a cabo el proceso de localización en coordenadas cartesianas. Esta aproximación permite mejorar la precisión de la estimación, lo que, a su vez, se traduce en un mejor rendimiento del algoritmo de localización en coordenadas cartesianas.

Además, esta arquitectura de procesamiento ofrece una ventaja adicional: la reducción sustancial de falsas alarmas. Al realizar el seguimiento en el dominio biestático como etapa intermedia, es posible filtrar las detecciones y solo inicializar procesos de multilateración o seguimiento en coordenadas cartesianas cuando existe un historial coherente de pistas que representen una trayectoria plausible. Esta capacidad de discriminación resulta especialmente importante en sistemas multiestáticos, donde es habitual la aparición de blancos fantasmas, un fenómeno que se agrava notablemente en entornos con múltiples blancos activos en el espacio de vigilancia.

Un aspecto esencial en los modelos de seguimiento es la correcta caracterización de la incertidumbre dinámica del blanco mediante el ruido de proceso. Este término modela las aceleraciones no observadas, maniobras inesperadas o perturbaciones externas que no están descritas explícitamente en el modelo dinámico elegido (por ejemplo, el modelo de velocidad constante o el de aceleración constante). Matemáticamente, el ruido de proceso se introduce como una entrada aleatoria de media cero y varianza conocida en la ecuación de transición de estados, lo que permite que el filtro no considere un modelo determinista, sino que conserve flexibilidad para seguir trayectorias reales. La intensidad de este ruido, representada por la matriz de covarianza Q , determina hasta qué punto el modelo dinámico refleja la dinámica real del blanco y afecta a la operación del filtro de seguimiento: valores bajos de q asumen trayectorias más suaves (adecuado para blancos con baja maniobrabilidad que se ajustan en mayor medida al modelo dinámico), mientras que valores altos permiten al filtro adaptarse mejor a maniobras rápidas, aunque a costa de un mayor riesgo de asociar falsas alarmas debido a la mayor incertidumbre de las predicciones [30].

Como un ejemplo inicial de los resultados obtenidos con el simulador implementado, en la Figura 3-11 se muestran los resultados de la simulación considerando distintos valores de ruido de proceso en una trayectoria sinusoidal aplicando un filtro de seguimiento basado en EKF (*Extended Kalman Filter*) que asume un modelo dinámico con velocidad casi constante. El gráfico de la izquierda representa el error medio en el tiempo, mientras que el gráfico de la derecha muestra el error medio global para cada nivel de ruido de proceso, representado en escala logarítmica. Por comparación, también se muestra el error obtenido aplicando un proceso de multilateración directamente sobre las medidas. Como puede observarse, la elección del ruido de proceso (que idealmente debería modelar la incertidumbre de la dinámica del blanco respecto al modelo dinámico empleado) afecta a los resultados del filtro de seguimiento, pudiendo incluso provocar una divergencia entre el estado real y el estado estimado con un aumento excesivo del error.

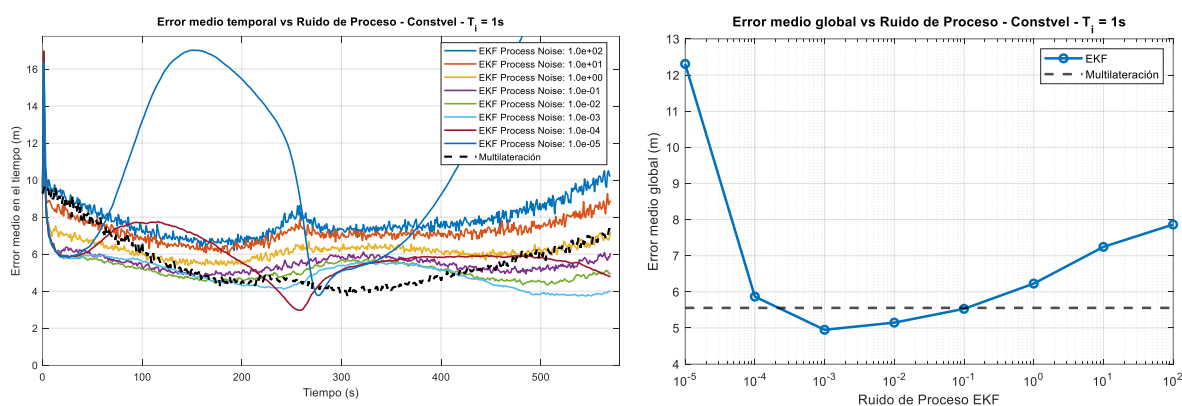


Figura 3-11 Error de predicción según el ruido de proceso

Además del ruido de proceso, el filtro debe modelar el ruido de medida, asociado a la incertidumbre de las observaciones proporcionadas por el radar. Este ruido se describe mediante la matriz de covarianza R , que representa la precisión de las mediciones disponibles. Matemáticamente, se asume que dicho error es un ruido blanco gaussiano de media cero, lo que implica que no existe correlación temporal entre las mediciones y que el sesgo medio es nulo. El valor de R depende de la calidad del sensor y de la técnica de estimación utilizada: un valor pequeño de varianza corresponde a un radar de alta precisión, mientras que un valor elevado refleja medidas menos fiables. La correcta elección de esta matriz es fundamental, ya que afecta directamente al peso relativo que los filtros de Kalman otorgan a la predicción frente a la medición en el proceso de actualización.

En la Figura 3-12 se presentan los resultados de una simulación para diferentes valores de ruido de medida en una trayectoria sinusoidal. El gráfico de la izquierda muestra la evolución del error medio temporal para cada nivel de ruido considerado en la aplicación del filtro de seguimiento, mientras que

el gráfico de la derecha representa el error medio global en función del factor multiplicativo aplicado al ruido real de medida (utilizado para simular las observaciones de entrada del filtro de seguimiento), expresado en escala logarítmica. Se observa que, para valores moderados de ruido, el EKF alcanza errores inferiores a los obtenidos mediante multilateración, aunque al incrementar excesivamente la incertidumbre de medida considerada en el filtro de seguimiento, al no ajustarse al ruido de medida real del sensor, el error global se dispara, degradando notablemente el rendimiento del filtro.

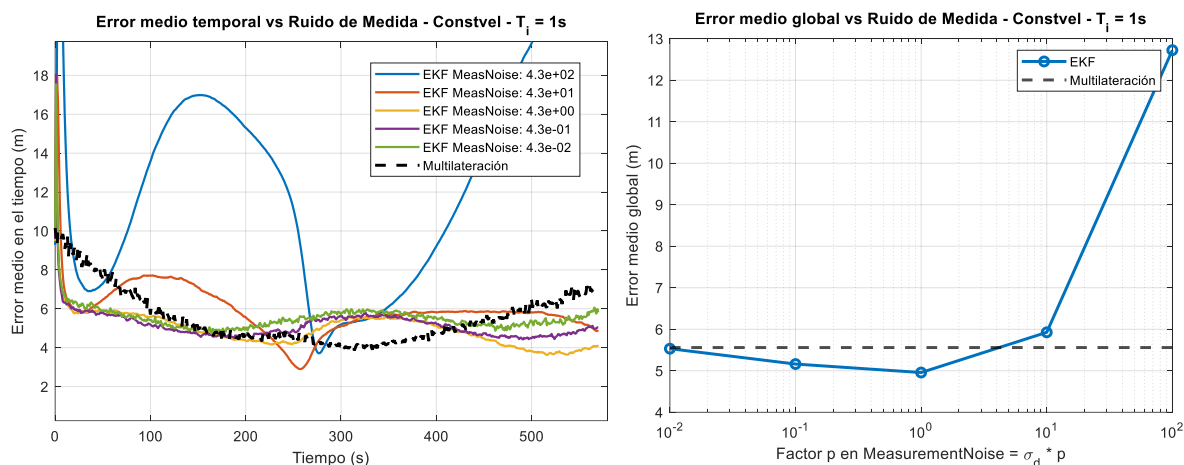


Figura 3-12 Error de predicción según el ruido de medida considerado para el filtro de seguimiento

El tiempo de refresco, relacionado con el tiempo de integración (T_i) en sistemas radar pasivos, es otro parámetro clave en el rendimiento del sistema de seguimiento y los errores de estimación, pues influye directamente en la capacidad de predicción y corrección de posiciones. Un tiempo de refresco reducido permite una mayor frecuencia de actualización, lo que mejora la capacidad de reacción del filtro frente a cambios en la trayectoria y, por tanto, una mejor precisión. En la Figura 3-13 se presentan los resultados de la simulación para el escenario considerado anteriormente, seleccionando los valores de ruido de proceso y de medida que ofrecían el mejor desempeño, y variando únicamente el tiempo de refresco. La gráfica de la izquierda muestra la evolución del error medio temporal, mientras que la gráfica de la derecha representa el error medio global en función de T_i . Se observa que, a medida que aumenta el tiempo de refresco, el rendimiento del EKF se degrada progresivamente, obteniéndose errores significativamente mayores respecto a configuraciones con tiempos de refrescos más cortos.

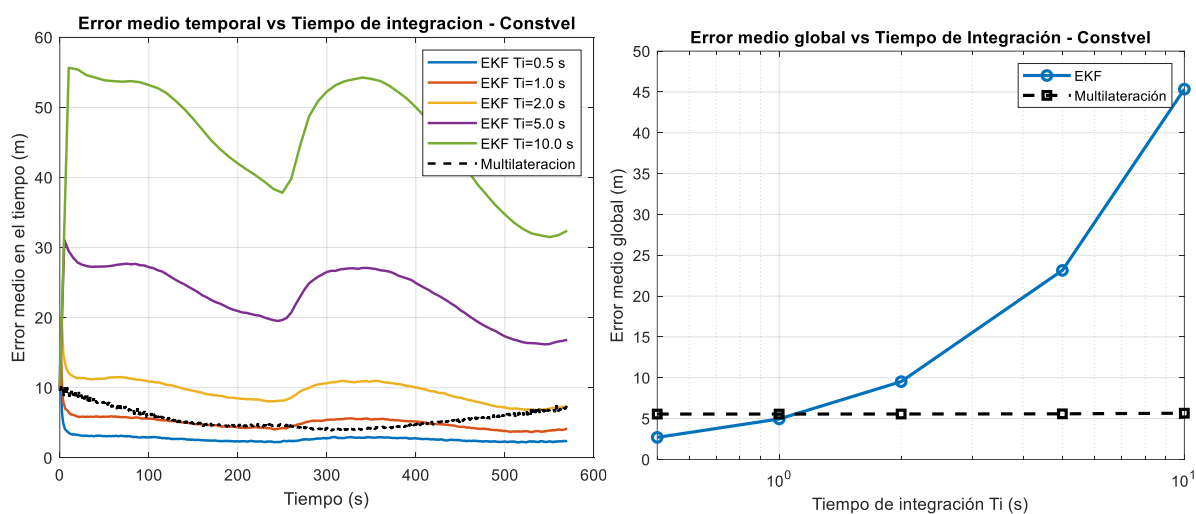


Figura 3-13 Error de predicción según el tiempo de refresco (asociado al tiempo de integración en radares pasivos)

En este trabajo se han evaluado diferentes filtros de seguimiento, los cuales se analizan teóricamente a continuación.

FILTRO DE KALMAN (KF)

El filtro de Kalman lineal es un estimador óptimo que minimiza el error cuadrático medio entre el estado real de un sistema, denotado con $X(n)$, y el estado suavizado $X_s(n)$ estimado por el filtro. Su optimalidad se basa en una serie de condiciones [34]:

- El modelo predictivo representa perfectamente al sistema real, salvo por una perturbación de entrada $W(n)$ (ruido de proceso).
- La perturbación $W(n)$ es ruido blanco, de media cero y con una covarianza conocida $Q(n) = E\{W(n)W^T(n)\}$.
- El ruido de medida $V(n)$ también es blanco y de media cero, con covarianza $R(n) = E\{V(n)V^T(n)\}$.
- Los términos de ruido de medida, ruido de proceso y error de estimación del estado inicial (asumido como variable aleatoria de media cero con covarianza conocida) son mutuamente incorrelados.

En la práctica, solo la tercera condición puede cumplirse con certeza. Las dos primeras suponen un modelo idealizado que rara vez se ajusta exactamente a procesos reales como en el caso de las dinámicas de los blancos. A pesar de estas limitaciones es ampliamente utilizado en sistemas radar.

El filtro de Kalman es un algoritmo recursivo para estimar el estado de un proceso a lo largo del tiempo cuando se realizan mediciones del mismo, también llamadas observaciones. Este filtro asume que el modelo de proceso (es decir, el modelo dinámico de los blancos) y el modelo de medida (es decir, el modelo que relaciona las medidas realizadas por el sistema con el vector de estados) son lineales. Por esta razón, el filtro de Kalman no se puede emplear directamente sobre las medidas biestáticas para el seguimiento en coordenadas cartesianas ya que la relación entre el espacio de medida (distancia y velocidad biestáticas) y el espacio de estado del objetivo no es lineal. Es por ello que se deben emplear otros filtros que permitan una relación no lineal entre el espacio de medida y el del objetivo, como el *Extended Kalman Filter* (EKF) o el *Unscented Kalman Filter* (UKF).

Para el caso del seguimiento en coordenadas cartesianas en radares pasivos multiestáticos, la única situación en la que puede utilizarse el filtro de Kalman lineal es cuando las múltiples medidas biestáticas de diferentes pares transmisor-receptor han sido previamente transformadas al espacio de estados del objetivo, por ejemplo, mediante un algoritmo de localización. En este caso, una vez convertidas las mediciones al dominio cartesiano, el seguimiento puede llevarse a cabo mediante el filtro de Kalman lineal.

FILTRO DE KALMAN EXTENDIDO (EKF)

El filtro de Kalman extendido (EKF) es un modelo no lineal del filtro de Kalman que se extiende a través del proceso de linealización. Este filtro sigue siendo un estimador recursivo del estado de un sistema, pero a diferencia del filtro lineal, permite que tanto el modelo dinámico como el modelo de medida sean no lineales. Para lograrlo, el EKF utiliza una aproximación lineal local de estos modelos mediante el cálculo de derivadas parciales (Jacobianos), lo que permite aplicar las ecuaciones del filtro de Kalman sobre sistemas no lineales [35].

La necesidad del EKF surge precisamente porque en muchos casos reales, como el radar pasivo con medidas biestáticas, la relación entre el espacio de estado (por ejemplo, coordenadas cartesianas) y el espacio de medidas (como distancia biestática) es no lineal. En estos escenarios, el filtro de Kalman lineal no puede aplicarse directamente, y se requiere el uso del EKF.

Para ello, se asume el modelo clásico de movimiento en coordenadas cartesianas:

$$\mathbf{x}_c(k + 1) = \mathbf{F}_c \mathbf{x}_c(k) + \mathbf{u}_c(k)$$

En el que $\mathbf{x}_c(k)$ es el vector de estado, \mathbf{F}_c es la matriz de transición que define el modelo dinámico, y $\mathbf{u}_c(k)$ es el ruido de proceso.

