### Universidad de Las Palmas de Gran Canaria

DEPARTAMENTO DE SEÑALES Y COMUNICACIONES

**Programa de Doctorado** Cibernética y Telecomunicación



## **TESIS DOCTORAL**

### Nuevos Algoritmos de Localización, Seguimiento e Identificación de Fuentes en Escenarios con Agrupaciones de Sensores Concentradas y Distribuidas

Autor Eduardo Hernández Pérez

Director Dr. Juan Luis Navarro Mesa

Las Palmas de Gran Canaria

Mayo 2010



#### DON PEDRO JOSE QUINTANA MORALES, SECRETARIO DEL DEPARTAMENTO DE SEÑALES Y COMUNICACIONES DE LA UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA.

#### CERTIFICA:

Que el Consejo de Doctores del Departamento en su sesión de fecha siete de mayo de dos mil diez, tomó el acuerdo de dar el consentimiento para su tramitación, a la tesis doctoral titulada "NUEVOS ALGORITMOS DE LOCALIZACIÓN, SEGUIMIENTO E IDENTIFICACIÓN DE FUENTES EN ESCENARIOS CON AGRUPACIONES DE SENSORES CONCENTRADAS Y DISTRIBUIDAS", presentada por el doctorando Don Eduardo Hernández Pérez y dirigida por el doctor Don Juan Luis Navarro Mesa.

Y para que así conste, y a efectos de los previsto en el artículo 73.2 del Reglamento de Estudios de Doctorado de esta Universidad, firma la presente en Las Palmas de Gran Canaria a, siete de mayo de dos mil diez.



Edificio de Electrónica y Telecomunicaciones Campus de Tafira 35017 Las Palmas de Gran Canaria

### Universidad de Las Palmas de Gran Canaria

DEPARTAMENTO DE SEÑALES Y COMUNICACIONES

Programa de Doctorado Cibernética y Telecomunicación



### **TESIS DOCTORAL**

### Nuevos Algoritmos de Localización, Seguimiento e Identificación de Fuentes en Escenarios con Agrupaciones de Sensores Concentradas y Distribuidas

AUTOR: Eduardo Hernández Pérez

DIRECTOR: Dr. Juan Luis Navarro Mesa

**El Director** 

El Doctorando

Las Palmas de Gran Canaria, Mayo de 2010

#### A mi madre,

porque siempre ha estado ahí, porque siempre ha creído en mi, por quererme sin medida incluso cuando no lo he merecido, gracias de corazón MAMA

#### A mis hijos Adrián y Eduardo,

por ser como son, tan distintos a mí y tan especiales para mi, por su silencio, por mis ausencias, por su espera, por todo lo que nunca les he dicho, gracias MUCHACHOS

> Casi todo lo que realice será insignificante, pero es muy importante que lo haga. (Mahatma Gandhi)

A lo largo del tiempo dedicado a esta tarea he compartido mi vida con muchas y diversas personas que han querido a su vez compartir conmigo cosas muy valiosas, su tiempo, su presencia, su amistad, su cariño, sus mejores deseos, sus conocimientos, etc., a todas ellas sin excepción un millón de gracias. No obstante, hay algunas a las que debo nombrar porque las he sentido muy cerca todo este tiempo.

En primer lugar y sin duda alguna debe estar mi director de tesis Juan Luis, su dedicación, sus aportaciones, sus correcciones, su insatisfacción permanente, su positividad y su entusiasmo, han logrado que yo terminara la tesis, GRACIAS GRACIAS, GRACIAS. En segundo lugar y sin que el orden altere en este caso la calidad del producto tengo que nombrar a los que considero mis compañeros y amigos de viaje más directos. Me emociona saber que no han dudado en facilitar mi tarea regalándome lo que tenían para dar, en algunos casos casi sin pedirlo: Juan Manuel (cine, música, humo, buen humor y nuestra Unión Deportiva), Manolo (camarada donde los haya), Montse (o como ser feliz siempre en cualquier circunstancia y lugar, espero seguir aprendiendo), Javier (la bondad y la generosidad viven arriba), Dioni (el yoga, los retiros y esa paciencia suya), Francisco Eugenio (incondicional de la causa), Fidel (el herreño inagotable) y Elena (un baluarte que siempre está ahí).

A Suso Vega, por haberme mostrado el camino de la solidaridad en el que aún soy sólo un aprendiz, Elena Henríquez (la que siempre ve las cosas como son) y Myriam (valiente, clara y decidida), que bonita amistad nos une con Malawi de fondo. A mis amigos de Labay, Amado, Mila, Jose, Antonio,... con los que espero volver a caminar nuevamente por todos los rincones de Gran Canaria.

A todos mis compañeros y amigos de la EUITT y del departamento de Señales y Comunicaciones por su constante aliento y apoyo, espero y deseo que aquellos que lo necesiten encuentren las fuerzas y el ánimo suficientes para hacer lo que tengan que hacer, los quiero ver pronto aquí mismito.

A todos los estudiantes que han compartido horas de aula, exámenes, proyectos y tutorías conmigo, y a los que seguramente habré fallado en algún momento de zozobra y hasta de egoísmo.

A quién ha compartido mi camino día a día en el pasado, por largo tiempo, porque seguro que me dio todo lo que podía darme, sólo espero haber correspondido en igual medida.

A Manuel Cubero por tantos y tantos ejemplos de cómo ser un señor en cualquier circunstancia. A Eduardo Rovaris y Rafa Pérez, por su fe en mí con su eterna pregunta ¿Cuándo terminas la tesis? Y como no, a todos mis profesores de los cursos de doctorado, a los que aprecio y admiro.

# Índice

Resumen				
Ak	ostra	act		XV
1.	Int	roducción		
	1.1	Motiu	vación y Objetivos	2
		1.1.1	La Localización desde la Perspectiva del Tipo de Información Básica	3
		1.1.2	Agrupaciones de Sensores Concentradas frente a Distribuidas y el Problema de la Localización	5
		1.1.3	Seguimiento Basado en la Distribución de los Sensores y el Tipo de Movimiento de las Fuentes	8
		1.1.4	Identificación de Fuente con Técnicas Paramétricas e Inclusión en el Proceso de Localización	10
	1.2	Orga	nización de la Memoria de Tesis	12
	1.3	Prine	cipales Contribuciones	14
		1.3.1	Agrupaciones Concentradas de Sensores – Nuevos Algoritmos de Localización, Seguimiento e Identificación de Cachalotes	15
		1.3.2	Agrupaciones Distribuidas de Sensores – Nuevos Algoritmos de Localización y Seguimiento con Redes Inalámbricas de Sensores	16

	En	Entorno		
	2.1	Propagación en entornos acústicos submarinos		20
		2.1.1	Pérdidas por Transmisión	23
		2.1.2	Ruido y Reverberación	27
		2.1.3	Propagación Multitrayecto	31
		2.1.4	Dispersión Doppler	35
	2.2	Prop	agación en Entornos Electromagnéticos Aéreos	37
		2.2.1	Modos de Propagación	39
		2.2.2	Ruido, Interferencia y Absorción	44
		2.2.3	Modelos de Propagación	45
		2.2.4	Técnicas de Transmisión y Modulación en LR-WPANs	54
	2.3	Tipos	s de Sensores e Información Básica de Interés	57
		2.3.1	Sensores en Agrupaciones Concentradas-Información Básica	58
		2.3.2	Nodos Inalámbricos en Agrupaciones Distribuidas-Información Básica	61
	2.4	Agru	paciones Concentradas de Sensores	66
		2.4.1	Agrupaciones Lineales	68
		2.4.2	Agrupaciones Bidimensionales	75
		2.4.3	Agrupaciones Tridimensionales	79
		2.4.4	Ancho de Banda de una Agrupación y Señales de Banda Ancha	82
	2.5	.5 Despliegue de Nodos Sensores y Topología de la Red en Agrupaciones Distribuidas		
		2.5.1	Despliegue de Nodos Sensores	84
		2.5.2	Topología de la Red	88
3.	Ag alg	rupac oritm	ciones Concentradas de Sensores - Nuevos nos de Localización, Seguimiento e	
	Ide	ntific	cación de Cachalotes	93
	3.1	Aplic	caciones Acústicas para el Estudio de los Cetáceos	95
	<i>3.2</i>	Ento: Subn	Entorno de Simulación de Propagación Acústica Submarina	
	3.3	El pr	oblema de la Estimación de la Dirección de Llegada	101
		3.3.1	Detección de Clics de Cachalotes	103
		3.3.2	Estimación DOA No-Paramétrica	107
		3.3.3	Estimación DOA Paramétrica	124

2. Modelos de Propagación de Señales y Muestreo del

	3.4	El pr medi	oblema del Seguimiento de Móviles y Aproximación ante Medidas de DOA	134
		3.4.1	El Modelo de Observación	135
		3.4.2	Seguimiento basado en un Vector de Estados y Medidas Relacionadas con la DOA	138
	3.5	Algor Ident	ritmo de Estimación Conjunta de DOA e tificación de Fuentes	145
		3.5.1	Modelado mediante Procesos AR y ARMA de Clics de Cachalotes	147
		3.5.2	Algoritmo de Estimación DOA Específico de Fuentes AR	153
		3.5.3	Algoritmos de Estimación DOA Específico de Fuentes ARMA	157
		3.5.4	Algoritmo de Identificación de Cachalotes	167
		3.5.5	Algoritmo Conjunto de Localización, Identificación y Seguimiento	172
	3.6	Expe	rimentos y Resultados	176
		3.6.1	Resultados del Modelado de Clics de Cachalotes Mediante Procesos AR y ARMA	176
		3.6.2	Simulaciones con los Algoritmos de Estimación DOA Específico de Fuentes AR y ARMA. Una Fuente	184
		3.6.3	Simulaciones con los Algoritmos de Estimación DOA Específico de Fuentes AR y ARMA. Dos Fuentes	197
		3.6.4	Simulaciones con el Algoritmo de Identificación	207
		3.6.5	Simulaciones con Algoritmo Conjunto de Localización, Identificación y Seguimiento	214
4.	Agı Alg Ina	rupac goritn lámb	ciones Distribuidas de Sensores – Nuevos nos de Localización y Seguimiento con Redes pricas de Sensores	221
	4.1	Entor para	rno de Simulación de Propagación Electromagnética Redes Inalámbricas de Sensores	223
	4.2	Una	perspectiva de los Métodos de Localización	232
	4.3	Loca	lización Mediante Niveles de Potencia	235
		4.3.1	Adopción de un Modelo de Propagación	235
		4.3.2	Estudio de Algoritmos de Localización	237
		4.3.3	Estimación de la Constante de Atenuación	242
	4.4	El pr medi	oblema del Seguimiento de Fuentes y Aproximación ante Medidas de Distancia	245
		4.4.1	El Modelo de Observación	245
		4.4.2	Seguimiento basado en un Vector de Estados	247

		4.4.3	Conjunción del Filtrado de Kalman y Medidas Relacionadas con la Distancia	255
	4.5	Expe	rimentos y Resultados	259
		4.5.1	Los Algoritmos de Localización Mediante Distancias Conocidas	260
		4.5.2	Estimación de la Constante de Atenuación	265
		4.5.3	Algoritmos de Localización Mediante Medidas de Potencia	272
		4.5.4	Algoritmo de Seguimiento	282
5.	Co	nclus	iones y Líneas Futuras	289
	5.1	Conc	lusiones	289
		5.1.1	Nuevos Algoritmos Aplicados en Agrupaciones Concentradas	290
		5.1.2	Nuevos Algoritmos de Aplicación en Agrupaciones Distribuidas	294
	5.2	Líneo	as Futuras	297
Bibliografía		299		
	1.	Libros y Capítulos de Libros		299
	2.	Artíc	ulos	302
	3.	Tesis	y Proyectos Fin de Carrera	316
	4.	Infor	mes de Proyectos	318
	5.	Docu	mentos Electrónicos en Internet	318
Índice de Figuras			321	
Ín	Índice de Tablas			331
Ac	Acrónimos			333

### Resumen

En esta tesis estudiamos el concepto de muestreo del entorno y cómo explotar la diversidad de información que podemos extraer de este para desarrollar aplicaciones de interés. Nuestra idea de partida era enriquecer con investigación básica el desarrollo de sistemas artificiales con los que aprovechar y mejorar las cualidades que la naturaleza nos inspira.

La forma más habitual de hacer dicho muestreo es mediante agrupaciones concentradas de sensores que van desde un simple elemento (p.e., hidrófonos, medidores de potencia) a varios agrupados en geometrías específicas. En los últimos diez años se ha extendido esta forma de extraer información del entorno a los sistemas de nodos sensores distribuidos y comunicados inalámbricamente en los que éstos están desplegados en áreas extensas. Se abren así nuevos horizontes de cara a la innovación.

El punto de mira del trabajo de investigación que presentamos está situado en un lugar intermedio entre la mera extracción de información básica del entorno y una aplicación final. En este contexto abordamos tres problemas que hemos denominado canónicos y que de por sí dan un margen amplio de posibilidades. Estos problemas son la localización, la identificación y el seguimiento de fuentes de señal. Inicialmente tratamos cada problema por separado para después enriquecer las soluciones alcanzadas de los mismos a través de desarrollos teóricos y su posterior validación. Esta validación se ha hecho pensando en una diversidad de entornos o escenarios. De la gran variedad posible hemos elegido dos de interés científico general, estos son, marino en zonas donde hay cetáceos y aéreo en la banda a 2'4 GHz. Para ambos hemos desarrollado bases de datos y corpus de señales, y herramientas de simulación que nos han permitido hacer aproximaciones muy realistas.

Para el escenario marino o, mejor, acústico submarino hemos comenzado con un estudio teórico de varios algoritmos conocidos de localización angular o DOA mediante agrupaciones concentradas en una estrategia de procesado clásico de agrupaciones. Pasamos después a trabajar sobre la hipótesis de que incluir información de la fuente que genera las señales enriquece las prestaciones alcanzables. Esta hipótesis se ha visto confirmada de forma genérica de la mano del modelado ARMA y particularizamos para unas fuentes (individuos) muy especiales, los cachalotes. Presentamos varios algoritmos de localización DOA donde la inclusión de un modelo específico de la fuente juega un papel principal. Hacemos un recorrido que va desde la base teórica hasta los experimentos que confirman nuestras expectativas.

Siguiendo en el mismo contexto, vamos un paso más adelante y hacemos la hipótesis de que conocida la DOA de un individuo dado podemos proceder a su identificación. El marco teórico es similar al planteado para localización. Nuestra hipótesis se ve confirmada igualmente a partir de los experimentos.

Dado que la mayoría de los cetáceos, es el caso de los cachalotes, se desplazan a lo largo del océano, surgió una discusión acerca de qué algoritmos utilizar para hacer un correcto seguimiento. Una vez planteado el modelo más adecuado de movimiento y los modelos matemáticos de observación más adecuados llegamos al filtrado de Kalman extendido donde las estimaciones de DOA pasan a ser las medidas. Finalmente, integramos en un algoritmo conjunto nuestros métodos de localización angular, identificación de fuente de señal y seguimiento de cachalotes culminando así un desarrollo incremental de los tres problemas canónicos planteados.

Para el escenario aéreo de radiofrecuencia hacemos una aproximación a los problemas canónicos basada en el uso de nodos sensores inalámbricos distribuidos. Primero abordamos el problema de localización cartesiana (p.e., en el plano bidimensional) usando valores de RSSI de las que estimar la distancia relativa entre nodos sensores fijos y móviles. Comenzamos por el estudio de los algoritmos más adecuados para este propósito procurando que la base teórica defina bien el papel de los niveles de potencia. Hecho esto se constata una serie de limitaciones de los algoritmos debidas a la propagación de las ondas de señal. Planteamos nuestro estudio a partir de la ecuación de Friis y nos centramos en la atenuación con la distancia. Particularmente, nos fijamos en el exponente denominado constante de atenuación. Nuestra hipótesis de partida en este contexto es que un conocimiento de dicha constante nos permite hacer una mejor introspección en las ecuaciones de los algoritmos de localización para mejorar sus prestaciones. Esto permitiría mitigar el efecto adverso de no conocer la constante real mediante el uso de una estimación de la misma. El desarrollo teórico que hemos presentado para estimar la constante de atenuación ha dado buenos resultados y su inclusión en los algoritmos de localización permite, efectivamente, mejorar los resultados.