La medida biestática se modela como:

$$\mathbf{z}_{bi}(k) = h_i(\mathbf{x}_c(k)) + \mathbf{w}_i(k)$$

Donde $\mathbf{z}_{bi}(k)$ es el vector de medidas biestáticas correspondientes al par transmisor-receptor i , $h_i(\cdot)$ es la función no lineal de transformación de los parámetros cartesianos en los parámetros biestáticos para el par i , y $\mathbf{w}_i(k)$ es el vector de medida de media cero y distribución gaussiana con la siguiente matriz de covarianza para el caso de medir la distancia y velocidad biestática y asumir que sus errores de medida son incorrelados:

$$\tilde{\mathbf{R}}_{ci} = E[\mathbf{w}_i(k) \mathbf{w}_i^T(k)] = \begin{bmatrix} \sigma_R^2 & 0 \\ 0 & \sigma_V^2 \end{bmatrix}$$

En el caso de considerar modelos dinámicos lineales, la etapa de predicción del filtrado es la misma que en el filtro de Kalman clásico debido a la relación lineal en el modelo de movimiento:

$$\hat{\mathbf{x}}_c(k + 1 | k) = \mathbf{F}_c \hat{\mathbf{x}}_c(k | k)$$

La función no lineal $h_i(\cdot)$ se linealiza en el EKF calculando la matriz jacobiana:

$$\mathbf{H}_{ci}(k) = \left. \frac{\partial h_i(\mathbf{x}_c)}{\partial \mathbf{x}_c} \right|_{\hat{\mathbf{x}}_c(k | k-1)}$$

Lo que corresponde al cálculo del valor de las derivadas parciales para el vector de estado predicho $\hat{\mathbf{x}}_c(k | k - 1)$. La matriz $\mathbf{H}_{ci}(k)$ se utiliza entonces en las ecuaciones estándar del filtro de Kalman que se basa en las siguientes etapas de corrección y predicción:

- Etapa de corrección:

$$\hat{\mathbf{x}}_c(k | k) = \hat{\mathbf{x}}_c(k | k - 1) + \mathbf{K}(k)(\mathbf{z}_{bi}(k) - \mathbf{H}_{ci}(k) \hat{\mathbf{x}}_c(k | k - 1))$$

$$\hat{\mathbf{P}}_c(k | k) = (\mathbf{I} - \mathbf{K}(k)\mathbf{H}_{ci}(k))\hat{\mathbf{P}}_c(k | k - 1)$$

donde la ganancia de Kalman $\mathbf{K}(k)$ viene dada por:

$$\mathbf{K}(k) = \hat{\mathbf{P}}_c(k | k - 1)\mathbf{H}_{ci}^T(k)(\mathbf{H}_{ci}(k)\hat{\mathbf{P}}_c(k | k - 1)\mathbf{H}_{ci}^T(k) + \tilde{\mathbf{R}}_{ci})^{-1}$$

- Etapa de predicción:

$$\hat{\mathbf{x}}_c(k + 1 | k) = \mathbf{F}_c \hat{\mathbf{x}}_c(k | k)$$

$$\hat{\mathbf{P}}_c(k + 1 | k) = \mathbf{F}_c \hat{\mathbf{P}}_c(k | k) \mathbf{F}_c^T + \mathbf{Q}(k)$$

FILTRO DE KALMAN UNSCENTED (UKF)

El Filtro de Kalman *Unscented* (UKF) es una generalización del filtro de Kalman diseñada para sistemas no lineales, ampliamente utilizada en aplicaciones como redes neuronales, control óptimo, navegación, y seguimiento de objetivos [35]. A diferencia del Filtro de Kalman Extendido (EKF), que linealiza las transformaciones no lineales utilizando matrices Jacobianas y series de Taylor de primer orden, el UKF emplea la Transformación *Unscented* (UT) para propagar la media y la covarianza de las estimaciones de estado a través de funciones no lineales sin necesidad de calcular derivadas como Jacobianos o Hessianos.

La idea central del UKF es que es más sencillo aproximar una distribución de probabilidad que una función no lineal arbitraria. Para ello, el UKF genera un conjunto de puntos determinísticos, denominados puntos sigma, que capturan la media y la covarianza del estado de un sistema. Estos puntos sigma se propagan a través de las funciones del modelo de proceso y del modelo de medida no lineales, generando un nuevo conjunto de puntos transformados. A partir de estos, se calculan la media y la covarianza de las estimaciones de estado, así como la covarianza del error de estimación. Este enfoque permite al UKF capturar con mayor precisión los estadísticos de variables aleatorias bajo transformaciones no lineales, especialmente en sistemas con no linealidades significativas [36].

El UKF asume que las ecuaciones de transición de estado y de observación de un sistema no lineal discreto en el tiempo incluyen términos de ruido de proceso y de observación aditivos, con media cero y matrices de covarianza. Comparado con el EKF, el UKF ofrece varias ventajas: es más preciso, más fácil de implementar, y mantiene un orden computacional similar al de la linealización, evitando los problemas asociados con la validez de las aproximaciones lineales y la existencia de Jacobianos en sistemas con discontinuidades.

FILTRO DE PARTÍCULAS (PF)

El filtro de partículas es un estimador bayesiano recursivo que permite estimar el estado de un sistema cuando el modelo dinámico y la relación entre estado y observaciones pueden ser no lineales y no gaussianas. A diferencia del filtro de Kalman y su versión extendida, que se basan en aproximaciones lineales y distribuciones gaussianas, el filtro de partículas utiliza un conjunto de muestras discretas, denominadas partículas, para representar y actualizar la distribución *a posteriori* del estado del sistema.

Estas partículas evolucionan en el tiempo mediante un algoritmo recursivo que consta de tres fases principales: inicialización, predicción y corrección. En la fase de inicialización, se genera un conjunto de partículas de acuerdo con una distribución inicial del estado. En la etapa de predicción, se propagan

las partículas a través del modelo dinámico del sistema, incorporando el ruido del proceso. Finalmente, en la fase de corrección, las partículas se ponderan en función de su consistencia con las mediciones observadas, y se lleva a cabo una etapa de re-muestreo para centrar la atención en las regiones del espacio de estado con mayor probabilidad.

El filtro de partículas es especialmente adecuado para problemas de seguimiento en los que las relaciones entre las mediciones y el estado no son lineales, o cuando las distribuciones de incertidumbre no pueden asumirse gaussianas, donde filtros como el de Kalman extendido presentan limitaciones.

El filtro de partículas comparte ciertas similitudes con el Filtro de Kalman *Unscented* (UKF), ya que ambos están diseñados para abordar la estimación de estado en sistemas no lineales. Sin embargo, existen diferencias fundamentales en su enfoque y aplicación. Ambos métodos transforman un conjunto de puntos a través de ecuaciones no lineales conocidas para estimar la media y la covarianza del estado, pero difieren en la forma en que estos puntos se seleccionan y en su complejidad computacional [37].

Como se ha comentado previamente, en el UKF, los puntos, denominados puntos sigma, se eligen de manera determinística mediante la Transformación *Unscented* (UT), un método que selecciona un conjunto mínimo de puntos para capturar la media y la covarianza de la distribución del estado [36]. Esta selección determinística permite al UKF ser computacionalmente más eficiente, ya que requiere un número significativamente menor de puntos en comparación con el filtro de partículas. Por el contrario, el filtro de partículas utiliza un conjunto de muestras aleatorias (partículas) para representar la distribución a posteriori, lo que implica que típicamente se necesita un número mucho mayor de partículas para lograr una representación adecuada de la distribución, aumentando el esfuerzo computacional [37].

Otra diferencia clave radica en la convergencia del error de estimación. En el filtro de partículas, el error de estimación puede converger a cero a medida que el número de partículas tiende al infinito, siempre que se utilice un número suficientemente grande de partículas. En cambio, el error de estimación del UKF no converge a cero, ya que su precisión está limitada por la aproximación de la distribución hasta los momentos de segundo orden. Esto hace que el filtro de partículas sea potencialmente más preciso en escenarios con no linealidades fuertes o ruido no gaussiano, aunque a costa de un mayor costo computacional.

En términos de aplicabilidad, el UKF ofrece un balance entre la simplicidad computacional del Filtro de Kalman y el alto rendimiento del filtro de partículas, siendo especialmente útil en sistemas donde las no linealidades son moderadas y se asume que las distribuciones son aproximadamente gaussianas. Por otro lado, el filtro de partículas es más adecuado para sistemas con distribuciones no gaussianas o no linealidades significativas, como en problemas de seguimiento con discontinuidades o modelos dinámicos complejos, donde los supuestos del UKF o el EKF no son válidos.

Para analizar y mostrar el funcionamiento del filtro de partículas se ha realizado una simulación con un objetivo en movimiento rectilíneo uniforme, representando la evolución de las partículas en distintas posiciones para observar su comportamiento. En primer lugar, cabe señalar que el filtro es capaz de adaptar la dispersión de las partículas en función del grado de ambigüedad presente en la intersección de las elipses de medida. En la Figura 3-14 se aprecia cómo esta dispersión varía según la geometría de las intersecciones. En el primer caso, la intersección de las elipses es bien definida, sin ambigüedad significativa en ninguno de los ejes, por lo que las partículas se distribuyen de manera compacta en torno a la posición predicha, tanto en el eje x como en el eje y. En contraste, en la figura de la derecha, la intersección resulta mucho más ambigua en el eje x, lo que provoca que las partículas se dispersen en mayor medida a lo largo de dicho eje, mientras que en el eje y permanecen más concentradas. De este modo, se puede concluir que el filtro de partículas resulta especialmente adecuado para este tipo de escenarios, ya que incorpora las distintas incertidumbres asociadas a la geometría de un sistema multiestático.

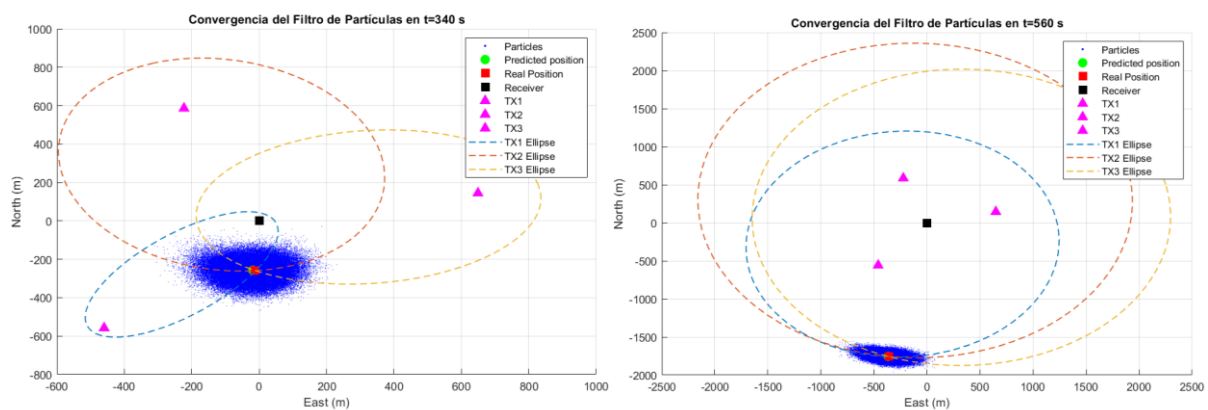


Figura 3-14 Distribución de las partículas en el filtro de partículas según la posición del blanco

Como se comentó previamente, otro aspecto determinante en la operación y rendimiento del filtro es el ruido de proceso, el cual modela las maniobras imprevistas del objetivo que no están contempladas en el modelo dinámico. Un mayor valor de este parámetro implica que el filtro asuma trayectorias potencialmente más rápidas o cambiantes, lo que le otorga una mayor capacidad de adaptación frente a movimientos bruscos, aunque a costa de reducir la precisión en la predicción. En la Figura 3-15 puede observarse este efecto: cuando el ruido de proceso se incrementa en un factor de 100, las partículas presentan una dispersión mucho más amplia. Esta mayor dispersión permite al filtro seguir trayectorias con variaciones más abruptas, pero introduce también una mayor incertidumbre en la estimación de la posición.

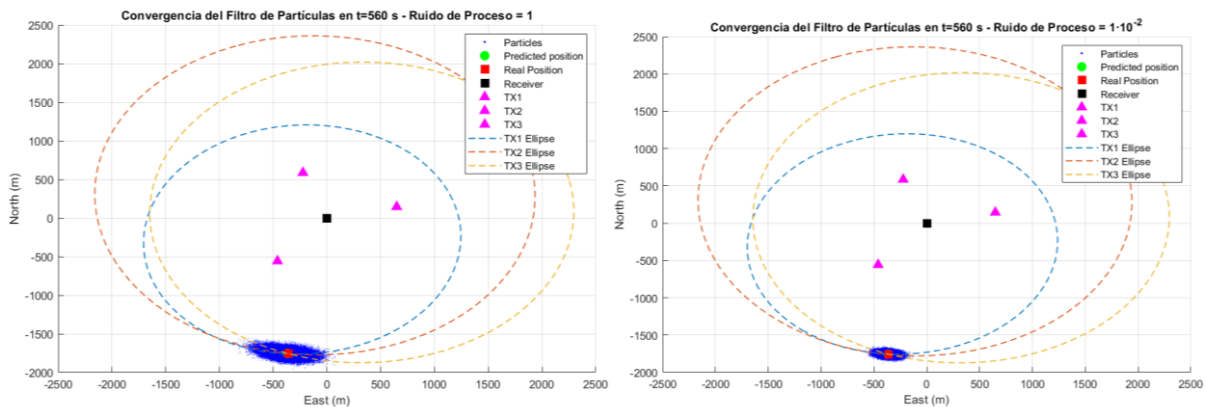


Figura 3-15 Distribución de las partículas en el filtro de partículas según el ruido de proceso considerado

De igual manera que con el ruido de proceso, el ruido de medida del sistema es un factor que determina la dispersión de las partículas, cuanto menor sea la precisión del sistema mayor dispersión habrá. En la Figura 3-16 se puede observar la diferencia de dispersión cuando el ruido de medida se considera 100 veces menor.

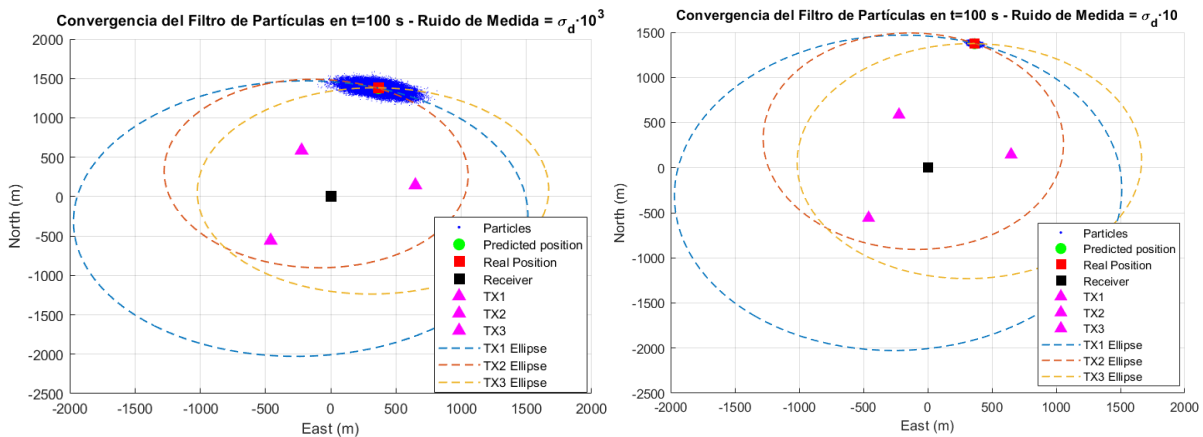


Figura 3-16 Distribución de las partículas en el filtro de partículas según el ruido de medida considerado

Por último, el factor que condiciona de manera decisiva la convergencia del filtro de partículas es el número de partículas empleadas por el filtro. Este parámetro define la resolución con la que se aproxima la distribución de probabilidad posterior: a mayor cantidad de partículas, mayor es la capacidad del filtro para representar con precisión la incertidumbre del sistema. En la Figura 3-17 se muestra una comparación entre dos simulaciones que difieren en un factor de 100 en el número de partículas. Puede observarse cómo, en el caso con menos partículas, la representación de la distribución es menos densa y más incompleta, lo que incrementa el riesgo de que el filtro pierda precisión o incluso degenera hacia

soluciones poco representativas. En cambio, con un número elevado de partículas, la densidad de muestreo mejora notablemente, lo que permite una estimación más robusta y ajustada a la dinámica real del objetivo. Sin embargo, este incremento en la calidad de la estimación se logra a costa de una mayor carga computacional, que crece de forma directamente proporcional al número de partículas. En consecuencia, la elección del número de partículas debe buscar un equilibrio entre la precisión deseada y los recursos computacionales disponibles, especialmente en aplicaciones en tiempo real donde los tiempos de respuesta son críticos.

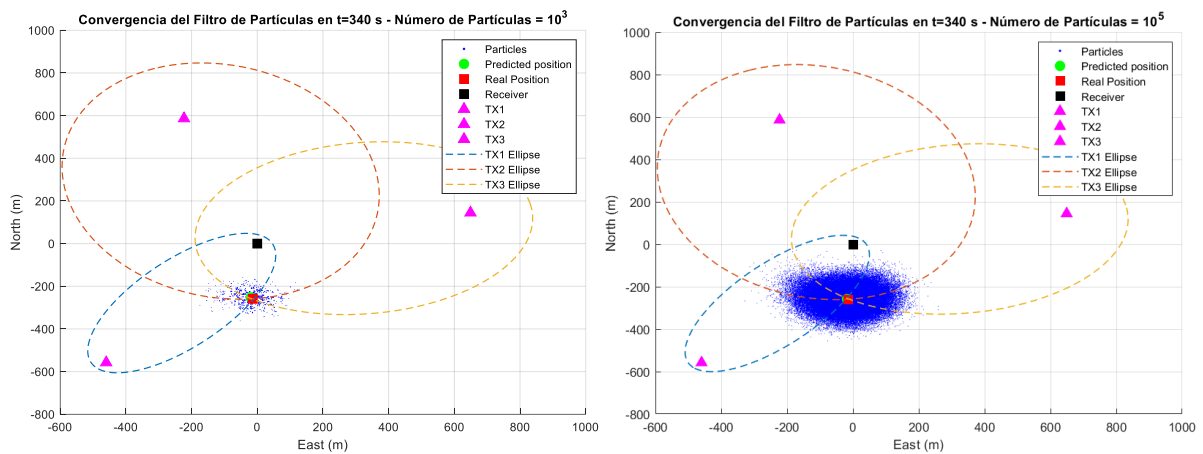


Figura 3-17 Convergencia de las partículas en el filtro de partículas según el número de partículas

3.3.MODELOS DINÁMICOS

Los objetivos considerados en este trabajo son vehículos aéreos que pueden tener una gran maniobrabilidad. Para poder realizar una estimación precisa de su trayectoria futura, es necesario definir modelos dinámicos adecuados que se integren en los filtros de seguimiento. Estos modelos permiten predecir el siguiente estado del objetivo a partir del estado actual. Se van a considerar tres modelos dinámicos que se van a evaluar en los diferentes filtros como funciones de transición de estado.

3.3.1. MOVIMIENTO RECTILÍNEO UNIFORME (MRU)

El modelo de movimiento rectilíneo uniforme es el más simple dentro de los modelos cinemáticos. En este caso, se asume que el objetivo mantiene una velocidad constante en cada uno de los ejes y sigue una trayectoria lineal sin cambios de rumbo. El estado del objetivo puede representarse mediante las siguientes ecuaciones [38]:

$$x(t + \Delta t) = x_0 + v_x \cdot \Delta t$$

$$y(t + \Delta t) = y_0 + v_y \cdot \Delta t$$

Donde x_0 e y_0 son las posiciones iniciales, v_x y v_y las velocidades constantes en cada uno de los ejes, Δt el intervalo de tiempo en el que se prevé el siguiente estado y x e y las posiciones finales que se quieren obtener. Por tanto, para realizar el seguimiento, el vector de estado incluye la posición y la velocidad en coordenadas cartesianas y el ruido de proceso se modela como una aceleración aleatoria gaussiana, por lo que este modelo también es llamado modelo de velocidad casi constante (*Nearly Constant Velocity Model*).

3.3.2. MOVIMIENTO RECTILÍNEO UNIFORMEMENTE ACELERADO (MRUA)

Para describir trayectorias con aceleración constante, se utiliza el modelo de movimiento rectilíneo uniformemente acelerado (MRUA). A diferencia del movimiento rectilíneo uniforme (MRU), que asume velocidades constantes, el MRUA permite representar objetivos que experimentan cambios continuos y constantes en su velocidad, es decir, trayectorias con aceleración constante.

Este modelo incorpora un grado adicional de libertad en el espacio de estados, al incluir explícitamente la aceleración como una variable del sistema. Esto permite al filtro tener en cuenta no solo la posición y la velocidad, sino también la influencia de una fuerza de aceleración sobre el movimiento del objetivo.

Las ecuaciones que modelan este tipo de movimiento son [38]:

$$x(t + \Delta t) = x_0 + v_x \cdot \Delta t + \frac{1}{2} a_x \cdot \Delta t^2$$

$$y(t + \Delta t) = y_0 + v_y \cdot \Delta t + \frac{1}{2} a_y \cdot \Delta t^2$$

Este tipo de modelo es útil para describir movimientos como despegues, aterrizajes o aceleraciones sostenidas ya que incorporar la aceleración permite anticipar con mayor fidelidad los cambios dinámicos del objetivo, mejorando la precisión de la estimación frente a modelos más simples. En este caso, el ruido de proceso se modela como un *jerk* (derivada de la aceleración) que sigue una distribución gaussiana de media cero, por lo que este modelo también es llamado modelo de aceleración casi constante (*Nearly Constant Velocity Model*).

3.3.3. MODELO DE GIRO CONSTANTE (CONSTANT TURN-RATE)

Cuando el objetivo sigue una trayectoria curva debido a un giro constante, se emplea el modelo de giro constante. MATLAB proporciona una implementación estándar de este modelo, cuyas variables de estado en dos dimensiones son:

$$x = \begin{pmatrix} x \\ v_x \\ y \\ v_y \\ \omega \end{pmatrix}$$

Donde ω es la tasa de giro en grados por segundo. Sin embargo, en este modelo dinámico no se modelan aceleraciones lineales en magnitud, pero el cambio de dirección se incluye mediante una componente angular. A diferencia del modelo de velocidad constante o el de aceleración constante, el modelo de giro constante representa con mayor realismo los cambios en la orientación del movimiento manteniendo la magnitud de la velocidad.

La aceleración instantánea viene dada por:

$$\dot{\mathbf{a}} = -\omega^2 \mathbf{v} + \mathbf{w}$$

Donde \mathbf{v} es el vector velocidad y \mathbf{w} representa ruido blanco. La tasa de giro ω puede obtenerse como:

$$\omega = \frac{|\mathbf{v} \times \mathbf{a}|}{v^2}$$

En el caso bidimensional, asumiendo una velocidad constante s y un ángulo de rumbo h , la velocidad se expresa como

$$v_x = s \cos h, \quad v_y = s \sin h$$

Suponiendo un giro a velocidad angular constante $\omega = h$, las posiciones futuras pueden predecirse integrando el movimiento circular:

$$x(k+1) = x(k) + T(S_W v_x(k) - C_W v_y(k))$$

$$y(k+1) = y(k) + T(C_W v_x(k) + S_W v_y(k))$$

Donde:

$$S_W = \frac{\sin(\omega T)}{\omega T}, \quad C_W = \frac{1 - \cos(\omega T)}{\omega T}$$

Las velocidades también se actualizan como:

$$v_x(t+1) = v_x(t) \cos(\omega T) - v_y(t) \sin(\omega T)$$

$$v_y(t+1) = v_x(t) \sin(\omega T) + v_y(t) \cos(\omega T)$$

Este modelo permite predecir tanto la posición como la velocidad de un objetivo que sigue una trayectoria circular o con cambios constantes en la dirección de movimiento. A diferencia del modelo de aceleración constante (MRUA), aquí no se introduce una aceleración lineal explícita, sino que la curvatura de la trayectoria se incorpora a través del parámetro ω , lo cual es más adecuado para representar trayectorias de vehículos o aeronaves que giran de forma sostenida [38].

En MATLAB, el modelo de giro constante se implementa a través de la función *constturn*, que permite predecir el estado futuro del sistema a partir de su estado actual.

4. DISEÑO, IMPLEMENTACIÓN Y RESULTADOS

Con el fin de evaluar las capacidades de los algoritmos de seguimiento en las arquitecturas multiestáticas planteadas en la motivación del trabajo, se ha desarrollado un entorno de simulación en MATLAB. Este entorno ha sido diseñado e implementado específicamente para reproducir distintos escenarios multiestáticos y analizar su comportamiento bajo diferentes configuraciones. Como punto de partida, fue necesario definir las funciones y clases fundamentales que sirven de base para la construcción de las simulaciones, de modo que el sistema pudiera modelar de forma modular tanto la geometría de las arquitecturas como los procesos de detección y seguimiento.

La Figura 4-1 muestra el diagrama de clases diseñado para este entorno de simulación, en el que se representan los elementos principales de un sistema radar multiestático. Se definieron tres clases básicas: *Target*, *Receiver* y *Transmitter*. La clase *Target* representa al objetivo e incluye atributos dinámicos como posición, velocidad y marcas temporales, además de métodos para simular y obtener su trayectoria y velocidad en instantes concretos. La clase *Receiver* modela las estaciones receptoras, almacenando sus coordenadas y proporcionando un método para calcular distancias a cualquier punto dado. De manera análoga, la clase *Transmitter* recoge los parámetros del transmisor, como frecuencia y operador, junto con su localización y un método equivalente de cálculo de distancias.

Este diseño orientado a objetos garantiza modularidad y escalabilidad, ya que cada clase encapsula tanto la información como las funciones específicas de cada entidad, facilitando así la extensión del entorno a escenarios más complejos. Además, la inclusión de métodos como *distanceTo* o *velocityAt* aporta flexibilidad para analizar las interacciones entre emisores, receptores y objetivos bajo diversas configuraciones multiestáticas.

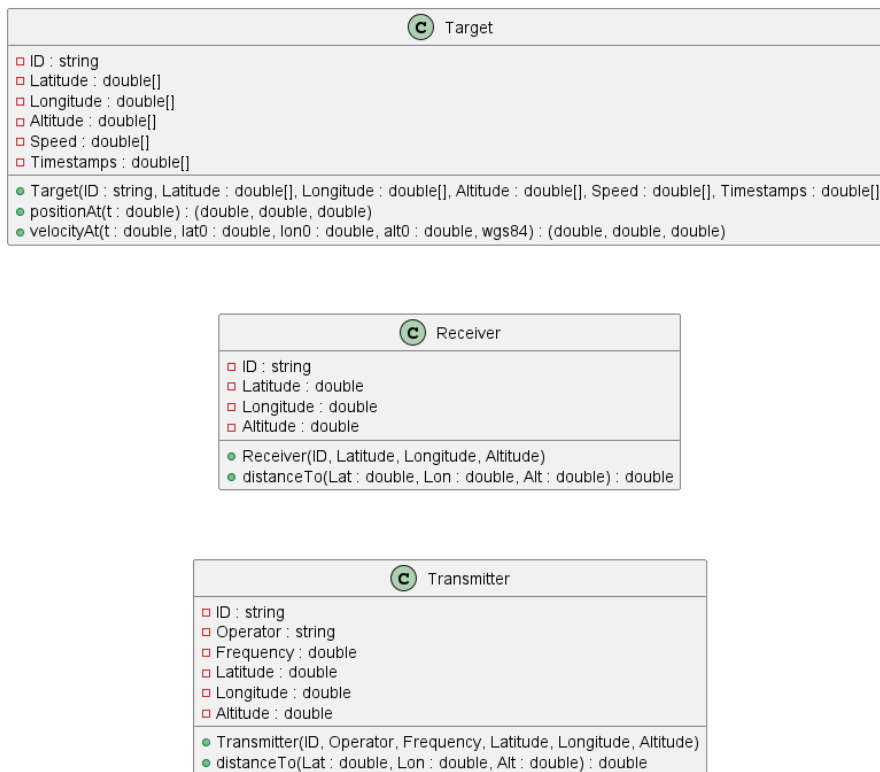


Figura 4-1 Diagrama de clases de un escenario multiestático

Una vez se diseñó e implementó esta estructura de clases, que permite la simulación de escenarios multiestáticos, y los algoritmos de localización y seguimiento considerados, se realizó un análisis de un escenario sobre el que centrar las simulaciones y mostrar las capacidades de la herramienta desarrollada y los resultados obtenidos.

En primer lugar, se establece el área de Ciudad Universitaria como ubicación sobre la que se desarrollan los escenarios considerando el despliegue de un sistema radar pasivo multiestático basado en señales transmitidas por sistemas de comunicaciones móviles. A través del portal *Infoantenas* del Ministerio para la Transformación Digital y de la Función Pública [39], se puede obtener la información sobre las estaciones de telefonía móvil disponibles en el área, así como su posición, operador y banda de frecuencia asignada. En la Figura 4-2 se muestran las antenas de telefonía instaladas en las inmediaciones de Ciudad Universitaria.

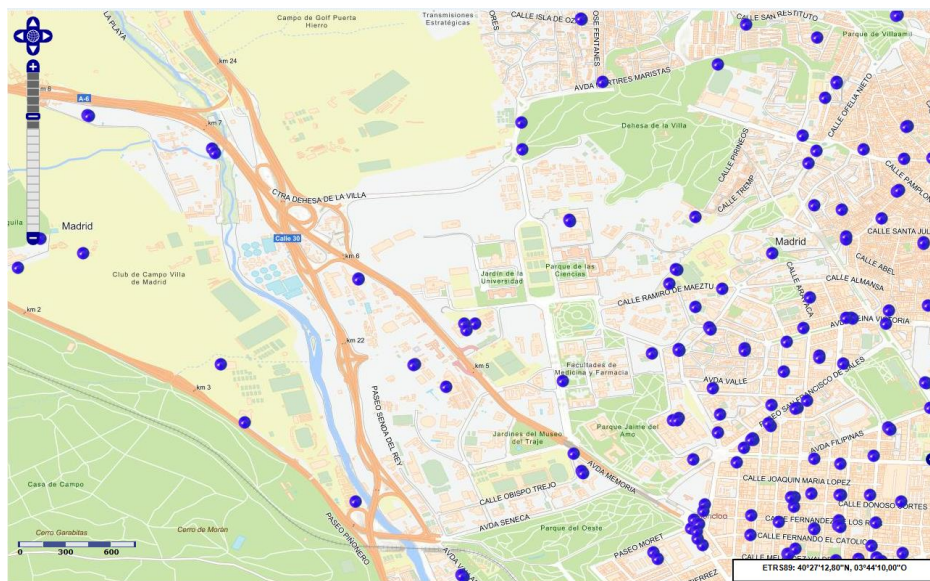


Figura 4-2 Portal “Infoantenas” (Área de Ciudad Universitaria) [39]

Se puede apreciar que el número de estaciones es mucho menor que en otras ubicaciones del centro de Madrid, donde la densidad de antenas es aparentemente mucho mayor.

Se va a escoger un escenario con una arquitectura multiestática con configuración pasiva basada en empleo de las estaciones de telefonía móvil como posibles iluminadores de oportunidad, asumiendo antenas transmisoras con diagramas de radiación omnidireccional. Además, se decide optar en un primer lugar con un único receptor situado en la ETSI Telecomunicaciones.

Por su distribución espacial, se han elegido como transmisores principales tres estaciones:

- Antena ETSI Caminos, Canales y Puertos
- Antena La Dehesa de la Villa (antigua subestación Iberdrola)
- Antena Universidad Nebrija

Estos tres transmisores, a simple vista otorgan ángulos muy diferentes respecto al receptor situado en la escuela de telecomunicaciones. En la Figura 4-3 se puede apreciar la distribución inicial que se va a evaluar. El puntero azul se corresponde con la posición del receptor y los punteros naranjas con la posición de los transmisores




Figura 4-3 Mapa cartográfico de la posición de los transmisores y el receptor

Con esta configuración se van a analizar diferentes métodos para la localización y seguimiento de objetivos.

4.1.LOCALIZACIÓN

Se van a analizar y evaluar los dos algoritmos descritos en el apartado 3.5.1. Localización del blanco.

Para ello, se define la región sobre la cual se desea realizar la vigilancia y se fija un tamaño de mallado para calcular el error de estimación de cada algoritmo en cada punto del área establecida. Se ha utilizado una escala de colores que va desde azul (mínimo error) hasta amarillo (máximo error en la estimación).

En la Figura 4-4 se muestran los resultados del algoritmo de multilateración, utilizando el método de Monte Carlo para estimar el error de estimación en el área definida. En el mapa de la izquierda se emplea una resolución analítica, mientras que en el de la derecha se utiliza una resolución basada en optimización numérica. Ambos mapas utilizan la misma escala de colores, de 0 a 20 metros, para facilitar la comparación. Se observa que el error con la solución analítica es menos uniforme y aumenta a medida que se incrementa la distancia al receptor.




Figura 4-4 Mapa de error de multilateración por resolución analítica y optimización numérica, respectivamente

Si se ajusta la escala del mapa obtenido mediante optimización numérica (ver Figura 4-5), se aprecia que el error es significativamente mayor a lo largo de las líneas base entre cada transmisor y el receptor, mientras que en las áreas comprendidas entre los transmisores el error se reduce.

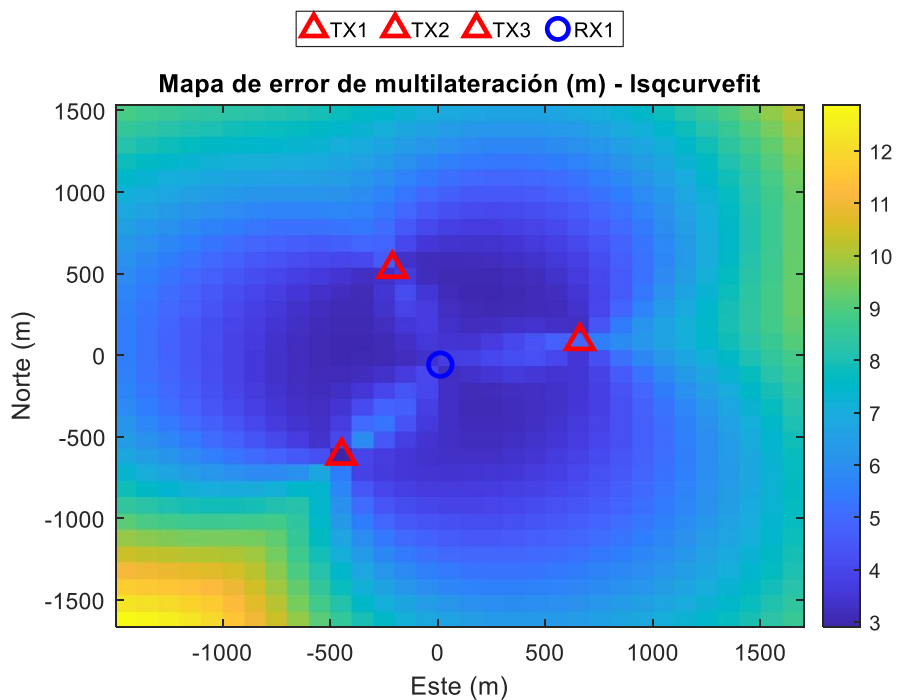


Figura 4-5 Mapa de error de multilateración por optimización numérica

Este fenómeno se explica por la problemática geométrica que surge cuando el objetivo se encuentra en la línea base entre el transmisor y el receptor, haciendo que el ángulo biestático (β) sea de 180° . Tal como se explicó en el apartado 3.1.2. Geometría, la resolución en distancia efectiva en coordenadas cartesianas viene por:

$$\Delta R_{efectiva} = \frac{c}{2 B \cos\left(\frac{\beta}{2}\right)}$$

Por lo que, cuando $\beta = 180^\circ$ entonces $\Delta R_{efectiva}$ tiende a infinito [30]. Esto implica que el error en las líneas directas sea superior.