La bondad de los resultados de localización nos permitió enfrentar el problema del seguimiento de fuentes de señal móviles. A tal afecto partimos de un modelo de movimiento de la fuente con el que abordar una correcta observación de la misma. Llegamos a una conclusión análoga a la alcanzada en el entorno submarino, el filtrado de Kalman extendido es adecuado para nuestros propósitos. Nuestra hipótesis aquí era que las medidas de distancia obtenidas a partir de nuestros algoritmos de localización son suficientemente buenas y que los errores de localización se pueden compensar hasta alcanzar un seguimiento con menores errores de localización que los iniciales. Los experimentos confirman las expectativas haciendo válida la hipótesis de partida. Se culminó así un desarrollo incremental de un algoritmo de localización y seguimiento.

### Abstract

In this PhD thesis we study the concept of environment sampling and how to exploit the information diversity we can extract from it in order to develop applications of interest. Our starting idea is to enrich the development of artificial systems by means of basic research with which to take advantege and to improve the qualities that nature inspires us.

The usual way to make environmental sampling is by means of (concentrated) sensor arrays that range from single elements (e.g., hydrophones, power measurement devices) to several of them organized in specific geometries. In the past decade the wireless sensor networks have matured as distributed systems in extense areas thus opening new horizons that lead to innovative solutions.

The key point of the research work we present is focused in an intermediate place between the extraction of basic information from the environment and an application. In this context, we face three problems that we call canonic which offer a wide spread of possibilities. These problems are localization, identificaction and tracking of signal sources. In our first approach we independently treat each problem and later we enrich the solutions we arrive to by means of theoretical developments y posterior validations. These validations have been envisaged in a variety of environments or scenarios. Among the available possibilities we have chosen two with general scientific interest. These are marine where cetaceans live and the air in the radiofrequency in the 2'4 GHz band. In order to perform realistic approaches to the real scenarios we have created simulation tools, and a signal corpus and a database.

For the acoustic submarine scenario we have started by a theoretical study of several known angular location or DOA algorithms that extract information from arrays in a standard array signal processing strategy. We further work on the hypothesis that including information from the signal souce enriches the achievable performance. This hypothesis has been confirmed in a general way by using ARMA modeling and, particularly, for a special kind of sources, sperm whales. We introduce several DOA algorithms in which the inclusion of a specific source model plays a principal role. Our development starts from the theoretical bases to the experiments that confirm our expectations.

Following in the same context we go a step forward and we make the hypothesis that known the DOA of a given individual we can identify it. The theoretical frame is similar to the one rised for angular location. Our hypothesis has been confirmed from the experiments.

Given that the most cetaceans like sperm whales move along the ocean there rised a discusion about the kind of algorithm to use in order to perform a good tracking. Once stablished the proper motion and observation mathematical models we arrived to an extended Kalman filtering where the DOA estimations become the measurements. Finally, we integrate in a single algorithm our angular location, signal source identification and tracking of sperm whales thus culminating an incremental development of the three posed canonical problems.

For the air rediofrequecy scenario we make an approach to the canocnical problems based on the usage of distributed wireless sensor nodes. First we tackle the location problem (e.g., in the two dimensional space) by using the RSSI from which to estimate the relative emitter-receiver distance between fixed and mobile nodes. We start by studying the most appropiate algorithms for our purposes trying that the role of the power levels be well stablished in the theoretical bases. Once we make the stablishment of these bases we state the algorithm limitations which are due to the propagation of the signal waves. We start our study from the Friis equation and we center our attention on the attenuation constant. Our hypothesis in this context is that the knowledge of that constant lets us to make a good study of the location algorithm equations to improve their performance. This fact may let to mitigate the lack of knowledge of the real constant by means of an estimation of it. The theoretical development that we have introduced to estimate the attenuation constant has given good results and its inclusion in the location algorithms lets effectively improve results.

The good results that we achieved lead us to face the mobile signal sources tracking problem. For that purpose we start from stablishment of the proper motion and observation mathematical models and we arrive to an analogous to the case of angular tracking, that is, the extended Kalman filtering is appropriate for our purposes. Our hypothesis here was that the distance measures from our location algorithms are good enough and that the location errors can be compensated till achieving a tracking with lower than the initial errors. The experiments confirm our expectations making valid our hypothesis. Thus, we culminated an incremental development of a location and tracking algorithm.

# CAPÍTULO 1

### Introducción

En la naturaleza existen mecanismos biológicos que poseen algún tipo de capacidad, más o menos avanzada, para realizar tareas de detección, localización, identificación o hasta realizar una forma de seguimiento de diversos tipos de emisiones. Para poder materializar estas capacidades es necesario que dispongan de sensibilidad para captar emisiones gaseosas o de alguna forma de energía como por ejemplo, electromagnética o acústica [Wood 1980, Suthers 1988, Tyack 2002]. Con frecuencia los humanos nos inspiramos en la forma en que se manifiestan esas capacidades para desarrollar sistemas de interés para alguna aplicación. En realidad ninguno de los mecanismos biológicos conocidos está preparado para procesar todos los tipos de emisiones, ni para interaccionar de manera natural en el medio donde estas se generan y propagan, por lo que se ha de recurrir a soluciones tecnológicas, esto es, no naturales.

La emulación mediante algún tipo de sistema artificial no está exenta de complicaciones y dificultades que en muchos casos se resuelven mediante aproximaciones, por ejemplo particularizando para un tipo concreto de emisión y o tipo de fuente. Visto desde una perspectiva muy global el proceso comienza con la captación de las emisiones de interés mediante algún tipo de sensor, continúa con su procesamiento para, finalmente, aportar alguna solución al problema de



Figura 1.0.1. Diagrama de Bloques de un Sistema de Detección, Localización, Identificación y Seguimiento.

interés. Es en este contexto donde entran los sensores como elementos de captación o, incluso, interacción que pueden funcionar agrupados muy próximos entre sí o distribuidos por el entorno [Ilyas 2005].

Siguiendo con nuestra perspectiva, desde un punto de vista muy general el proceso global que nos interesa, ver Figura 1.0.1, comienza con la detección, es decir por la extracción de información o flujo de información de cualquier ambiente, con o sin colaboración ni sincronización directa con la fuente emisora. El proceso continúa con la localización de la fuente (p.ej., angular, cartesiana) y seguimiento de su evolución en el entorno. Además, un paso previo necesario debe ser su identificación, p.ej. para discernir si es de nuestro interés su seguimiento. En esta tesis abordaremos todos estos elementos vistos como desafío científico y nuestro objetivo general es desarrollar nuevos algoritmos o hacer aportaciones que mejoren las prestaciones de los ya existentes.

#### 1.1 Motivación y Objetivos

Los desafíos planteados en el apartado anterior dan lugar a una serie de problemas científicos de aplicación en ingeniería. A estos problemas los denominamos canónicos. Entendemos por canónicos aquellos que resultan esenciales para desarrollar aplicaciones finales o, por lo menos, alcanzar objetivos intermedios. Esto es, sin una solución de los mismos no se puede llegar a un sistema final. La definición de un sistema o aplicación específica no es necesaria para plantear estos problemas. Dicho de otra forma, a poco que lo pensemos todos podemos coincidir en que se necesita una solución para ellos. Los problemas canónicos que abordamos en esta tesis son: localización, seguimiento, caracterización e identificación de fuentes.

El abanico de sistemas o aplicaciones que necesitan de solución para alguno de los problemas anteriormente planteados es muy amplio, pero no es nuestro objetivo hacer una recopilación exhaustiva. A grandes trazos podemos plantear lo siguiente. Con frecuencia es necesario que un sistema haga una detección de señal que active etapas posteriores del sistema para el que se aplique. Es el caso de codificación o reconocimiento de voz, detección de presencia en seguridad, detección de paso de vehículos, detección de fuentes acústicas aéreas o submarinas, etc. La localización de fuentes, fijas o móviles, es necesaria en sistemas de posicionamiento (p.ej., GPS), navegación aérea o marítima, seguimiento de mercancía diversa en almacenes o de maquinarias en fabricas, seguimiento de cetáceos en el océano [Thomas 1986a], etc. Particularmente, si la fuente es móvil hace falta aplicar soluciones específicas que van más allá de la mera localización. Abundando en esta exposición puede plantearse el problema de identificar la fuente. Es el caso de identificación de locutor, recuento de ejemplares de cetáceos, identificación de tipo de vehículos, etc. Para esta identificación es necesario caracterizar las fuentes mediante la aplicación de modelos que las describan. Se entiende, pues, que la caracterización es a su vez un problema fuente de soluciones para la identificación.