También resulta relevante evaluar el coste computacional de ambos algoritmos. Para ello se ha utilizado una herramienta de MATLAB (*tic-toc*) para medir el tiempo que toma la ejecución de cada uno en un ordenador con un procesador Intel Core i5-8250U de 1,80 GHz y 8 GB de memoria RAM:

- Optimización numérica: 6,25 segundos.
- Resolución analítica: 0,099 segundos.

La resolución analítica presenta un tiempo de computación mucho menor, ya que la optimización numérica requiere de múltiples iteraciones para converger a una solución. La diferencia de tiempos entre ambas soluciones es de casi dos órdenes de magnitud:

$$\log_{10} \frac{6,25}{0,099} = 1,8$$

Aunque los resultados en términos de error de posición son ligeramente mejores con la optimización numérica, la diferencia en el coste computacional es significativa. Por esta razón, se recomienda emplear la resolución analítica siempre que sea posible.

El único caso en el que se considera necesaria la optimización numérica es cuando la arquitectura del sistema incluye múltiples receptores ubicados en distintas posiciones, situación en la cual la resolución analítica no es aplicable.

4.1.1. ÁNGULO DE LLEGADA

Además de la estimación basada únicamente en medidas de distancia biestática, se ha considerado una extensión del algoritmo mediante la incorporación de medidas de ángulo de llegada (AoA) en los

receptores. Esta mejora tiene como objetivo resolver ambigüedades geométricas inherentes al uso exclusivo de elipses biestáticas, especialmente en configuraciones con pocos transmisores.

Cada par transmisor-receptor define un elipsoide donde se espera que se encuentre el objetivo, pero al existir múltiples soluciones geométricas compatibles con intersecciones de múltiples elipses de diferentes pares transmisor-receptor, la solución puede no ser única. Introduciendo medidas de dirección de llegada desde los receptores, es posible reducir significativamente las soluciones ambiguas, cuando hay receptores con *arrays* de antenas capaces de estimar direcciones de llegada de la señal reflejada.

El enfoque se basa en un ajuste de mínimos cuadrados no lineales utilizando la función *lsqcurvefit* de MATLAB. En esta implementación, se define la función que calcula, a partir de una posición estimada del objetivo, las distancias biestáticas esperadas entre cada par transmisor-receptor y los ángulos de llegada esperados en cada receptor.

La función devuelve ambos vectores concatenados en una única matriz:

$$\begin{pmatrix} d_1 \\ d_2 \\ \dots \\ d_N \\ \theta_1 \\ \dots \\ \theta_N \end{pmatrix}$$

Esta representa los valores calculados para una posición estimada $\mathbf{x} = (x, y)$. Es la propia función *lsqcurvefit* la que se encarga de comparar internamente estos valores con los datos observados $[d_{medido}, AoA_{medido}]$, buscando la posición (x, y) que minimiza la diferencia cuadrática entre el modelo y las medidas.

El modelo angular para cada receptor viene dado por:

$$\theta_j^{modelo}(x) = \arctan\left(\frac{y - y_{rxj}}{x - x_{rxj}}\right)$$

Donde (x_{rxj}, y_{rxj}) son las coordenadas del receptor j , y (x, y) es la posición estimada del objetivo en coordenadas cartesianas. Con un único receptor se asume que el ángulo de llegada medido es el mismo para todos los pares en las simulaciones.

Dado que las distancias biestáticas y el ángulo de llegada medidos tienen resoluciones distintas no sería correcto aplicar el algoritmo de minimización por mínimos cuadrados ponderando con los mismo pesos las distancias y el ángulo. Para lograr una ponderación más adecuada entre ambas fuentes de

información se introdujo el uso de la distancia de Mahalanobis como criterio de ponderación. Esta distancia permite escalar de forma coherente las diferentes magnitudes involucradas.

La distancia de Mahalanobis es una generalización del concepto de distancia euclídea, adaptada a situaciones multivariantes donde las variables no son necesariamente independientes ni están medidas en las mismas escalas. Matemáticamente, para una medida observacional \mathbf{x} y una distribución con media $\boldsymbol{\mu}$ y matriz de covarianza $\boldsymbol{\Sigma}$, la distancia de Mahalanobis se define como [40]:

$$D_M(\mathbf{x}) = \sqrt{(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu})}$$

Esta métrica transforma los datos al espacio de variables estandarizadas y no correlacionadas, evaluando así de manera más justa la proximidad entre vectores multivariantes. En el contexto de este trabajo, se aplica para ponderar las medidas de distancia y ángulo en función de su incertidumbre, considerando además los errores de las medidas angulares y de distancia biestática.

En relación con la distancia de Mahalanobis, en la implementación desarrollada, las diferencias de las distancias biestáticas se escalan por su desviación estándar σ_d , mientras que las diferencias de los ángulos de llegada se escalan en función de una desviación en distancia transversal (*cross-range*) estimada, proporcional a la distancia desde el receptor al objetivo inicial. Esta variabilidad se modela como:

$$\sigma_{AoAd} = \sigma_{AoA} \cdot d_j$$

Donde d_j es la distancia entre el receptor j y una posición inicial estimada del objetivo, y σ_{AoA} es la resolución angular en radianes del sistema, que viene definida por la antena de vigilancia del receptor. La Figura 4-6 ilustra esquemáticamente el cálculo de esta resolución angular.




Figura 4-6 Esquema para el cálculo de incertidumbre en *cross-range*

De esta forma, se construye un vector de residuos normalizado:

$$y = \left[\frac{d_i^{medido}}{\sigma_d}; \frac{\theta_j^{medido}}{\sigma_{AoA_d}} \right]$$

Y un modelo análogo para las predicciones del algoritmo. Esto equivale a utilizar una versión diagonalizada de la distancia de Mahalanobis, asumiendo independencia entre las variables (no se incluye la matriz de covarianza completa, pero se considera su componente escalar en la ponderación).

Esta formulación mejora la robustez del algoritmo frente a incertidumbres y proporciona una manera de combinar información heterogénea, mejorando la precisión de la estimación.

En la Figura 4-7 se presenta el resultado del mapa de error que se consigue implementando esta extensión del algoritmo de multilateración mediante la integración del ángulo de llegada, con una resolución angular de 5°. Debido a la elevada incertidumbre angular, el resultado obtenido no mejora respecto a la multilateración, pero puede ser de gran utilidad en escenarios de asociación con múltiples objetivos ya que reduce notablemente la incertidumbre en la asociación de las medidas biestáticas de múltiples pares transmisor-receptor.

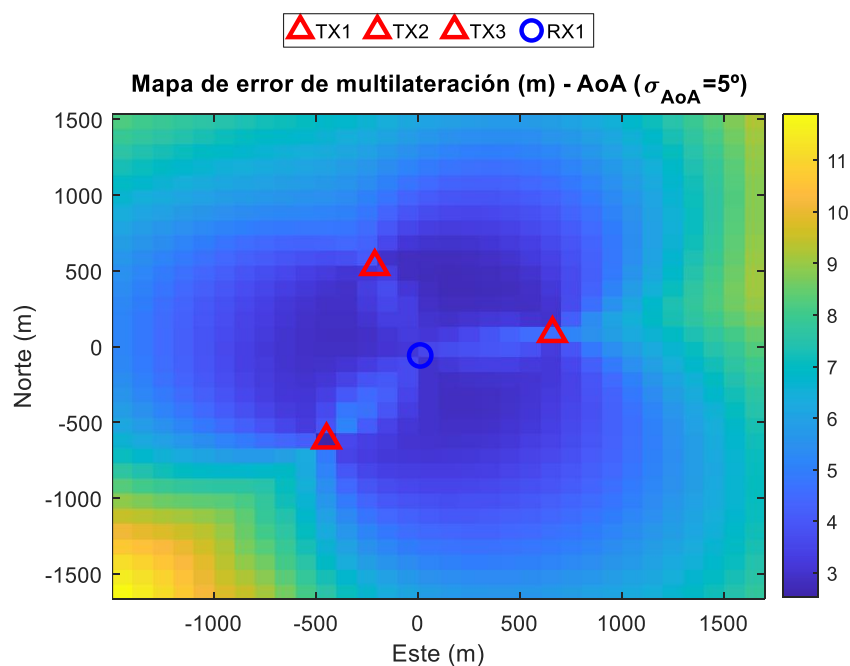


Figura 4-7 Mapa de error de multilateración empleando la medida del ángulo de llegada

4.1.2. CONFIGURACIONES CON MÚLTIPLES TRANSMISORES Y RECEPTORES

Tras haber evaluado la configuración multiestática más sencilla (compuesta por tres transmisores y un único receptor), en este apartado se amplía el análisis a escenarios más complejos que incorporan múltiples transmisores y receptores. El objetivo es estudiar cómo la inclusión de múltiples pares $Tx-Rx$ influye en la precisión de localización y en la robustez del sistema. Estas configuraciones permiten explotar la diversidad geométrica y la redundancia de información para mejorar la estimación de la posición de los objetivos, reducir la ambigüedad y mitigar las zonas de baja resolución.

En la Figura 4-8 se presenta el error de multilateración en una configuración multiestática con un transmisor más.

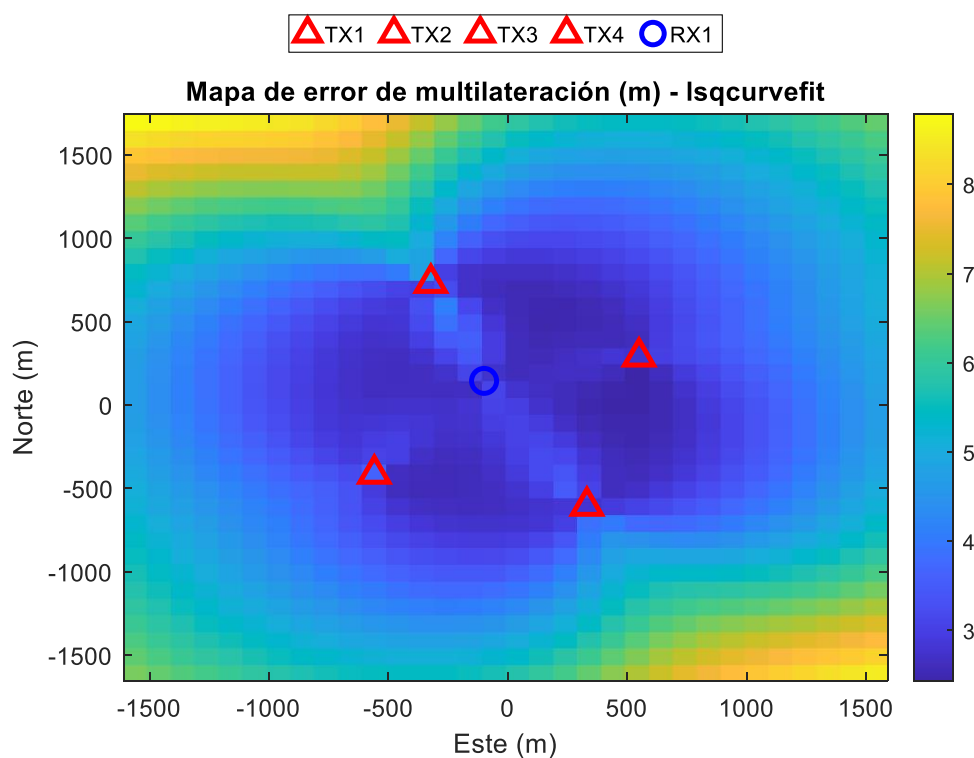


Figura 4-8 Mapa de error de multilateración con 4 transmisores

En la siguiente configuración, además de incorporar un transmisor adicional, se ha introducido un segundo receptor ubicado en una posición diferente. Esto implica un aumento significativo en la complejidad del sistema. Mientras que añadir un transmisor extra únicamente requiere incorporar un nuevo canal de recepción en el receptor existente (uno por cada nueva combinación transmisor-receptor,

para obtener la señal de referencia asociada a cada nuevo transmisor), la inclusión de un segundo receptor físicamente separado conlleva desafíos mucho mayores.

El principal inconveniente radica en la necesidad de sincronización precisa entre ambos receptores. Además, cada receptor debe disponer de un número de canales de recepción que crece con el número de transmisores presentes en la red, lo que supone una duplicación de recursos hardware respecto a una arquitectura con un único receptor. Esta configuración más compleja exige mecanismos adicionales de coordinación de datos para garantizar un funcionamiento correcto del sistema multicanal y multiestático. Asimismo, el nivel de computación requerido aumenta considerablemente debido al mayor número de elipses biestáticas que deben intersectarse para obtener la posición precisa del objetivo. Matemáticamente, el número de elipses generadas para un blanco es igual al producto del número de transmisores (N_{Tx}) por el número de receptores (N_{Rx}), es decir,

$$N_{elipses} = N_{Tx} \cdot N_{Rx}$$

Por lo tanto, al incrementar cualquiera de estos parámetros, el número de elipses a analizar crece linealmente con ambos, aumentando así la complejidad computacional del sistema.

En la Figura 4-9 se observa cómo la incorporación de un receptor adicional mejora la precisión en las líneas directas entre transmisor y receptor, reduciendo el error que en la configuración anterior era mayor. Además, se logra una zona de vigilancia central con un error más homogéneo y reducido. Esto se refleja también en la leyenda de colores, donde el rango de color que representa el error ha pasado de aproximadamente 2,5 hasta 8,5 metros en el caso anterior a 1,8 hasta 6,5 metros en la configuración actual. No obstante, esta mejora en la precisión ha implicado un incremento en el tiempo de computación, que ha pasado de 8,02 a 10,37 segundos. Este aumento era esperable, dado que en este escenario el número de elipses biestáticas consideradas se ha duplicado, lo que incrementa la carga computacional del algoritmo de localización basado en la resolución del problema de optimización de forma iterativa.

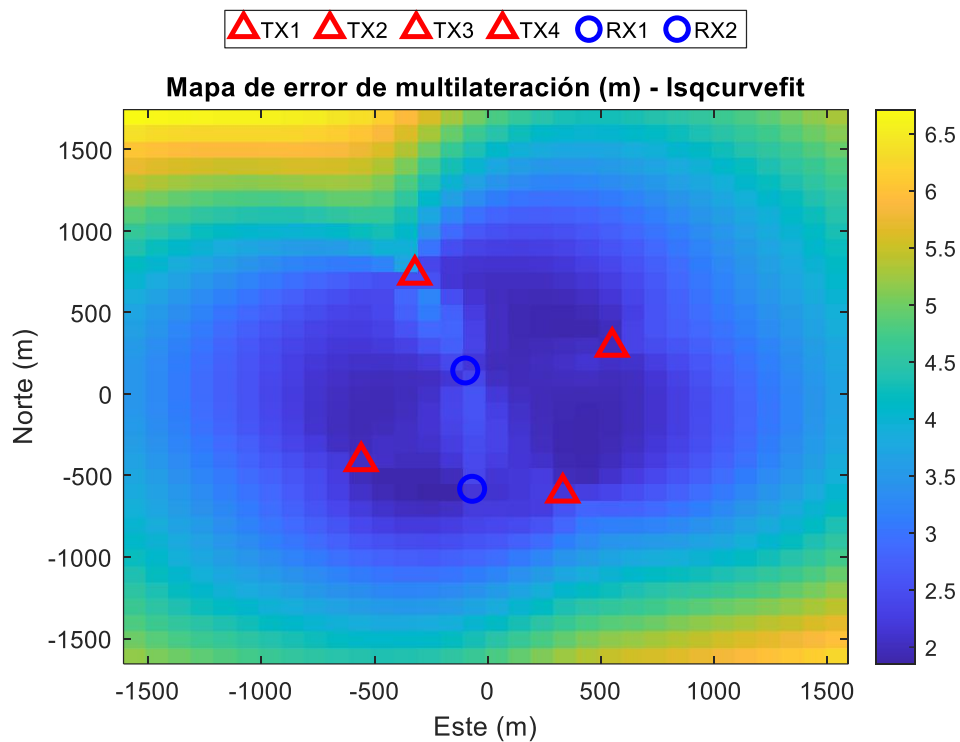


Figura 4-9 Mapa de error de multilateración con 4 transmisores y 2 receptores

Se elabora la Tabla 4-1 comparativa que permita analizar los rangos de error en la estimación de la posición del objetivo, así como el tiempo medio de computación asociado, para cada uno de los escenarios evaluados. Esta comparación facilita la evaluación del compromiso entre precisión y complejidad computacional en los distintos métodos implementados.

| | Rango error (m) | Tiempo medio de computación (s) |
|---------------------------------------|-----------------|---------------------------------|
| Resolución analítica (3Tx-1Rx) | 3,7-17,7 | 0,099 |
| Minimización (3Tx-1Rx) | 2,9-12,8 | 6,25 |
| Minimización con AoA (3Tx-1Rx) | 2,8-11,9 | 5,85 |
| Minimización (4Tx-1Rx) | 2,4-8,7 | 8,02 |
| Minimización (4Tx-2Rx) | 1,8-6,7 | 10,37 |

Tabla 4-1 Resultados de error de medida y tiempo de computación

4.2. FILTROS DE SEGUIMIENTO

Las no linealidades existentes entre el espacio de medida y el espacio de estado del objetivo hacen necesario comparar el rendimiento de distintos filtros y modelos dinámicos frente a diversas trayectorias de los blancos, con el objetivo de identificar cuál resulta más eficaz para este tipo de sistemas. Para ello, se plantean varios escenarios en los que un objetivo sigue distintos patrones de movimiento, considerando una arquitectura multiestática con tres transmisores y un único receptor, tal como se presentó en el apartado de anterior 4.1. Localización.