#### 1.1.1 La Localización desde la Perspectiva del Tipo de Información Básica

Podemos entender *Localizar* como la acción de determinar o señalar el emplazamiento que debe tener alguien o algo. También se entiende como fijar algo en un lugar o unos límites determinados. Por tanto, básicamente se trata de estimar sus coordenadas cartesianas (x,y,z) o polares, distancia radial, ángulo de azimut y ángulo de elevación  $(r,\varphi, \theta)$ . El contexto en que tratamos de llevar a cabo esa acción, sea con Agrupaciones Distribuidas o Concentradas nos orientará hacia una u otra metodología.

En lo relativo a la información básica a utilizar existen diferentes alternativas que hemos de analizar en función de las condiciones de trabajo y los objetivos marcados. Así, tenemos la que da lugar a resultados muy precisos pero con alto coste (energético, de tiempo y recursos de proceso, hardware, etc.), mientras que otras no son tan precisas, pero pueden estar disponibles en la mayoría de los nodos. Estas alternativas incluyen RSS (Received Signal Strength), TOA/TDOA, diferencias de fase o el de alcance en comunicación.

#### • La Información Básica

Los métodos basados en RSS estiman la distancia entre los nodos de una red distribuida en base a la intensidad de la señal recibida desde uno de los nodos. Para calcular la posición uno de los métodos más básicos e intuitivos es el conocido como Trilateralización o su versión generalizada Multilateralización [Boukerche 2009]. Este se basa en el cálculo de la posición de un nodo mediante la intersección de tres círculos, para ello el nodo necesita conocer la posición de tres nodos referencia, así como la distancia a cada uno de esos nodos.

Las diferencias de fase suelen estudiarse en el contexto de las agrupaciones concentradas [Johnson 1993]. Así, el primer enfoque para realizar el procesado espacio temporal de los datos recogidos en una agrupación de sensores es el Filtrado Espacial o Conformador de Haz (Beamforming). La idea es apuntar la agrupación en una dirección cada vez y medir la potencia de salida. De esta forma, por ejemplo, se obtiene la dirección de llegada como resultado de encontrar la dirección donde se obtuvo la máxima potencia. Se trata de una mera aplicación espacio temporal del análisis de Fourier (Beamformer Convencional o de Barlett), posteriormente Filtrado Espacial de Mínima Varianza (Beamformer de Capon), Métodos Basados en Subespacios donde destaca MUSIC (MUltiple SIgnal Clasification) y las técnicas clásicas de estimación del retardo temporal (Time Delay Estimation, TDE) [Manolakis 2005, Van Trees 2002]. Su principal limitación reside en que sus prestaciones son directamente proporcionales al tamaño de la agrupación (apertura), lo que se traduce en que los métodos fundamentados en el espectro, aunque computacionalmente atractivos, no siempre producen suficiente precisión, en particular en aquellos escenarios donde encontramos señales con una alta correspondencia entre sí.

Si la única información útil para estimar una distancia es el Alcance en Comunicación entre sensores, es posible establecer que si se recibe un paquete desde otro nodo, entonces la distancia entre estos nodos se encuentra entre cero y el máximo de Alcance de Comunicación. Claramente esto será efectivo cuando no necesitamos una distancia precisa sino que es suficiente con un intervalo. Su ventaja claramente reside en la simplicidad y el bajo coste del método, no se necesita hardware extra ni tampoco cálculos adicionales. Sin embargo, la magnitud del error no es viable para la mayoría de los sistemas de localización.

El medio de propagación de las ondas puede ser aéreo, submarino o a través de sólidos, donde fenómenos como la dispersión, atenuación, absorción, reflexión, refracción, difracción, multitrayecto, etc., caracterizan a las ondas [Balanis 1989, Kinsler 1992]. Igualmente podemos hablar de espacios abiertos o espacios cerrados, lo que entraña también fenómenos adicionales, como por ejemplo la reverberación en el caso de ondas acústicas. Además, las fuentes acústicas, mecánicas o electromagnéticas consideradas pueden tener un carácter estático o móvil (movimiento esporádico o continuo). También hemos de considerar que tanto las fuentes como los receptores pueden tener un carácter directivo. Todos estos aspectos conforman las condiciones de contorno del problema y acotan las metodologías, estrategias y técnicas aplicables. En definitiva, afectan a cómo captamos y extraemos la información básica de la que se nutrirán nuestros algoritmos.

#### • Objetivos Particulares

Desde el punto de vista de la localización y la información básica hay abiertas una serie de líneas de investigación. Las que vamos a abordar en esta tesis son:

- Estudiar las fuentes según su naturaleza y fundamentos matemáticos para su modelado.
- Estudiar los escenarios de según la naturaleza de las señales, por ejemplo, fuentes acústicas y fuentes electromagnéticas.
- Considerar el tipo de información básica: amplitud o potencia, fase y retardo como bases de información.
- Estudiar y caracterizar el medio de propagación con énfasis en parámetros de interés.

#### 1.1.2 Agrupaciones de Sensores Concentradas frente a Distribuidas y el Problema de la Localización

Una agrupación de sensores de tipo distribuido se compone de una serie de nodos, desde unos pocos hasta miles, desplegados en un área dependiente de la aplicación. Una agrupación de tipo concentrada es aquella cuyos nodos están agrupados según una geometría que normalmente es regular (lineal, plana o volumétrica) con un espaciado entre sensores que no excede, por ejemplo, a una semilongitud de onda. Estas suelen desplegarse en campo lejano de la fuente. Ambos tipos de agrupaciones pueden estar integrados en sistemas pasivos o activos. En los pasivos la misión de los sensores es captar señales. En los activos las agrupaciones emiten y reciben señales (p.ej., sonar, radar). Tenemos entonces el reto científico de decidir, en función de un problema determinado, si usar agrupaciones concentradas o distribuidas. En ambos casos, también hemos de decidir si el sistema es activo o pasivo.

Ambos tipos de agrupaciones (distribuidas y concentradas) pueden usarse para observar campos de ondas acústicas, mecánicas o electromagnéticas que se encuentren dentro de su radio de captación. En el contexto de los campos mencionados los sensores utilizados pueden tomar diversas formas: Antenas, micrófonos, hidrófonos, acelerómetros, transductores de ultrasonidos, etc. De estos obtenemos información básica en forma de niveles de potencia, retardos, ángulos, etc. Desde un punto de vista científico el tipo de campo es un condicionante de importancia que determina el tipo de sensores y su distribución.

Antes de pasar al tipo de agrupación hemos de tener en cuenta que la propagación de ondas y su tipología han de tenerse en cuenta como condicionante fundamental de investigación.

#### • Agrupaciones Concentradas en el Problema de Estimación de Dirección de Llegada

Cuando se tratan agrupaciones concentradas emerge el Procesado de Agrupaciones de Señales (Array Signal Processing, ASP) a raíz de la concepción de estos sistemas para conjugar los datos recogidos en varios sensores y llevar a cabo una determinada tarea de estimación, habitualmente la localización angular de un objeto.