4.2.1. TRAYECTORIA RECTILÍNEA

Se define un objetivo utilizando la clase *Target* creada en MATLAB, con un punto inicial y otro final especificados mediante sus coordenadas geográficas (latitud y longitud), así como una velocidad constante. Con estos parámetros, se genera una trayectoria rectilínea dentro de la zona de vigilancia, que se representa sobre un mapa cartográfico en la Figura 4-10.

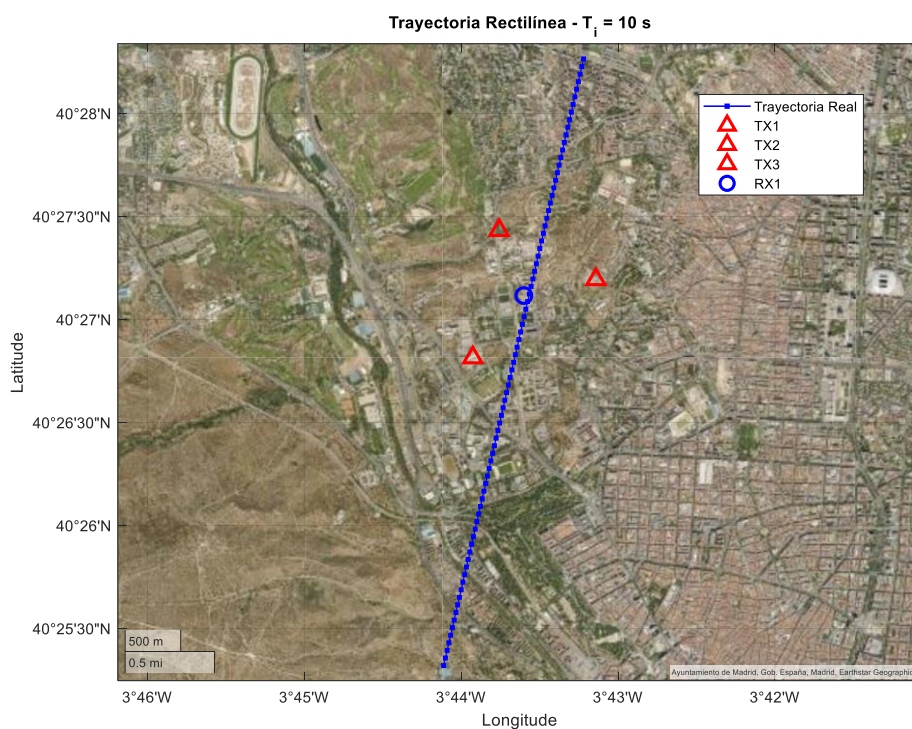


Figura 4-10 Trayectoria rectilínea del blanco para un tiempo de integración de 10 segundos sobre un mapa cartográfico

Para simular el proceso de medida con ruido, las medidas de distancia biestática obtenidas en cada canal de vigilancia se ven afectadas por ruido gaussiano de media cero y desviación estándar dada por $\frac{c}{B\sqrt{12}}$, que está relacionada con la desviación estándar del error para una distribución uniforme de la posición del blanco en la celda de resolución en distancia biestática. Asumiendo un ancho de banda de 20 MHz por canal, típico en canales de LTE, la desviación típica resultante para las medidas de distancia biestática es de 4,33 metros.

El tiempo de integración representa un parámetro clave en estos sistemas de radar pasivo, ya que determina la tasa de refresco del sistema. A diferencia de un radar monoestático con antena giratoria, cuya tasa de actualización viene impuesta por la velocidad de rotación, en este caso el tiempo de integración es configurable en fase de diseño, lo que permite adaptar el sistema a distintos escenarios operativos.

En cuanto a los filtros empleados, todos reciben como entrada las distancias biestáticas correspondientes a la posición simulada más un ruido gaussiano (excepto el filtro de Kalman lineal). Dado que el filtro de Kalman estándar no permite definir una función de medida no lineal, en su caso se utiliza como entrada la posición estimada en coordenadas cartesianas mediante el proceso de multilateración, en lugar de las distancias biestáticas. Además, tanto este filtro como los no lineales se inicializan con la solución obtenida a partir de la multilateración en las primeras medidas, lo que proporciona un estado inicial consistente antes de que los algoritmos comiencen a realizar la predicción y corrección.

En la Figura 4-11 se presentan los resultados del error de predicción de la posición del blanco. La línea negra discontinua representa el error asociado a la multilateración directa, siendo este más reducido cuando el objetivo se encuentra en regiones de menor error, como se analizó en el apartado 4.1. Localización. El filtro de Kalman lineal, que parte de esta multilateración, logra reducir ligeramente el error en comparación con dicha técnica por sí sola.

Los filtros capaces de manejar relaciones no lineales entre medidas y estado (EKF, UKF y PF) consiguen una mejora más significativa, reduciendo el error de predicción en varios metros. El *Unscented Kalman Filter* (UKF) destaca por su rápida inicialización, aunque a largo plazo pierde algo de precisión frente a otras alternativas. Por el contrario, el filtro de partículas presenta una inicialización más lenta, pero alcanza finalmente un rendimiento comparable al resto. El filtro de Kalman Extendido (EKF) ofrece el mejor equilibrio entre rapidez de convergencia y precisión en la estimación.

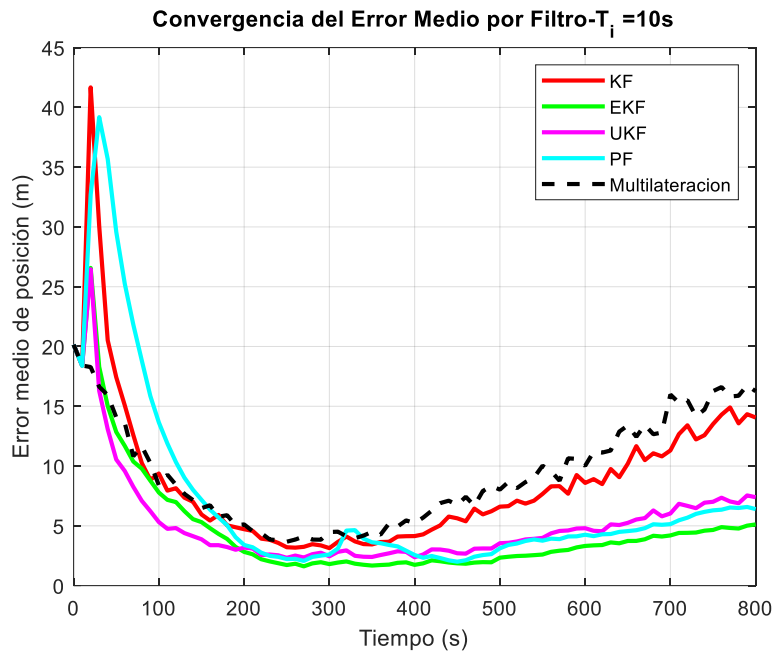


Figura 4-11 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 10 segundos en un escenario con trayectoria rectilínea

Para una trayectoria más reducida, en la Figura 4-12 se muestra la trayectoria rectilínea del blanco para un tiempo de integración de 1 segundo sobre un mapa cartográfico.

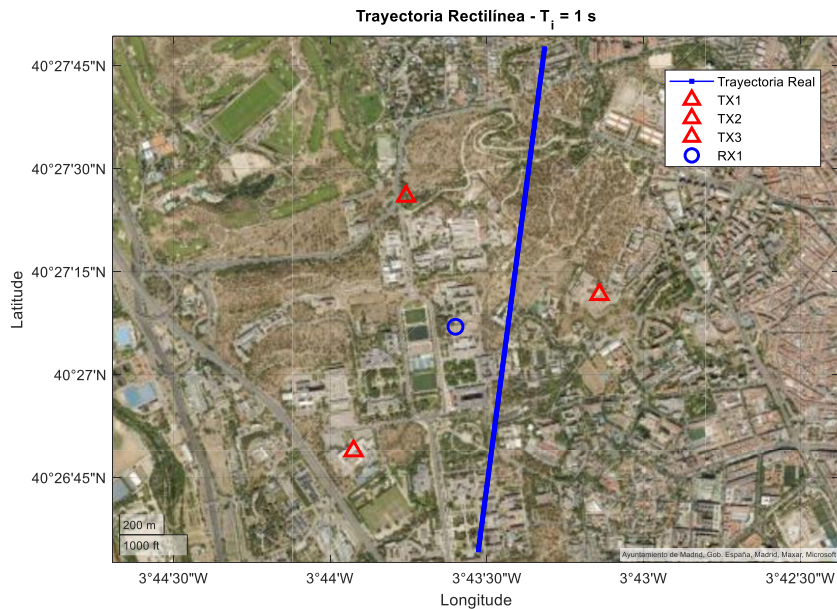


Figura 4-12 Trayectoria rectilínea del blanco reducida para un tiempo de integración de 1 segundo sobre un mapa cartográfico

En esta misma configuración, y dentro del área de vigilancia donde el error de multilateración es menor, se comparan los distintos filtros, cuyos resultados se presentan en la Figura 4-13. Hay una inicialización buena de los filtros dado el bajo error de multilateración y el elevado número de muestras. La mejora de la precisión de predicción del filtro de Kalman lineal se debe principalmente a que el error por multilateración en esa área es bajo. Se puede observar como a partir del instante de tiempo 300 comienza a aumentar el error por multilateración y el del filtro de Kalman también aumenta con él. El resto de los filtros presentan unos resultados similares al escenario anterior.




Figura 4-13 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 1 segundo en un escenario con trayectoria rectilínea

En este caso de trayectoria rectilínea con velocidad constante, el cambio en el tiempo de integración no presenta un efecto significativo en los errores de estimación alcanzables tras la convergencia de los filtros, ya que no se considera la maniobrabilidad y cambios en la trayectoria del blanco.

4.2.2. TRAYECTORIA NO LINEAL

Las trayectorias perfectamente rectilíneas y de velocidad constante resultan adecuadas en aplicaciones como la aviación civil, donde las aeronaves suelen mantener rumbos fijos y velocidades estables durante la mayor parte del tiempo. Sin embargo, este supuesto deja de ser realista en escenarios de vigilancia con objetivos que presentan alta maniobrabilidad, especialmente en entornos urbanos. Por este motivo,

se evalúa el desempeño de los modelos dinámicos y filtros de seguimiento considerando una trayectoria sinusoidal dentro del área de vigilancia.

En primer lugar, se analiza el comportamiento de un modelo dinámico que no reproduce fielmente el movimiento real del blanco. En la Figura 4-14 se muestra, sobre un mapa cartográfico, la trayectoria sinusoidal seguida por el objetivo junto con las posiciones predichas por los distintos filtros. La Figura 4-15 presenta el error medio asociado a cada filtro, donde se observa un error de inicialización elevado en todos los casos. Este error disminuye progresivamente y alcanza su mínimo en la parte más lineal de la trayectoria, alrededor del instante de 330 segundos. Se puede apreciar como en los picos de la senoide, donde se produce el mayor cambio de rumbo, es dónde peor predicción consiguen los filtros. Dichos resultados son coherentes con lo esperado, ya que reflejan el desajuste entre el modelo dinámico asumido y el movimiento real del blanco.

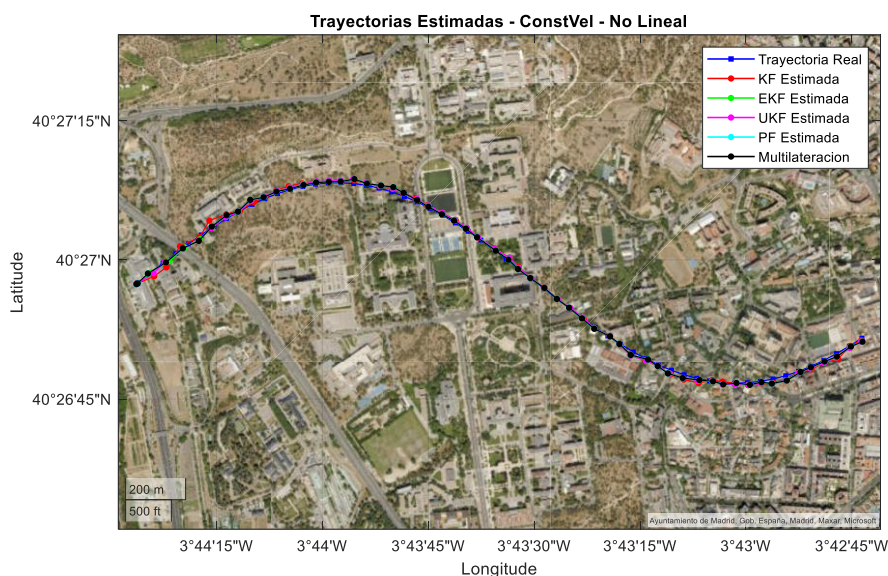


Figura 4-14 Trayectoria no lineal y estimaciones obtenidas con distintos filtros de seguimiento para una simulación del escenario

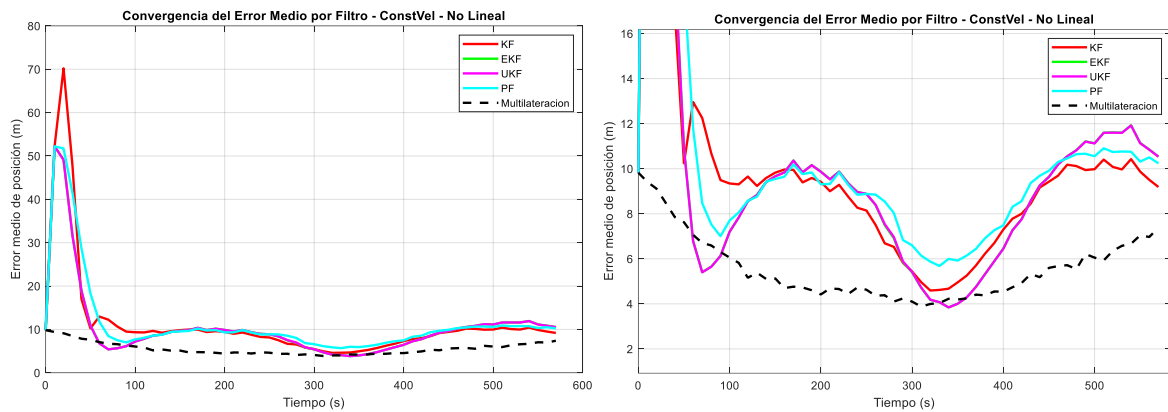


Figura 4-15 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 10 segundos en un escenario con trayectoria no lineal

Por otra parte, el tiempo de integración empleado (10 segundos) resulta demasiado elevado. Para mejorar el rendimiento, se evalúa un tiempo de integración reducido a 1 segundo. Aunque persiste la discrepancia entre el modelo dinámico y el movimiento real, esta reducción permite una mayor capacidad de corrección y, en consecuencia, una mejora significativa del error medio de estimación. La Figura 4-16 evidencia cómo los filtros logran reducir el error de predicción por debajo del obtenido mediante multilateración. Además, la mayor tasa de refresco favorece una convergencia más rápida.