Sin pérdida de generalidad, centrémonos en la estimación de dirección de incidencia mediante agrupaciones concentradas lineales. A menudo la información básica a usar es la diferencia de fase entre sensores. En la Figura 1.1.1 podemos ver un modelo esquemático de tal sistema, donde se representa la relación funcional existente entre el medio ambiente, la agrupación de sensores y el procesador. El modelo matemático que normalmente se usa en ASP [Krim 1996] para componer el vector de datos recogidos por la agrupación lo podemos ver en la ecuación Ec.1.1.1.

$$\mathbf{x}(t) = \mathbf{A}(\theta) \cdot \mathbf{s}(t) + \mathbf{n}(t) \tag{Ec. 1.1.1}$$



Figura 1.1.1. Modelo de un Sistema para ASP.

donde  $A(\theta) = [g(\theta_l), ..., g(\theta_M)]$  ( $L \times M$ ) es la matriz de dirección,  $s(t) = [s_l(t), ..., s_M(t)]^T$ la señal emitida por cada una de las fuentes y n(t) representa un ruido aditivo. El número de sensores sería L y el número de fuentes incidentes sobre la agrupación es M. El vector  $g(\theta) = [g_l(\theta), ..., g_L(\theta)]^T$  contiene la característica de respuesta (amplitud, fase y dirección) correspondiente a cada uno de los L sensores en la dirección genérica  $\theta$ . El problema así planteado tiene como objetivo principal determinar la dirección de incidencia de las señales emitidas por las fuentes (Direction Of Arrival, DOA).

Cuando la información básica a usar es el tiempo de retardo (Time Delay Estimation, TDE) existen diversas técnicas que se orientan a la estimación de  $\tau$ , o sea la diferencia de tiempos de llegada (Time Difference Of Arrival, TDOA). Las TDOAs estimadas se transforman en un sistema de ecuaciones no lineales de diferencias de distancia entre fuente y sensores, la solución del citado sistema proporciona una estimación de la posición donde se localiza la fuente.

Una pregunta que nos podemos hacer es si es posible enriquecer la fuente de conocimiento, por ejemplo, en la ecuación Ec.1.1.1 para mejorar las estimaciones. En esta tesis pretendemos hacer hipótesis y desarrollar nuestro propio algoritmo para incluir información sobre el proceso de producción de la señal dentro del algoritmo de estimación de dirección de llegada.

#### • Agrupaciones Distribuidas en el Problema de Localización de Fuentes

Muchas de las técnicas usadas para resolver el problema de localización de una o varias fuentes no son aplicables a las agrupaciones distribuidas, Figura 1.1.2. En este caso la separación entre sensores es grande, en términos de la longitud de onda, por lo que los conceptos clásicamente usados en agrupaciones concentradas no son aplicables. Se impone así la necesidad de buscar metodologías alternativas



Figura 1.1.2. Modelo de un sistema distribuido.

e incluso información básica diferente. Por ejemplo, si antes no tenía sentido hablar de diferencias de amplitud de señales y sí de diferencias de fase, ahora sí tiene sentido trabajar con diferencias de amplitud o en una forma más útil, de potencia. Otro aspecto a destacar es que en las agrupaciones concentradas los sensores están agrupados en el centro geométrico de la agrupación, mientras en las distribuidas esto no es así.

En las agrupaciones distribuidas merecen especial interés las inalámbricas, [Pahlavan 2002] aquellas donde los sensores o agrupaciones de sensores distribuidas tienen capacidad para comunicarse con un Centro de Proceso directa o indirectamente, o bien con los sensores adyacentes, por lo que aunque comúnmente se les denomina sensores hemos de entender que se trata de auténticos nodos de comunicación que incorporan diversos sensores, al menos uno, también de una manera más coloquial se les conoce como motas. Ante este escenario surgen entonces una serie de nuevas consideraciones: Procesado descentralizado, procesado colaborativo, consumo de energía, conocimiento o no de la posición exacta del sensor, sincronización, procesado de señal incoherente, radio de acción por atenuación y sensibilidad del sensor, naturaleza de las señales captadas.

En esta tesis el énfasis lo pondremos en redes inalámbricas distribuidas, que están constituidas por nodos que tienen capacidad, dentro de su radio de acción, para recoger información del medio circundante. Los nodos están dotados de capacidad de procesado sobre la información captada y con la facultad añadida de poder comunicarse con los nodos de su entorno o directamente con el Centro de Proceso. En la literatura al efecto a estas redes se les conoce como Redes Inalámbricas de Sensores (Wireless Sensor Network, WSN).

En el contexto de las redes distribuidas el problema de la localización de fuentes puede simplificarse y definirse del modo siguiente: Dada una red y un conjunto de nodos baliza y sus posiciones  $(x_b, y_b)$ , queremos encontrar la posición de los nodos desconocidos, transformando estos nodos desconocidos en nodos fijos. Por tanto, la posición de los nodos no necesita ser predeterminada, lo que permite un despliegue aleatorio en terrenos inaccesibles o en operaciones de auxilio ante catástrofes.

También son de aplicación métodos basados en TOA y TDOA que requieren nodos sincronizados con precisión, además de la incorporación en el paquete de datos transmitido de información relativa al instante de emisión. Los métodos basados en diferencias más aplicados en WSN, requieren calcular la diferencia de tiempo que varias señales emitidas desde el nodo emisor toman para llegar a otro nodo. Para ello se necesita que los nodos estén equipados con hardware extra que les permita enviar dos tipos de señales con distintas velocidades de propagación de manera simultánea, como señales de radio y acústicas (sonidos o ultrasonidos). Estos métodos se muestran bastante precisos, pero presentan desventajas tales como necesitar hardware adicional para enviar la segunda señal, con el consiguiente incremento del coste del nodo. Además, el alcance de la segunda señal es normalmente bajo, oscilando entre los 3 m y 10 m.

Uno de los mayores desafíos científicos en este campo está en el tipo de información básica a utilizar. De entre todos (retardos, niveles de potencia recibida, etc.) el nivel de potencia recibida es el que más se usa porque la mayoría de los nodos de sensores lo dan como información. Su uso plantea problemas derivados de la interacción de las ondas en su propagación por el entorno. Así, reflexiones, difracción, etc. afectan de tal forma que no son pocos los investigadores que se cuestionan la utilidad de la potencia. En esta tesis vamos un paso más adelante investigando sobre cómo afecta la propagación a dichos valores y la mejor forma de corregir los problemas que plantea.

#### • Objetivos Particulares

Los objeticos dentro de este apartado son fundamentales pues condicionan el resto de líneas de investigación. Principalmente, estudiaremos y definiremos las principales fuentes de conocimiento que nos permitirán sentar las bases de toda la tesis. Así, los objetivos particulares son:

- Estudiar un enfoque apropiado para agrupaciones concentradas y distribuidas.
- Desarrollar nuevos algoritmos de localización mediante la estimación de la dirección de llegada.
- Estudiar la posible inclusión de nuevas fuentes de conocimiento que permitan mejorar la localización angular.
- Desarrollar nuevos algoritmos de localización mediante niveles de potencia.
- Incorporar la estimación de parámetros del modelo de propagación en la localización mediante niveles de potencia.

#### 1.1.3 Seguimiento Basado en la Distribución de los Sensores y el Tipo de Movimiento de las Fuentes

Los algoritmos de procesado de agrupaciones de sensores para la localización de fuentes móviles están condicionados a que las fuentes de energía se mueven poco en relación con la agrupación. Cuando una fuente se mueve apreciablemente las características de la señal propagándose quebrantan los supuestos realizados en



Figura 1.1.3. Secuencia de Procesos en un Algoritmo de Seguimiento genérico.

los algoritmos, p.ej. que la dirección de propagación permanece constante en promedio a lo largo del proceso de medida. Otro aspecto importante es que cuando tengamos más de una fuente, seamos capaces de seguir discerniendo quién es quién aunque se crucen. En general como mínimo la posición y velocidad han de tenerse en cuenta, y si fuese factible también la aceleración.

Un algoritmo de seguimiento debe ser capaz no sólo de determinar la localización en un instante determinado,  $x_0$ , sino también el movimiento de fuentes perfectamente identificadas, x(t) y v(t) (desplazamiento y velocidad). Luego, los algoritmos en cuestión deberán extender sus facultades para:

- Inclusión explícita de la dinámica de los movimientos de la fuente e incluso la agrupación de sensores dentro del algoritmo de procesado de señal.
- Como complemento de la localización se aportará la estimación del movimiento de la fuente en forma de la velocidad de la misma, por ejemplo, a través de medidas específicas.

Una primera opción sería aplicar los métodos de localización sobre los datos disponibles en cada instante de tiempo considerado. Obteniendo así una sucesión de localizaciones que conectadas suponen la estimación del camino seguido por el objeto bajo observación. Sin embargo, los efectos del desplazamiento relativo sobre las señales recibidas pueden dar lugar a errores en la estimación de la localización de cuantía inaceptable, por tanto será necesario aplicar algún proceso más robusto y eficiente.

Aquellos algoritmos de seguimiento que incorporan el movimiento de las fuentes en la estimación de las localizaciones pueden caracterizarse como un predictor del estado, concepto más amplio que localización ya que engloba posición y movimiento, seguido de una corrección dependiente de una medida u observación, Figura 1.1.3.

Se define así un marco de investigación en el que tendremos que afrontar problemas como la definición del concepto de estado, modelo de medida e integración de ambos [Blackman 1999]. De todos los métodos existentes hoy en día el de Kalman es uno de los de más éxito. Sin embargo, cuando la función f es manifiestamente no lineal existen otros métodos como Extended Kalman Filter (EKF) que será objeto de nuestra atención. El EKF se inscribe entre los métodos de tipo bayesiano en los que se hacen necesarias funciones de densidad de probabilidad.

#### • Objetivos Particulares

Desde el punto de vista del seguimiento de fuentes hay una serie de líneas de investigación que vamos a seguir:

- Estudiar los patrones de evolución de fuentes móviles según la naturaleza de las señales.
- Incorporar las medidas de distancia a partir de niveles en el proceso de seguimiento.
- Incorporar las medidas de localización angular en el proceso de seguimiento.
- Desarrollar de nuevos algoritmos de seguimiento con agrupaciones.

#### 1.1.4 Identificación de Fuente con Técnicas Paramétricas e Inclusión en el Proceso de Localización

En el apartado 1.1.1 hemos puesto énfasis en el concepto de información básica. Así, consideramos de interés la potencia recibida, los retardos de llegada a los sensores, etc. Hemos dejado para un apartado específico un concepto un tanto más difuso de información básica que es la relacionada con el proceso de producción de la señal por parte de la fuente. Nuestro punto de partida es preguntarnos, si incluir nuestro conocimiento sobre el proceso de producción de la señal puede enriquecer nuestros algoritmos hasta el punto de mejorar las prestaciones esperadas en términos de localización angular. El punto de mira está puesto sobre las situaciones prácticas en que conocemos el tipo de fuente, cómo genera las señales y, además, disponemos de herramientas de descripción matemática de las mismas. Es el caso de los cachalotes, que son fuentes acústicas con un aparato productor de sonidos razonablemente bien conocido para el que podemos usar técnicas paramétricas de tipo ARMA.

En el contexto de esta tesis, una visión global del proceso de identificación es como sigue. Comienza con la adquisición de datos y detección de presencia de señal de interés (Figura 1.1.4). La detección es un caso especial de la clasificación, donde sólo dos clases son posibles Presente o Ausente. Una vez que disponemos de señal para trabajar hemos de preguntarnos qué tipo de fuente es. Estamos ante un problema de clasificación multiclase [Van Der Heijden 2005] donde cada clase representa un especie (p.ej., tipo de cetáceo). Una vez determinado el tipo de fuente se puede hacer un estudio más detallado de la misma con una serie de subclases que en su conjunto representan la riqueza global. Así, las subclases representarían grupos más específicos (p.ej., cachalotes). Finalmente, abordamos el problema de identificación de individuos para su posterior inclusión en el método de estimación de localización angular.



Figura 1.1.4. Flujo de proceso de detección, clasificación e identificación.

Afrontar el problema de la identificación siempre conlleva la creación previa de una base de datos, obtenida de observaciones previas, con la que comparar las nuevas adquisiciones. Así mismo, otro proceso íntimamente ligado a la identificación es la estimación de unos parámetros para obtener una descripción útil de los individuos de interés.

Hay estudios de las señales de cachalote [Hernández 2002b, Hernández-Pérez 2003] donde se justifica la bondad del modelado ARMA, o su versión AR, para describir los clics. Este tipo de modelos se apoyan en la idea de que cada valor de la serie depende solamente de la suma ponderada de los valores previos de la misma serie, s(k), componente autorregresivo (AR, AutoRegressive)  $a_i$  y de una suma ponderada de los valores actuales y previos de una serie temporal diferente, u(k), componente media móvil (MA, Moving Average)  $b_i$  más un termino de ruido.

$$s(t) = \sum_{k=1}^{N} a_k s(t - k \cdot T) + \sum_{k=0}^{M} b_k u(t - k \cdot T) + n(t)$$
 (Ec.1.1.3)

En la ecuación Ec.1.1.3 tenemos la expresión para un modelo ARMA de orden (N,M), donde la parte AR es de orden N y la parte MA es de orden M. Más útil aún es la descripción que aporta la función de transferencia asociada pues recoge cualidades importantes como máximos de transmisión o formantes asociados a las resonancias del sistema y mínimos asociados a interacciones complejas destructivas en la generación de los clics.

Podemos particularizar, por ejemplo, para fuentes de tipo AR [Ziskind 1992]. En este caso la ecuación (Ec.1.1.1) que describe la salida de una agrupación concentrada de sensores queda de la siguiente forma:

$$\mathbf{x}(t) = \mathbf{A}(a,\theta) \cdot \mathbf{s}(t) + \mathbf{B}(\theta) \cdot \mathbf{\varepsilon}(t) + \mathbf{n}(t)$$

donde **A** es la matriz de dirección de la agrupación extendida, la matriz  $\mathbf{B}(\theta)$ viene dada por  $\mathbf{B}(\theta) = [\mathbf{A}^{\mathrm{T}}(\theta), \mathbf{0}^{\mathrm{T}}, \dots, \mathbf{0}^{\mathrm{T}}]^{\mathrm{T}}$  y  $\boldsymbol{\varepsilon}(t)$  es el vector de los errores de estimación. Como se puede observar, la descripción de los datos de la agrupación x(t) se ven enriquecidos por los coeficientes de predicción  $\{a_i\}$  además de las direcciones de incidencia. Se abren así dos vías principales de investigación, identificación de individuos cuando la DOA es conocida y estimación de DOA cuando el individuo es conocido.

#### • Objetivos Particulares

Las líneas de investigación que nos hemos propuesto seguir en lo relativo al reto de la identificación, en nuestro contexto, nos lleva a marcar los siguientes objetivos en ese ámbito

- Estudio de técnicas de modelado y descripción de fuentes.
- Incorporación de un modelo de la fuente en el proceso de identificación.
- Estimación de la localización angular a partir del modelo de fuente.
- Identificación de individuos a partir del modelo de fuente y el conocimiento de la localización angular.
- Estimación e identificación simultánea a partir del modelo de fuente.

#### 1.2 Organización de la Memoria de Tesis

La memoria de esta tesis la hemos estructurado en 5 capítulos. El primer capítulo es este de introducción donde exponemos la motivación, objetivos y principales contribuciones al tiempo que describimos como está organizado este documento de tesis.

El Capítulo 2 lo hemos reservado para el desarrollo de todos los conceptos y cuestiones fundamentales que suponen el sustrato de los grandes temas que acometemos en esta tesis. Dada la diversidad de contextos entre los distintos temas abordados, hemos dividido a su vez el capítulo en una serie de apartados, concretamente 5. En los dos primeros damos una visión general de todos aquellos fenómenos que se desencadenan cuando una onda acústica se propaga en el medio marino o cuando una onda electromagnética lo hace en el medio aéreo. El tercer apartado está dedicado a presentar los tipos de sensores que empleamos para cada medio y tipo de onda, así como la información básica que podemos esperar de cada uno, como producto de su interacción con el tipo de onda considerado. Un aspecto de gran relevancia en sí mismo es el relativo al enriquecimiento conseguido mediante la asociación de múltiples sensores con un mismo fin. En este sentido los apartados cuarto y quinto nos ilustran al respecto. Más concretamente en el cuarto apartado lo hacemos respecto de las agrupaciones concentradas de sensores y sus distintas geometrías, pros y contras de las mismas. El último apartado, el quinto, nos introduce en las técnicas básicas aplicadas en las topologías y el despliegue de las agrupaciones distribuidas de sensores.