Figura 4-16 Error medio de la predicción de los filtros con un modelo dinámico de velocidad constante y tiempo de integración de 1 segundo en un escenario con trayectoria no lineal

En conclusión, cuando el espacio recorrido durante el tiempo de integración es pequeño en comparación con los cambios de dirección del blanco, la aproximación mediante un modelo dinámico de velocidad constante puede resultar suficientemente válida.

Por otro lado, es posible aplicar otros modelos dinámicos, como el de giro constante, que en este caso se ajusta mejor al movimiento real del blanco. En la Figura 4-17 se observa que, para un tiempo de integración de 10 segundos, el error medio de predicción es inferior al obtenido con el modelo de velocidad constante, manteniéndose por debajo de los 7 metros una vez superada la fase de inicialización. En contraste, con el modelo de velocidad constante el error llegaba a superar los 10 metros, dependiendo del punto de la trayectoria en que se encontrara el blanco, con este modelo se mantiene más constante el error.




Figura 4-17 Error medio de la predicción de los filtros con un modelo dinámico de giro constante y tiempo de integración de 10 segundos en un escenario con trayectoria no lineal

De igual forma, se simuló el mismo escenario para un tiempo de integración de 1 segundo. Tal como muestra la Figura 4-18, en este caso se logra mejorar los resultados de la multilateración y todos los

filtros presentan un buen desempeño. Además, las prestaciones obtenidas son muy similares a las del modelo de velocidad constante. Esto se debe a la conclusión previamente alcanzada: cuando el espacio recorrido durante el intervalo de integración es pequeño en comparación con el cambio de dirección del blanco, incluso un modelo dinámico sencillo es capaz de adaptarse correctamente a la trayectoria.




Figura 4-18 Error medio de la predicción de los filtros con un modelo dinámico de giro constante y tiempo de integración de 1 segundo en un escenario con trayectoria no lineal

4.3. ASOCIACIÓN EN ESCENARIOS MULTIOBJETIVO

En entornos reales de vigilancia, es habitual que se detecten múltiples objetivos de forma simultánea. Esta situación representa un desafío significativo para los sistemas de seguimiento, que deben ser capaces no solo de detectar la presencia de varios blancos, sino también de asociar correctamente cada medición con su correspondiente trayectoria y mantener una estimación precisa del estado de cada uno.

El seguimiento multiobjetivo introduce una dimensión adicional de complejidad, ya que la incertidumbre en el origen de las observaciones se suma al ruido habitual de las mediciones. Es decir, en cada instante, no es posible asegurar con certeza si una detección concreta corresponde a un objetivo real, a otro blanco cercano, a un eco espurio, a ruido de fondo o a un falso positivo. Esta ambigüedad en la asociación de medidas puede degradar drásticamente el rendimiento del sistema si no se gestiona adecuadamente.

Los algoritmos de seguimiento multiobjetivo buscan resolver este problema mediante técnicas que permitan establecer y mantener correspondencias fiables entre mediciones y trayectorias a lo largo del tiempo.

Se ha desarrollado en MATLAB un algoritmo que tiene como objetivo simular un sistema radar multiestático orientado al seguimiento de múltiples objetivos móviles en un entorno urbano. Utiliza medidas sintéticas de distancia biestática generadas entre transmisores y receptores fijos para localizar y estimar la trayectoria de objetivos. Esta simulación permite analizar el rendimiento de técnicas de seguimiento en configuraciones con varios objetivos al mismo tiempo, así como un algoritmo para la asociación de medidas (*plots*) a trazas.

Para facilitar la comprensión del proceso general del algoritmo, se ha elaborado el siguiente diagrama de flujo, que se presenta en la Figura 4-19, que resume las principales etapas. Este diagrama permite visualizar de forma clara y estructurada los pasos seguidos desde la detección hasta la asociación de medidas y la estimación de trayectorias.

**Diagrama de flujo -
Asociación y Seguimiento en Sistema Radar Multiestático Multiobjetivo**

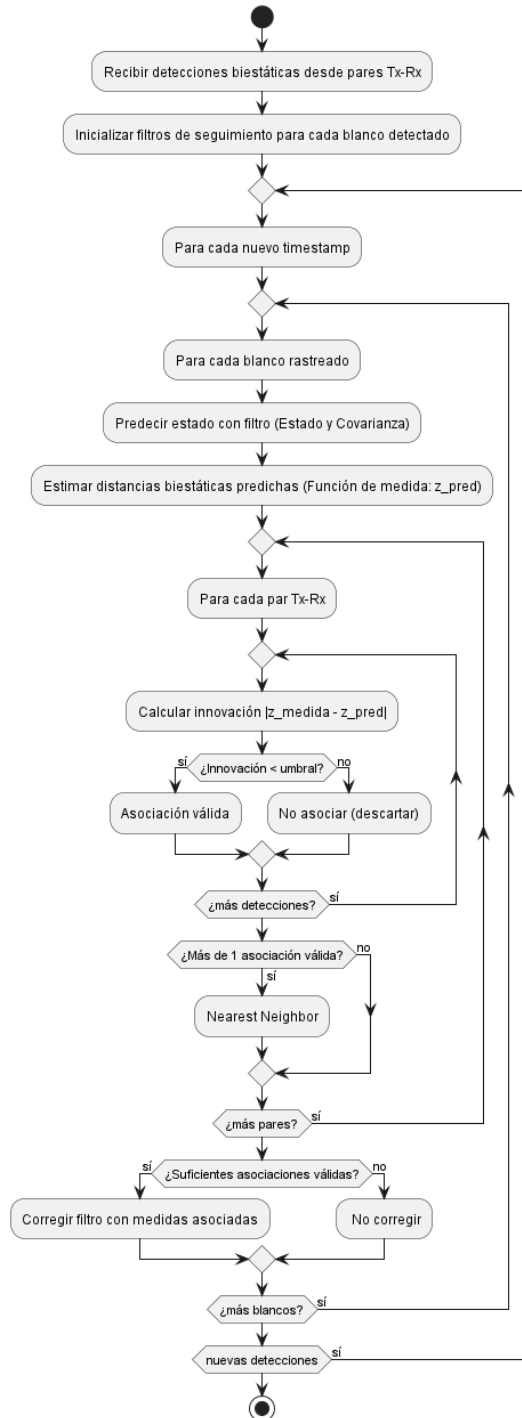


Figura 4-19 Diagrama de flujo del algoritmo de un sistema de asociación y seguimiento en radar multiestático

El escenario parte de la definición de múltiples transmisores con posiciones geográficas distintas, así como uno o más receptores. Se definen varios blancos móviles con trayectorias distintas: lineales o sinusoidales, expresadas en coordenadas geodésicas (latitud, longitud, altitud).

El modelo de movimiento considerado en el filtro de seguimiento es el de velocidad constante, implementado mediante el modelo de velocidad constante compatible con el filtro extendido de Kalman (EKF). Para cada instante de tiempo, se simula la distancia biestática real entre cada objetivo y cada par transmisor-receptor, añadiendo ruido gaussiano con desviación típica proporcional a la resolución impuesta por el ancho de banda. Este ruido simula la incertidumbre de medición. A continuación, el algoritmo predice el estado (posición y velocidad en coordenadas cartesianas) de cada blanco usando el EKF y calcula las distancias biestáticas esperadas en el siguiente instante de medida según las funciones del modelo de proceso y del modelo de medida. La asociación entre detecciones y objetivos se realiza comparando la diferencia entre la medida simulada y la predicción del filtro, aplicando un umbral dinámico basado en la incertidumbre de predicción.

El estado estimado del objetivo en el filtro de Kalman extendido se encuentra en coordenadas cartesianas, lo que implica que la comparación directa entre la medida simulada y la estimación debe considerar esta transformación de espacio. La asociación de datos se basa en calcular la innovación, es decir, la diferencia entre la medida y la predicción del filtro. Sin embargo, para determinar si esa innovación es significativa (es decir, si la medida puede considerarse compatible con la predicción), no es suficiente con tomar un umbral fijo. Se requiere un umbral adaptativo que considere la incertidumbre actual del estado estimado, y cómo esta incertidumbre afecta el valor estimado de la medida. El modelo de medida en el contexto biestático es:

$$z = \| r - x \| + \| t - x \|$$

Donde x es la posición del objetivo y r y t son las posiciones del receptor y transmisor, respectivamente. Este modelo es no lineal, por lo que el filtro de Kalman extendido (EKF) lo linealiza alrededor del estado estimado mediante su Jacobiano, denotado H_p .

Para el par transmisor-receptor p , el Jacobiano H_p en el espacio de estado $[x, v_x, y, v_y]$ se calcula como:

$$H_p = \left[\frac{\partial x}{\partial z}, \frac{\partial v_x}{\partial z}, \frac{\partial y}{\partial z}, \frac{\partial v_y}{\partial z} \right]$$

Dado que la observación no depende de las componentes de velocidad (v_x, v_y), estas derivadas parciales son cero. Por tanto, el Jacobiano queda:

$$H_p = \left[\frac{x - t_x}{\| x - t \|} + \frac{x - r_x}{\| x - r \|}, 0, \frac{x - t_y}{\| x - t \|} + \frac{x - r_y}{\| x - r \|}, 0 \right]$$

Dado que el estado estimado tiene una covarianza $P_{pred} \in \mathbb{R}^{4 \times 4}$, que describe la incertidumbre del estado en el espacio cartesiano, se desea conocer la varianza inducida en la medida z . Esta se obtiene proyectando la covarianza del estado al espacio de medida mediante la matriz H_p :

$$S = H_p \cdot P_{pred} \cdot H_p^T$$

El escalar S representa la varianza linealizada de la predicción en el espacio de medida, es decir, cuánto se espera que varíe z debido a la incertidumbre en la posición del objetivo.

La desviación estándar asociada es:

$$\sigma_{linealizado} = \sqrt{S}$$

Para determinar si la innovación observada es aceptable, se define un umbral dinámico que depende de $\sigma_{linealizado}$.

$$threshold = k \cdot \sigma_{linealizado}$$

Se aplica una constante multiplicativa k , relacionada con un nivel de confianza estadístico. Este factor se elige según la distribución normal estándar (media 0, desviación 1), ya que se asume que los errores de medida e incertidumbres siguen esta distribución. En la Figura 4-20, se puede observar que para un $k = 1$, el umbral abarca el 68,27% de probabilidad de que la innovación caiga dentro de ese rango. Finalmente se ha elegido $k = 2$, lo que implica que se acepta como válida cualquier innovación que esté dentro de dos veces la desviación estándar esperada del modelo, lo cual implica un margen estadístico del 95%. Un valor de k más alto aumentaría la tolerancia, pero también aumenta el riesgo de asociar medidas erróneas. Valores más bajos la reducen, pero aumentan las probabilidades de rechazar asociaciones correctas.

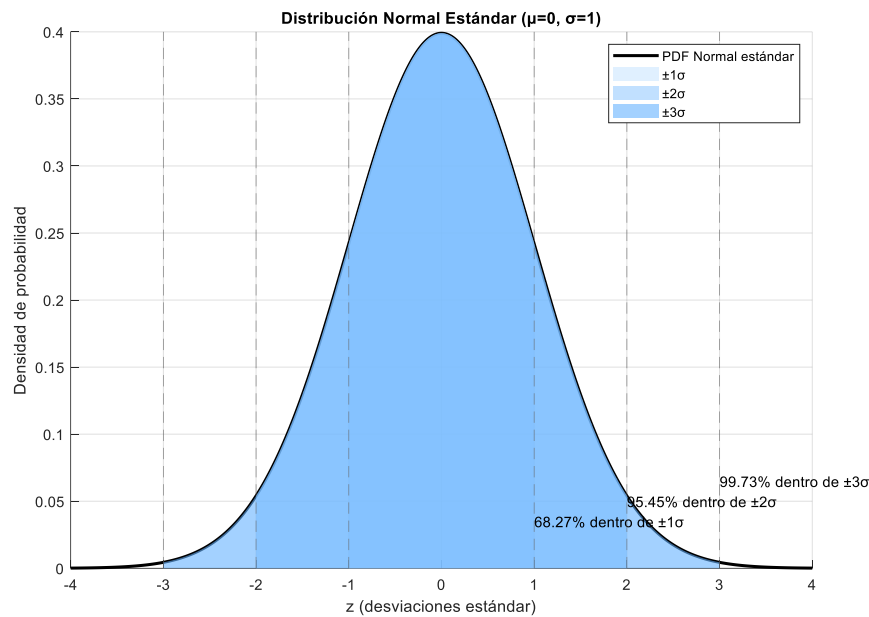


Figura 4-20 Probabilidad de asociación en una distribución normal según la desviación

Finalmente, se realiza la asociación comparando la innovación con el umbral:

$$\text{Si } |z_{det} - z_{pred}| < \text{threshold} \Rightarrow \text{asociar medida al blanco}$$

Este esquema permite un test de compatibilidad estadística, que respeta la geometría no lineal del problema y la incertidumbre en cada instante del filtro.

Para resolver la ambigüedad en la asociación de medidas a múltiples blancos, especialmente cuando varias medidas cumplen el test de compatibilidad estadística, se ha implementado el algoritmo de *Nearest Neighbor* (NN) como estrategia de selección final. Este enfoque propone asignar cada medida al objetivo cuya predicción esté más próxima a la observación, tras haber superado un test de validación estadístico basado en la incertidumbre [41]. El procedimiento se resume en la Figura 4-21, que muestra un esquema de asociación por el método NN.

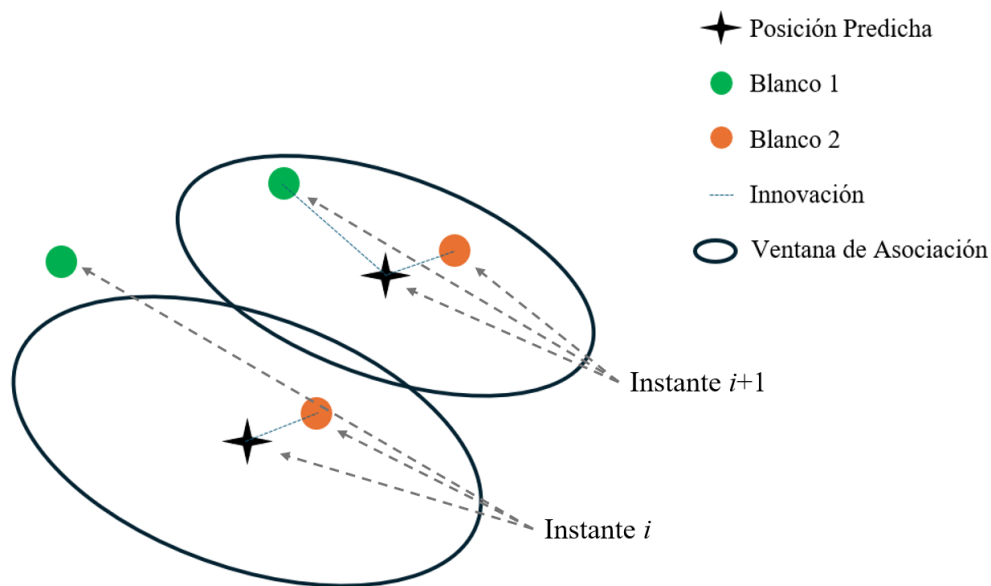


Figura 4-21 Esquemático de asociación por el método de *Nearest Neighbor* para dos instantes de medida consecutivos.

El principio de NN consiste en proyectar las posiciones estimadas de cada traza al instante actual (usualmente mediante un filtro de Kalman u otro predictor) y luego calcular la distancia entre cada medida y cada predicción. La medida se asocia a la traza que minimiza esta distancia. Si todas las distancias están dentro de un umbral (basado en la desviación estándar de la innovación), entonces la más cercana se selecciona como la asociación válida. Matemáticamente, si \hat{z} es la predicción y z_i una medida candidata:

$$v_i = |z_i - \hat{z}| \text{ y se selecciona } z_{\text{asociada}} = \arg \min_i v_i$$

Este enfoque convierte el problema de múltiples objetivos en varios problemas independientes de asociación 1 a 1, simplificando considerablemente la lógica. No obstante, esta simplicidad conlleva ciertas limitaciones. El algoritmo NN no gestiona de forma explícita falsas alarmas, blancos no detectados o la presencia de objetivos muy próximos entre sí, lo que puede provocar errores de asociación y degradar el rendimiento del filtro.

Si una pista no recibe asociaciones de *plots*, no se realiza la corrección. Se vuelve al principio de la iteración y el filtro vuelve a predecir para el siguiente instante de medida, pero sin haber realizado el proceso de corrección. Esto es independiente para cada uno de los objetivos, permitiendo el seguimiento de múltiples blancos simultáneos.

En la Figura 4-22 se muestra el resultado de la simulación de un escenario radar multiestático en un entorno urbano, en el que se han seguido tres objetivos móviles que describen trayectorias distintas, tanto en forma como en orientación. Las trayectorias reales están representadas con líneas continuas de colores (azul, naranja y amarillo), mientras que las trayectorias estimadas mediante el algoritmo de seguimiento aparecen marcadas con símbolos de asterisco del mismo color, pero con una tonalidad más clara y con línea discontinua.