El gran tema de nuestra tesis, según reza en el título de la misma, es el desarrollo de nuevos algoritmos que se apliquen a la localización, seguimiento e identificación de fuentes. En el capítulo 3 este reto se toma en el contexto de las fuentes acústicas y las agrupaciones concentradas. Específicamente, y sin pérdida de generalidad, las fuentes de nuestro interés son los cachalotes, razón por la cual el medio en que nos movemos dentro de este capítulo es un ambiente submarino. Para ordenar los distintos frentes abiertos en este capítulo hemos organizado su contenido en seis apartados. En el primer apartado damos una pincelada sobre las aplicaciones acústicas que para el estudio de los cetáceos podemos encontrar, se trata de sistemas concretos y alguna propuesta novedosa y en vías de desarrollo. Para el segundo apartado hemos dejando la presentación de una herramienta de simulación para propagación acústica submarina. Esta herramienta, que ha sido desarrollada por nosotros, nos resulta de gran ayuda en aquellos experimentos que requieran visos de realismo, sin tener que acceder al medio en sí mismo, con todo lo que ello conlleva. En el tercer apartado nos introducimos en el problema de la detección DOA, estudiando previamente la detección específica de sonidos de cachalotes, para a continuación acometer la estimación de la DOA. El cuarto apartado nos introduce en el seguimiento de fuentes en movimiento partiendo de medidas de DOA. El quinto nos sirve para introducir los distintos elementos que forman parte de nuestro algoritmo conjunto para las tareas de Localización, Identificación y Seguimiento. Para ello empieza el apartado con la propuesta de modelado AR y ARMA para sonidos de cachalotes, seguidamente presentamos nuestros algoritmos de DOA específico de fuentes AR y ARMA, y a continuación nuestro algoritmo de identificación para cachalotes. Todo este conjunto de algoritmos se amalgama para conseguir un algoritmo conjunto de localización angular y seguimiento.

La localización y el seguimiento de fuentes los hemos enfocado en dos contextos distintos: agrupaciones concentradas y distribuidas. El capítulo 3, como ya hemos indicado previamente, lo hemos dedicado al contexto donde la localización y seguimiento la hacíamos mediante agrupaciones concentradas. Así las cosas, el capítulo 4 se ocupa de los algoritmos de localización y seguimiento en entornos de sensores distribuidos. El paso previo a nuestra inmersión en este contexto lo exponemos en el primer apartado de este capítulo, se trata del entorno de simulación de propagación electromagnética para redes inalámbricas de sensores (WSN). Esta herramienta la hemos desarrollo como elemento indispensable para probar nuestros algoritmos en situaciones cuasi reales. El segundo apartado nos sirve de preámbulo para el resto de los apartados, para ello presentamos una breve y concreta perspectiva sobre las metodologías de localización. El tercer apartado se centra en la localización mediante el uso de los niveles de potencia, para ello adoptamos un modelo de propagación, seguidamente estudiamos algunos algoritmos básicos de localización y otros derivados, para terminar con distintas formas de estimar la constante de atenuación del modelo de propagación. El cuarto apartado lo dedicamos a exponer la metodología que usaremos para afrontar el problema del seguimiento de fuentes mediante medidas de distancia. Definimos el modelo de observación, planteamos un seguimiento basado en vector de estados y aplicamos filtrado de Kalman en conjunto con las medidas relacionadas con la distancia para afrontar nuestro problema de seguimiento en un escenario con sensores distribuidos. Para

concluir, el quinto apartado está dedicado a mostrar los experimentos y sus resultados. Este apartado está organizado de manera que en principio probamos los algoritmos de localización con valores de distancia conocidos, a la par que comprobamos como procesan los errores que puedan sobrevenir en estos valores. Seguidamente experimentamos con la estimación de la constante de atenuación, desde unas condiciones cuasi ideales a otras con un significativo deterioro a fin de comprobar la robustez de nuestras propuestas. A continuación introducimos las pruebas para nuestro algoritmo de localización basados en las medidas de potencia como base de partida para la estimación de las distancias, sometemos así a nuestro algoritmo a toda una serie de pruebas para refrendar sus prestaciones y habilidades. Estas pruebas van desde simulaciones sencillas hasta pruebas de campo, pasando por simulaciones en entornos más complicados. Terminamos con los experimentos y resultados para el algoritmo de seguimiento.

El último capítulo, capítulo 5, de conclusiones y líneas futuras, nos sirve para presentar una discusión sobre los resultados de nuestras líneas de investigación a partir de los fundamentos teóricos y los resultados obtenidos. Se completa este capítulo con un apartado dedicado a las líneas futuras, es decir, expondremos todas aquellas puertas, que no entrando directamente en los objetivos de partida, hemos abierto o vislumbrado a lo largo de nuestra investigación. Puertas que suponen unas nuevas expectativas que nos proponemos explorar.

El documento de tesis termina con una serie de complementos que hemos añadido para un uso más eficiente del mismo, estos son: Bibliografía donde listamos todas las referencias utilizadas (libros, artículos, informes, tesis y proyectos fin de carrera, y documentos electrónicos en Internet), Índice de Figuras, Índice de Tablas y Lista de Acrónimos.

#### **1.3 Principales Contribuciones**

Las principales contribuciones de esta tesis se enmarcan dentro de nuestra actividad investigadora que comenzó en el Centro Tecnológico para la Innovación en Comunicaciones (CeTIC) [CeTIC 2009] que en la actualidad se ha convertido en el Instituto Universitario para el Desarrollo Tecnológico y la Innovación en Comunicaciones (IDeTIC) [IDeTIC 2010].

Uno de los objetivos del procesado de señal es el de extraer tanta información como sea posible de nuestro entorno. El mismo es observado o muestreado mediante sensores que recogen información de las ondas que se propagan por un medio determinado. En esta tesis nos acercamos al problema del muestreo de la diversidad mediante sensores que están agrupados bien de forma concentrada o distribuida. Abordamos, así, dos visiones del muestreo orientado a tres problemas canónicos que a su vez sirven de nexo de enlace conceptual entre las dos formas de muestrear. Esto es, los objetivos generales de desarrollar algoritmos de localización, identificación y seguimiento son objeto de aportación científica partiendo de la forma en que observamos el entorno.

El cumplimiento de los objetivos de esta tesis ha supuesto la realización de varias contribuciones científicas. Estas están recogidas en los capítulos 3 y 4 de este documento de tesis y a continuación pasamos a describirlas, indicando también

aquellos trabajos y publicaciones que tienen relación directa con las mismas. Con el objeto de facilitar la identificación de las contribuciones se enumeran y describen agrupadas por capítulos.

#### 1.3.1 Agrupaciones Concentradas de Sensores - Nuevos Algoritmos de Localización, Seguimiento e Identificación de Cachalotes

Una de las principales ideas que subyace en esta parte de la tesis es la de aprovechar la riqueza aportada por las cualidades propias de las señales de interés. Nuestros trabajos refuerzan la idea de que los cachalotes pueden verse como fuentes sonoras con firma acústica propia. En este campo hemos trabajado sobre el modelado de fuente y hemos comprobado cómo el de tipo AR es adecuado [Hernández 2002b]. Avanzando sobre esta idea pasamos al modelado ARMA [Hernández-Pérez 2003]. Dentro de este campo hemos progresado trabajado sobre la base del error de reconstrucción y la calidad espectral en términos de una correcta y precisa descripción de las frecuencias de resonancia y de los mínimos de transmisión llegando a la conclusión de que una formulación TSLS (Two-Stage Least Squares) es la más adecuada. Todo ello a través de los experimentos que presentamos en este documento sobre diferentes tipos de clics e individuos.

Para la realización de nuestros experimentos hemos desarrollado una completa herramienta de simulación, Cetus3D. Esta es de las pocas existentes en la actualidad para este tipo de trabajos y ha servido para simular (incluso emular) fenómenos que van desde que una fuente genera una señal y le imprime una directividad hasta que llega a una agrupación de hidrófonos pasando por las atenuaciones, cambios de dirección de propagación, reflexiones, etc. Podemos trabajar, así mismo, con diferentes posiciones de la fuente y la agrupación, movimiento de la fuente, condiciones de viento, ruido interferente, etc.