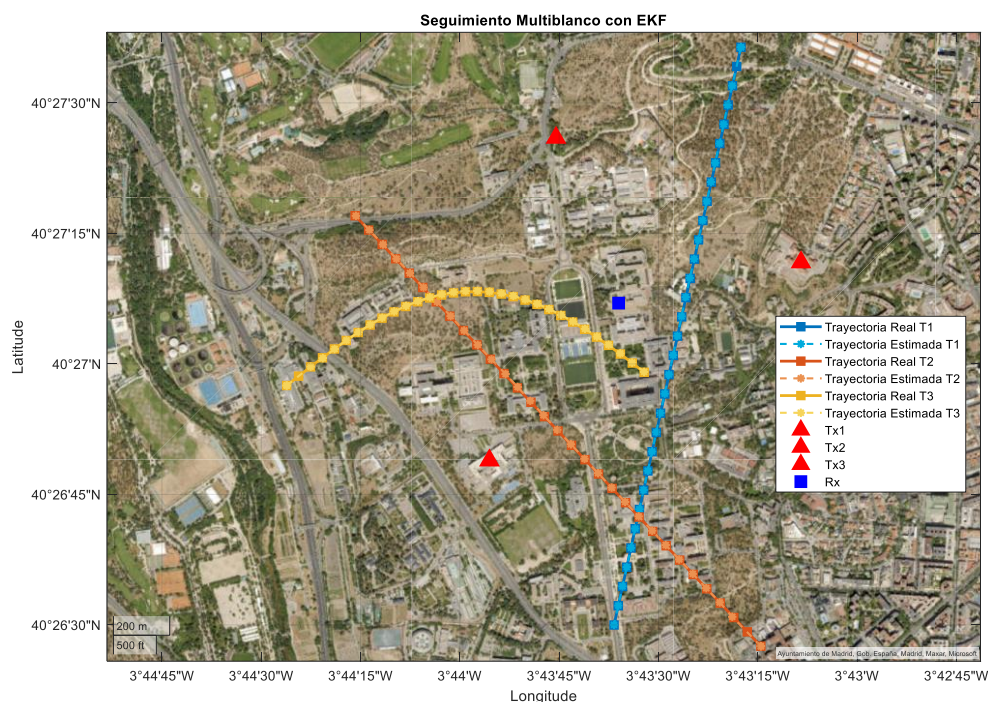


Figura 4-22 Resultado en mapa cartográfico de un proceso de asociación y seguimiento en radar multiestático

Para el seguimiento de los objetivos se ha empleado un Filtro de Kalman Extendido (EKF), adaptado para trabajar con medidas no lineales como las distancias biestáticas. La estimación de trayectorias se ha realizado a partir de estas medidas sintéticas, generadas entre transmisores (representados con triángulos rojos) y un único receptor (cuadrado azul). La asociación de medidas a trazas se ha gestionado mediante el algoritmo descrito previamente, basado en un test de validación estadística seguido de la regla de *Nearest Neighbor* para resolver ambigüedades.

El resultado demuestra que el algoritmo implementado es capaz de asociar de forma correcta las medidas a cada blanco, incluso en condiciones en las que las trayectorias de los objetivos se cruzan o se encuentran próximas entre sí. En la Figura 4-23 se presentan los errores medios de estimación de posición a lo largo del tiempo para cada uno de los filtros. Se observa que, tras un breve transitorio

inicial, necesario para que los filtros de seguimiento converjan, el error de estimación de la posición de los objetivos se mantiene, en todos los casos, por debajo de los 10 metros, validando así la efectividad del enfoque propuesto para aplicaciones de seguimiento urbano con múltiples objetivos.




Figura 4-23 Error medio de la predicción de los filtros para cada blanco

En escenarios multiobjetivo es habitual que varias distancias biestáticas entren dentro del rango de asociación, lo que genera ambigüedades en la asignación de detecciones a blancos. Para resolver este problema resulta especialmente útil disponer de la medida del ángulo de llegada (AoA), ya que aporta información adicional que permite desambiguar asociaciones que, de otro modo, serían indistinguibles.

En la Figura 4-24 se muestra el diagrama de flujo del algoritmo de seguimiento y asociación propuesto incorporando el uso del ángulo de llegada. A diferencia del esquema anterior, este algoritmo emplea la información angular cuando varias detecciones superan el test de compatibilidad estadística. En este caso, en lugar de aplicar directamente el método *Nearest Neighbor*, se utiliza el ángulo de llegada como criterio de asociación adicional.

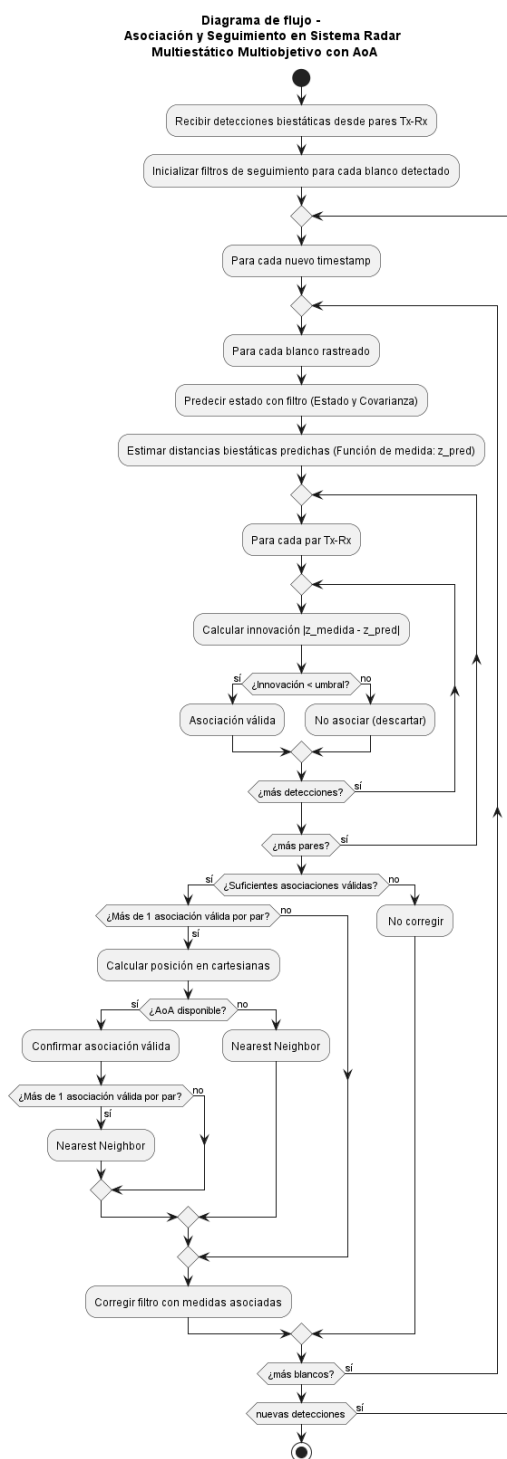


Figura 4-24 Diagrama de flujo del algoritmo de asociación y seguimiento en radar multiestático con medidas de ángulo de llegada

El procedimiento es el siguiente: cuando varias detecciones de un par transmisor-receptor podrían asociarse a un mismo blanco, y tras agotar las asociaciones posibles, se estima la posición del objetivo

en coordenadas cartesianas y se calcula el ángulo relativo al receptor. Dicho ángulo se compara con la medición de AoA. Si la diferencia entre ambos es menor al doble de la desviación estándar del ruido angular, la detección correspondiente se acepta como la asociación correcta y las demás se descartan. En el caso de que varias detecciones superen simultáneamente este test, se recurre al método de *Nearest Neighbor*, tal y como se hacía en el algoritmo base. Se ha optado por utilizar el doble de la desviación estándar porque este umbral equivale a un intervalo de confianza del 95%, lo que ofrece un buen equilibrio entre rechazar asociaciones incorrectas y mantener la probabilidad de aceptar las que realmente corresponden al blanco.

Una vez resueltas las asociaciones, el procedimiento continúa de la misma forma que en el algoritmo anterior: se actualiza el filtro de seguimiento con las detecciones validadas y se repite la iteración hasta procesar todas las medidas disponibles.

Se ha implementado el algoritmo de asociación basado en la medida del ángulo de llegada al receptor para un escenario donde los blancos que siguen las mismas trayectorias que en el caso anterior. Los errores medios de predicción en el tiempo para cada blanco obtenidos se muestran en la Figura 4-25. Los resultados son muy similares a los del caso previo, dado que la información del ángulo de llegada se ha empleado para la asociación de las medidas y no para la predicción.




Figura 4-25 Error medio de la predicción de los filtros para cada blanco con medida de AoA

5. CONCLUSIONES Y LÍNEAS FUTURAS

5.1. CONCLUSIONES

Este trabajo ha permitido analizar y evaluar diferentes aspectos relacionados con la arquitectura de los sistemas radar multiestáticos y las técnicas de seguimiento de objetivos.

En primer lugar, se ha demostrado que las particularidades de la arquitectura y del procesado en sistemas multiestáticos derivan en un sistema de detección con una precisión elevada en las zonas definidas para la vigilancia, siempre que la disposición de transmisores y receptores esté adecuadamente distribuida. Una geometría bien planteada, que favorezca la intersección clara de las elipses de distancia biestática, resulta fundamental para reducir las ambigüedades e incertidumbre de localización. El incremento en el número de nodos (transmisores y/o receptores) contribuye a mejorar el proceso de multilateración: en las regiones cercanas a los transmisores la mejora se traduce en unos pocos metros, mientras que, en las áreas más alejadas, donde las intersecciones presentan mayor ambigüedad, la reducción del error puede alcanzar la decena de metros. No obstante, esta ganancia en precisión se obtiene a costa de un mayor coste computacional, lo que introduce un compromiso entre exactitud y eficiencia.

En cuanto a la incorporación de la medida de ángulo de llegada, los resultados muestran que su impacto sobre la precisión global de la multilateración es reducido debido a la elevada incertidumbre angular considerada y su limitación por tamaños viables de *arrays* de antenas desplegables en entornos urbanos. Su principal utilidad no radica en la mejora directa de la estimación de posición, sino en la resolución de ambigüedades en escenarios multiobjetivo. En este tipo de situaciones, donde pueden aparecer blancos fantasmas o asociaciones incorrectas, la información angular aporta un criterio adicional que facilita el proceso de asociación y reduce la probabilidad de una asociación errónea.

Por otro lado, se ha comprobado que las no linealidades inherentes al espacio de medida hacen poco adecuado el uso de filtros lineales de seguimiento. En particular, el filtro de Kalman lineal presenta un rendimiento inferior debido a que depende de una multilateración previa, para adaptar el espacio de medida al espacio de estado, la cual introduce un error adicional en la estimación. En cambio, los filtros no lineales permiten trabajar directamente con las medidas ruidosas extraídas del procesado radar, lo que mejora de la capacidad de predicción y corrección.

En este sentido, tanto el Filtro de Kalman Extendido (EKF) como el *Unscented Kalman Filter* (UKF) han demostrado un comportamiento muy similar en los escenarios evaluados, ofreciendo resultados precisos y con un coste computacional relativamente bajo. El Filtro de Partículas, si bien proporciona estimaciones al mismo nivel de calidad que los anteriores, presenta un coste de cálculo mucho más elevado debido a la necesidad de manejar un gran número de partículas. Por tanto, no se considera

idóneo en los casos estudiados, siendo suficiente recurrir al Filtro de Kalman Extendido, que equilibra adecuadamente precisión y eficiencia computacional.

El proceso de asociación, por su parte, constituye un elemento clave en la correcta actualización de las trayectorias, representadas como pistas, en escenarios con múltiples objetivos. Se ha comprobado que este procedimiento, basado en la relación entre las detecciones y los objetivos en movimiento, puede implementarse de forma efectiva mediante el uso de filtros de seguimiento que proporcionan predicciones para establecer ventanas de asociación basadas en umbrales dinámicos de compatibilidad en cada instante de tiempo. En las simulaciones realizadas, el algoritmo de asociación implementado ha demostrado un funcionamiento adecuado. Asimismo, la incorporación de la medida de ángulo de llegada aporta una mejora sustancial frente a ambigüedades generadas por múltiples detecciones válidas en un mismo par, al permitir sustituir el criterio de *Nearest Neighbor* por una asociación apoyada en la consistencia angular, lo que confiere al sistema una mayor robustez en escenarios complejos.

La herramienta desarrollada que permite simular escenarios arbitrarios de sistemas radar multiestáticos y la aplicación de algoritmos de seguimiento, incluyendo la asociación de *plots* a pistas, no sólo posibilita la evaluación de las capacidades de estos algoritmos para distintas dinámicas de blancos y geometrías del escenario, sino que también puede ser empleada para realizar la optimización de despliegues de estos sistemas de vigilancia en entornos urbanos y la selección de los iluminadores de oportunidad considerados en arquitecturas de radar pasivo.

5.2. LÍNEAS FUTURAS

En este trabajo se han llevado a cabo simulaciones de arquitecturas multiestáticas para evaluar su comportamiento y evaluar la eficacia de los algoritmos de localización, seguimiento y asociación implementados. Sin embargo, como toda investigación basada en entornos simulados, los resultados constituyen un punto de partida que puede y debe ser ampliado en el futuro para aproximarse de manera más fiel a la realidad de los sistemas pasivos.

Una primera línea de trabajo consiste en considerar con mayor detalle las características reales de los transmisores utilizados. En las simulaciones desarrolladas se han modelado transmisores omnidireccionales, lo cual simplifica el análisis; no obstante, en la práctica, las antenas de telefonía presentan un carácter sectorial y limitaciones específicas en cuanto a cobertura angular y nivel de señal. La incorporación de estas restricciones en el modelado permitiría obtener simulaciones más realistas, especialmente en entornos urbanos, donde la presencia de edificios y obstáculos refuerza la necesidad de un análisis detallado de la cobertura efectiva. Además, se podría simular la operación de los algoritmos de asociación y seguimiento incorporando falsas alarmas y considerando una probabilidad

de detección de los objetivos para cada par transmisor-receptor relacionada con su SNR estimada en función de su distancia al transmisor y receptor.

Otra línea de investigación se centra en la validación experimental de los resultados obtenidos. Para ello, se podría realizar un despliegue controlado de receptores siguiendo las configuraciones propuestas en este trabajo. Dicho despliegue permitiría comprobar de forma práctica el funcionamiento de los algoritmos de multilateración, filtrado y asociación, así como contrastar los errores asumidos en las simulaciones con mediciones reales. Esta comparación aportaría información valiosa para ajustar modelos, afinar los parámetros de los filtros y cuantificar las diferencias entre un entorno idealizado y la realidad operativa.

Adicionalmente, futuras investigaciones podrían explorar la optimización de la arquitectura desde un punto de vista computacional. En particular, el elevado coste de algunos filtros como el de partículas abre la puerta al estudio de técnicas híbridas o de reducción de complejidad que permitan mantener un rendimiento elevado sin comprometer la eficiencia. Del mismo modo, ampliar las pruebas a escenarios con mayor densidad de objetivos o con trayectorias más complejas permitiría evaluar la robustez del proceso de asociación en condiciones más exigentes.

6. BIBLIOGRAFÍA

- [1] H. Griffiths, «Early history of bistatic radar,» de *2016 European Radar Conference (EuRAD)*, London, UK, 2016.
- [2] N. H. Nguyen y K. Dogancay, *Signal Processing for Multistatic Radar Systems: Adaptive Waveform Selection, Optimal Geometries and Pseudolinear Tracking Algorithms*, Academic Press, 2020.
- [3] N. J. Willis, *Bistatic radar*, vol. 2, SciTech Publishing, 2005.
- [4] V. S. Chernyak, *Fundamentals of multisite radar systems: multistatic radars and multistatic radar systems*, Routledge, 2018.
- [5] H. D. Griffiths y C. J. Baker, *An introduction to passive radar*, Artech House, 2022.
- [6] M. Malanowski, K. Kulpa, J. Kulpa, P. Samczynski y J. Misiurewicz, «Analysis of detection range of FM-based passive radar,» *IET Radar, Sonar & Navigation*, vol. 8, n° 2, pp. 153-159, 2014.
- [7] J. E. Palmer, H. A. Harms, S. J. Searle y L. Davis, «DVB-T passive radar signal processing,» *IEEE transactions on Signal Processing*, vol. 61, n° 8, pp. 2116-2126, 2012.
- [8] B. Knoedler, C. Steffes y W. Koch, «Detecting and tracking a small uav in gsm passive radar using track-before-detect,» de *IEEE Radar Conference (RadarConf20)*, Florence, Italy, 2020.
- [9] Z. Geng, R. Xu y H. Deng, «LTE-based multistatic passive radar system for UAV detection,» *IET Radar, Sonar & Navigation*, vol. 14, n° 7, pp. 1088-1097, 2020.
- [10] F. Santi, I. Pisciotano, D. Pastina y D. Cristallini, «Multi-angle DVB-S based passive ISAR sensitivity to target motion estimation errors,» de *IEEE Radar Conference (RadarConf23)*, San Antonio, TX, USA, 2023.
- [11] H. Ma, M. Antoniou, A. G. Stove, J. Winkel y M. Cherniakov, «Maritime moving target localization using passive GNSS-based multistatic radar,» *IEEE Transactions on Geoscience and Remote Sensing*, vol. 56, n° 8, pp. 4808-4819, 2018.

-
- [12] R. Blázquez-García, D. Cristallini, M. Ummenhofer, V. Seidel, J. Heckenbach y D. O'Hagan, «Capabilities and challenges of passive radar systems based on broadband low-Earth orbit communication satellites,» *IET Radar, Sonar & Navigation*, vol. 18, nº 1, pp. 78-92, 2024.
- [13] P. Samczynski, P. Krysik y K. Kulpa, «Passive radars utilizing pulse radars as illuminators of opportunity,» de *IEEE Radar Conference*, 2015.
- [14] H. Griffiths, L. Cohen, S. Watts, E. Mokole, C. Baker, M. Wicks y S. Blunt, «Radar spectrum engineering and management: Technical and regulatory issues,» *Proceedings of the IEEE*, vol. 103, nº 1, pp. 85-102, 2014.
- [15] P. J. Beasley y M. A. Ritchie, «Development of an active and passive, multistatic enabled, radar system,» de *18th European Radar Conference (EuRAD)*, 2021.
- [16] E. T. Michailidis, K. Maliatsos y D. Vouyioukas, «Software-Defined Radio Deployments in UAV-Driven Applications: A Comprehensive Review,» *IEEE Open Journal of Vehicular Technology*, 2024.
- [17] T. Ulversoy, «Software Defined Radio: Challenges and Opportunities,» *IEEE Communications Surveys & Tutorials*, vol. 12, nº 4, pp. 531-550, 2010.
- [18] Comisión Nacional de los Mercados y la Competencia (CNMC), «Telecomunicaciones y Audiovisual: Informe Económico-Sectorial 2024,» Informe ESTAD/CNMC/004/25, 2025.
- [19] C. E. Papadopoulos y H. Yeung, «Uncertainty estimation and Monte Carlo simulation method,» *Flow Measurement and Instrumentation*, vol. 12, nº 4, pp. 291-298, 2001.
- [20] M. H. Kalos y P. A. Whitlock, *Monte Carlo Methods*, Wiley-VCH, 2008.
- [21] Hensoldt, «Twinvis Passive Radar Datasheet,» 2024. [En línea]. Available: <https://dam.hensoldt.net/m/51e84e07b501246e/original/Twinvis-Passive-Radar-Datasheet-English.pdf>. [Último acceso: 15 Marzo 2025].
- [22] V. J. Amuso, J. Standley, D. Fränken y S. Lutz, «The Benefits of a Networked Distributed Surveillance Architecture Using Both Cooperative and Non-Cooperative Sensing Systems,» de *Integrated Communication, Navigation and Surveillance Conference (ICNS)*, Dulles, VA, EEUU, 2022.

-
- [23] P. Valpolini, «FCAS sensor network takes off: German industry wins contract under the Future Combat Air System programme,» *EDR Magazine*, 7 Febrero 2023.
- [24] S. Saillant, D. Bok, J.-P. Molinié, A. Leventis, P. Samczynski y col., «IEEE Radar Conference,» de *iFURTHER Project -A Cognitive Network of HF Radars for Europe Defence*, Sydney, Australia, 2023.
- [25] H. Wilden, C. Kirchner, O. Peters, N. B. Bekhti, A. Brenner y T. Eversberg, «GESTRA — A phased-array based surveillance and tracking radar for space situational awareness,» de *2016 IEEE International Symposium on Phased Array Systems and Technology (PAST)*, Waltham, MA, USA, 2016.
- [26] Z. He, W. Xu, H. Shen, D. W. K. Ng, Y. C. Eldar y X. You, «Full-duplex communication for ISAC: Joint beamforming and power optimization,» *IEEE Journal on Selected Areas in Communications*, vol. 41, nº 9, pp. 2920-2936, 2023.
- [27] H. Ma, «Integrated Sensing and Communication - The ISAC Technology,» de *2024 IEEE 2nd International Conference on Sensors, Electronics and Computer Engineering (ICSECE)*, Jinzhou, China, 2024.
- [28] S. Bendett y N. Leonid, «The drone war over Ukraine,» de *The Air War in Ukraine*, Routledge, 2024, pp. 168-194.
- [29] F. Gregory, «The Use of Modified Commercial Drones in Ukraine: Adoption Capacity Theory and Adaptation under Fire in Practice,» *Emerging Threats & Technology Working Group*, 4 Marzo 2025.
- [30] M. Malanowski, *Signal Processing for Passive Bistatic Radar*, Artech, 2019.
- [31] D. Cristallini y D. W. O'Hagan, *Passive Radars on Moving Platforms*, IET, 2023.
- [32] O. Kanhere, S. Goyal, M. Beluri y T. S. Rappaport, «Target localization using bistatic and multistatic radar with 5G NR waveform,» de *IEEE 93rd Vehicular Technology Conference (VTC2021-Spring)*, Helsinki, Finland, 2021.
- [33] MATLAB, «`lsqcurvefit`,» [En línea]. Available: <https://es.mathworks.com/help/optim/ug/lsqcurvefit.html>.
- [34] M. C. Budge y S. R. German, *Basic Radar Tracking*, Artech, 2019.

-
- [35] P. S. Madhukar y L. B. Prasad, «State Estimation using Extended Kalman Filter and Unscented Kalman Filter,» de *2020 International Conference on Emerging Trends in Communication, Control and Computing (ICONC3)*, Lakshmanagarh, India, 2020.
- [36] S. J. Julier y J. Uhlmann, «Unscented filtering and nonlinear estimation,» *Proceedings of the IEEE*, vol. 92, nº 3, pp. 401-422, 2004.
- [37] S. Duboisson, *Tracking with Particle Filter for High-Dimensional Observation and State Spaces*, John Wiley & Sons, 2015.
- [38] S. Blackman y R. Popoli, *Design and Analysis of Modern Tracking Systems*, Artech, 1999.
- [39] Secretaría de estado para la sociedad de la información y la agenda digital, Gobierno de España, «Infoantenas,» [En línea]. Available: <https://geoportal.minetur.gob.es/VCTEL/vcne.do>.
- [40] G. J. McLachlan, «Mahalanobis distance,» *Resonance*, vol. 4, nº 6, pp. 20-26, 1999.
- [41] T. Kirubarajan y Y. Bar-Shalom, «Target Tracking Using Probabilistic Data Association-Based Techniques with Applications to Sonar, Radar, and EO Sensors,» de *Multisensor Data Fusion*, CRC Press, 2009, p. 223–262.

ANEXO A: ASPECTOS ÉTICOS, ECONÓMICOS, SOCIALES Y AMBIENTALES

A.1 INTRODUCCIÓN

El presente Trabajo de Fin de Máster se enmarca en el ámbito de los sistemas de localización y seguimiento de objetivos mediante radares multiestáticos, con especial atención a los radares pasivos. Se trata de un área de investigación con una relevancia creciente en la actualidad, ya que combina desarrollos tecnológicos avanzados con implicaciones sociales, económicas, legales y ambientales de gran interés. La localización y seguimiento de objetivos en movimiento mediante sistemas radar multiestáticos constituye un reto técnico complejo, derivado de la naturaleza no lineal de la relación entre el espacio de medida y el espacio de estado. Esto dificulta el uso de filtros lineales convencionales y plantea la necesidad de recurrir a filtros no lineales y técnicas de seguimiento y asociación de detecciones.

El objetivo principal del proyecto ha sido desarrollar, implementar y analizar algoritmos en un entorno simulado que permitan evaluar la precisión de localización y predicción de los filtros de seguimiento en escenarios realistas y con múltiples objetivos. Para alcanzar este propósito, se han estudiado los fundamentos de los radares biestáticos, multiestáticos y pasivos, así como diferentes enfoques de filtrado y asociación. La finalidad última es disponer de una base sólida para el diseño de sistemas más precisos y robustos, capaces de responder a necesidades presentes en ámbitos como la seguridad, la defensa, la gestión del tráfico aéreo o la monitorización del espacio aéreo.

Más allá de su dimensión técnica, este trabajo aborda problemáticas con claras implicaciones sociales, económicas y ambientales. Desde el punto de vista social, un sistema de localización fiable puede mejorar la seguridad y la capacidad de prevención de incidentes, contribuyendo directamente a la protección de la población. Además, podría ser utilizado para desarrollar sistemas del control de tráfico aéreo en entornos urbanos que sean aplicables a nuevos conceptos de movilidad y logística. En el ámbito económico, la introducción de soluciones basadas en radares pasivos y en hardware de bajo coste tipo SDR (*Software Defined Radios*) como COTS permite reducir significativamente los costes de instalación y operación, aumentando la viabilidad de este tipo de sistemas en distintos escenarios. En el plano legal, la ventaja de los radares pasivos es evidente, ya que aprovechan emisores existentes y no requieren transmisiones propias, evitando así la ocupación de nuevas bandas del espectro radioeléctrico, un recurso limitado y fuertemente regulado. Finalmente, en el plano ambiental, la ausencia de emisiones

y la reducción del consumo energético los convierten en una alternativa más sostenible frente a tecnologías tradicionales.

A.2 DESCRIPCIÓN DE IMPACTOS RELEVANTES RELACIONADOS CON EL PROYECTO

Durante la fase de análisis de impactos, se han identificado una serie de aspectos clave en los que el proyecto tiene una incidencia directa. Estos impactos se agrupan principalmente en los planos social, económico, legal y ambiental, y constituyen los ejes centrales de su sostenibilidad.

En el ámbito económico, el impacto más relevante es la posibilidad de reducir costes de instalación y mantenimiento al aprovechar infraestructuras ya existentes. El radar pasivo elimina la necesidad de transmisores propios, y el uso de SDR como hardware comercial estándar de bajo coste ofrece una flexibilidad y escalabilidad difícilmente alcanzable con soluciones hardware específicas. Esto abre la puerta a aplicaciones prácticas con presupuestos reducidos y convierte la tecnología en una opción atractiva tanto para instituciones públicas como privadas.

Desde la perspectiva social, la capacidad de mejorar la seguridad y la fiabilidad en la localización de objetivos resulta fundamental. Aplicaciones como la gestión del tráfico aéreo, la protección de fronteras o la monitorización del espacio aéreo tienen un impacto directo en la seguridad de la población, y un sistema de localización preciso puede reducir riesgos, facilitar la detección temprana de amenazas y optimizar la gestión de emergencias.

En el plano legal, la ventaja clave radica en la reutilización del espectro electromagnético. Dado que los radares pasivos no requieren emitir señales propias, no es necesario solicitar nuevas licencias ni ocupar bandas adicionales, lo que garantiza el cumplimiento normativo y evita conflictos con otros servicios de radiocomunicaciones. Este aspecto es especialmente relevante en contextos en los que el espectro está fuertemente regulado y saturado.

Finalmente, en términos ambientales, el proyecto apunta a una reducción significativa en el consumo energético frente a los radares activos. Al no requerir transmisores, los sistemas pasivos hacen un uso más eficiente de la energía, lo que contribuye a una menor huella de carbono y los convierte en una alternativa tecnológica más alineada con los objetivos de sostenibilidad.

A partir de este análisis, se han identificado como principales grupos de interés: las administraciones públicas (encargadas de la regulación del espacio aéreo y la seguridad), los operadores de transporte y telecomunicaciones (beneficiarios de una mayor eficiencia en la gestión del tráfico), la industria

tecnológica (que encuentra en el radar pasivo una vía de innovación con costes reducidos), y la sociedad en general, que se beneficia de mejoras en seguridad y sostenibilidad.

A.3 ANÁLISIS DETALLADO DE ALGUNO DE LOS PRINCIPALES IMPACTOS

De entre los impactos analizados, el aspecto económico vinculado al empleo de SDR como componentes COTS resulta especialmente relevante. La adopción de este tipo de hardware permite reducir drásticamente los costes iniciales de desarrollo y despliegue, al tiempo que ofrece una gran adaptabilidad. Mientras que en los radares tradicionales es necesario diseñar y fabricar equipos específicos para cada aplicación, el uso de SDR posibilita adaptar mediante software un mismo hardware a múltiples configuraciones y escenarios.

Esta flexibilidad no solo tiene un impacto directo en la investigación y el desarrollo, al facilitar la experimentación en entornos controlados, sino que también repercute en la escalabilidad de los sistemas una vez desplegados en aplicaciones prácticas. En sectores donde los presupuestos son limitados, esta reducción de costes puede marcar la diferencia entre la viabilidad o no de un proyecto tecnológico. Además, en el ámbito de la defensa, el empleo de tecnologías COTS permite reducir la dependencia de proveedores específicos, lo cual incrementa la resiliencia y favorece la competitividad industrial.

Además, el desarrollo de la herramienta de análisis y simulación de los algoritmos de localización y seguimiento en sistemas radar multiestáticos no solo posibilita la evaluación de las capacidades alcanzables de los sistemas en determinados escenarios, sino que también permite llevar a cabo el diseño y optimización de despliegues sin necesidad de realizar costosas medidas de campo.

El impacto económico positivo se complementa con beneficios indirectos de carácter social y ambiental: la reducción de costes facilita la adopción de tecnologías de localización más avanzadas, mejorando la seguridad ciudadana, mientras que la eficiencia energética inherente a los radares pasivos contribuye a una disminución del consumo global de recursos.

A.4 CONCLUSIONES

El análisis realizado permite concluir que el proyecto no solo aborda un reto técnico de gran complejidad, sino que también se enmarca en un contexto más amplio en el que convergen dimensiones sociales, económicas, legales y ambientales. Desde un punto de vista ético, el desarrollo de tecnologías

que mejoran la seguridad y optimizan el uso de recursos responde a la necesidad de avanzar hacia sistemas más responsables y sostenibles.

Socialmente, la contribución más destacada radica en la mejora de la seguridad y la fiabilidad en la localización y seguimiento de objetivos, con aplicaciones directas en sectores críticos como el transporte aéreo o la protección de fronteras. Económicamente, la reducción de costes derivada del empleo de radares pasivos y SDR como hardware COTS amplía el acceso a estas tecnologías y favorece su adopción en distintos escenarios. En el plano legal, el radar pasivo se presenta como una alternativa compatible con los marcos regulatorios existentes, al no requerir emisiones adicionales ni nuevas licencias de espectro. Por último, en el plano ambiental, se subraya la reducción del consumo energético y la consecuente disminución del impacto ambiental frente a soluciones activas tradicionales.

En conjunto, el uso de criterios de sostenibilidad aporta un valor añadido significativo al proyecto. No se trata únicamente de una investigación orientada a la mejora técnica, sino de un trabajo que propone soluciones coherentes con las demandas actuales de eficiencia, sostenibilidad y responsabilidad social. Esto refuerza su pertinencia y lo sitúa como un ejemplo de cómo la ingeniería puede contribuir a un desarrollo tecnológico alineado con los retos globales.

ANEXO B: PRESUPUESTO ECONÓMICO

En este anexo se presenta en la Tabla 9-1 un desglose detallado del presupuesto asociado al trabajo realizado. La información incluye los costes vinculados al diseño y desarrollo de los entornos de simulación en un sistema de radar pasivo, considerando equipos y licencias de software, gastos de mano de obra y costes indirectos. Este análisis económico tiene como objetivo garantizar la transparencia del proyecto y poner de manifiesto la viabilidad y la planificación necesarias para su correcta ejecución.

COSTE DE MANO DE OBRA (coste directo)

| Horas | Precio/hora | Total |
|-------|-------------|-----------------|
| 800 | 15 € | 12.000 € |

COSTE DE RECURSOS MATERIALES (coste directo)

| | Precio de compra | Uso en meses | Amortización (en años) | Total |
|--|------------------|--------------|------------------------|----------|
| Ordenador personal (Software incluido) | 1.500,00 € | 6 | 5 | 150,00 € |
| Licencia MATLAB | 3.000,00 € | 6 | 5 | 300,00 € |

COSTE TOTAL DE RECURSOS MATERIALES

450,00 €

GASTOS GENERALES (costes indirectos)

15%

sobre CD

1.867,50 €

BENEFICIO INDUSTRIAL

6%

sobre CD+CI

859,05 €

SUBTOTAL PRESUPUESTO

15.176,55 €

IVA APLICABLE

21%

3.187,08 €

TOTAL, PRESUPUESTO

18.363,63 €

Tabla 9-1 Presupuesto económico