Hemos realizado una estudio, también, exhaustivo de diversas técnicas de estimación de localización angular (DOA) para fuentes de banda ancha aprovechando las diferencias de fases en los sensores de la agrupación como información básica. De especial interés es el caso de fuentes para las que conocemos dos formas de diversidad. Una viene dada por su dirección de llegada y la otra por el hecho de que la fuente posee firma propia. Así nuestros trabajos se han orientado a desarrollar nuevos algoritmos de DOA de banda ancha mediante la inclusión de un modelo AR de producción por parte de la fuente [Hernández 2002a]. En coherencia con el enriquecimiento del modelado de fuente hacia el tipo ARMA también hemos trabajado sobre la idea estimar DOA de fuentes de este tipo con notable mejora sobre nuestros trabajos previos [Navarro-Mesa 2004]. Esta mejora viene de las prestaciones alcanzadas en términos de error de estimación y, particularmente, optimización de la carga computacional. A esta optimización llegamos partiendo de una formulación inicial en la que demostramos la validez del planteamiento y como este evoluciona hasta llegar a un algoritmo alternativo con menor carga computacional. Hemos de destacar que la inclusión del modelo de producción ofrece una ventaja más, esta es, podemos localizar un número de fuentes igual o superior al de sensores superando así la

limitación de que este número ha de ser inferior. Los experimentos en diversas condiciones de ruido de fondo refuerzan la bondad de nuestros trabajos.

Como hemos visto, el disponer de un adecuado modelo de producción de la fuente nos ha reportado mejoras en la estimación de DOA. No hemos parado ahí. Ante la pregunta de si es posible identificar un individuo a partir de un determinado clic la respuesta es afirmativa. Nuestros trabajos en [Hernández-Pérez 2004] sobre identificación de individuos demuestran que podemos abordar este problema con éxito. Los trabajos posteriores presentados en esta tesis abundan en la misma idea.

Yendo un paso más adelante avanzamos sobre la idea de una localización e identificación conjunta. Si bien en [Hernández-Pérez 2004] ya adelantábamos esta idea en nuestros trabajos posteriores se ha madurado llegando al caso de trabajar hasta dos fuentes simultáneas. Incluso hemos estudiado específicamente el efecto del error de DOA en la identificación. Cerramos así un triángulo representado por el modelo de fuente, localización mediante estimación de DOA e identificación.

Finalmente, hemos presentado un algoritmo de localización de cachalotes que aporta mejoras en esa función y en una mejor descripción de la evolución de individuos aislados en sus maniobras de inmersión. En el caso de varias fuentes, el uso de nuestro método de estimación de DOA mediante modelos ARMA permite seguir varias fuentes superando así una limitación clásica de otros algoritmos, que es la necesidad de reglas (p.ej., heurísticas) específicas a tal efecto.

#### 1.3.2 Agrupaciones Distribuidas de Sensores - Nuevos Algoritmos de Localización y Seguimiento con Redes Inalámbricas de Sensores

En esta línea de trabajo también hemos desarrollado una herramienta de simulación que nos ha permitido realizar simulaciones antes de trabajar con medidas de campo. El programa LocTrackS-WSN permite definir el escenario, la ubicación de las fuentes y los nodos receptores, simular la generación de paquetes y su modulación-demodulación, estimar el error de bit y de chip, representar niveles de potencia (RSSI) recibidos, representar errores de localización, mostrar trayectorias reales y estimadas para fuentes móviles, etc.

Aceptando la idea de usar niveles de potencia dados por los valores de RSSI como información básica, nuestro trabajo de investigación comienza en este ámbito. De esta forma nos hemos tenido que fijar expresamente en la propagación de las señales de radiofrecuencia generadas siguiendo el estándar 802.15.4. Así, partiendo de un modelo de propagación basado en la ecuación de Friis, centramos nuestro interés en su aplicación en escenarios donde se producen reflexiones en obstáculos como el suelo, paredes, etc. Planteamos así la idea de centrarse en la constante de atenuación que sustituye el exponente cuadrático en el efecto de la distancia sobre la potencia recibida. Dado que los métodos de estimación de localización trabajan indirectamente con la distancia entre emisor y receptor y la apreciación de esta distancia está afectada por la constante de atenuación hemos desarrollado un algoritmo propio de estimación de dicha constante. Esto es importante, además, por el hecho de que las fuentes móviles hacen muy cambiante esta constante cada vez que se muestrean los niveles de potencia.

Se han estudiado diversos métodos de localización que van desde puntos de vista como la Multilateralización o los Baricentros a otros más elaborados que toman los anteriores como inicialización y usan conceptos como relaciones ratiométricas o un modelo de muelles. De todos el uso conjunto del método de los Baricentros y un modelo de muelles, junto con Baricentros ofrecen las mejores prestaciones.

Hemos visto cómo la ventaja de usar valores de RSSI comporta dificultad a la hora de diseñar algoritmos de seguimiento. De esta forma hemos presentado una manera sencilla y efectiva de incluir las medidas de distancia emisor-receptor en un modelo de medidas que alimenta una ecuación de estado basada en la posición y la velocidad del móvil. Con este planteamiento hemos justificado la utilidad de un filtrado de Kalman extendido. La bondad de nuestras aportaciones se ha visto a partir de simulaciones y de experimentos in-situ en un entorno real.

Las contribuciones de estas líneas de investigación han sido implementadas dentro del proyecto de investigación "Solving Major Problems in MicroSensorial Wireless Networks –uSWN" financiado por la Unión Europea en el ámbito del Sexto Programa Marco de Investigación y Desarrollo Tecnológico, iniciado en Octubre 2006 y concluido en Septiembre 2009. Particularmente, el informe interno [Navarro-Mesa 2009a] recoge las aportaciones científicas presentadas en esta tesis y en el informe [Navarro-Mesa 2009b] se describe la instalación de una aplicación end-to-end donde se pueden apreciar las trayectorias seguidas por los móviles.

# CAPÍTULO 2

## Modelos de Propagación de Señales y Muestreo del Entorno

Las agrupaciones de sensores ya sean distribuidas o concentradas normalmente se despliegan inmersas en algún tipo de medio donde sea posible la propagación mediante ondas. En esta tesis trabajaremos con dos medios particulares, el submarino y el aéreo. Como las señales a captar son de naturaleza acústica, ondas mecánicas para el medio submarino, y de naturaleza electromagnética, ondas electromagnéticas para el medio aéreo, habrá que usar modelos que se ajusten a nuestras necesidades.

Los modelos de propagación a emplear en cada caso deben ser los adecuados a nuestras aplicaciones, por tanto, se hace necesario un somero repaso a todo aquello que caracteriza la propagación de las ondas en esos medios.

Empezaremos, en el primer apartado, con la propagación de señales acústicas en entornos acústicos submarinos. Como bien es sabido se trata de un medio fluido con características propias, no sólo las debidas a la composición química del medio, sino también las que obedecen a condiciones de contorno tales como sus límites, superficie del mar y fondo del mismo, ambos de composición y estado cambiante en distancias relativamente cortas. Por otro lado, las potencias y frecuencias de emisión dependerán de la fuente, p.ej., cetáceos.

Seguidamente, en el segundo apartado nos ocuparemos de la propagación en entornos electromagnéticos con interés por los aéreos exteriores. Particularizando, trabajamos con unas Redes Inalámbricas de Sensores (Wireless Sensor Network, WSN) que se ajustan al estándar IEEE 802.15.4. Por otro lado las potencias de emisión llevan a distancias de propagación que no sobrepasan el centenar de metros. Cobran así importancia los obstáculos y límites que formen parte del escenario de interés.

Cuando se trata de muestrear un entorno hemos de utilizar algún tipo de sensor adecuado al tipo de onda que se quiere captar o parámetro físico que se quiere medir. Así mismo, y dependiendo de cómo se agrupen los citados sensores, de manera concentrada o distribuida, será necesario establecer la conexión entre estos sensores y el sistema central o base, que en algunos casos podrá ser mediante cables, adecuados al medio en el que vaya a estar inmerso, o bien será necesario algún sistema más elaborado para realizar el transporte de la información captada hasta el sistema de procesamiento central. En el tercer apartado abordamos diversos aspectos relativos a los sensores y la información básica que extraemos de ellos.

Dedicaremos el cuarto apartado a las agrupaciones concentradas de sensores. Estableceremos su modelo básico, así como sus especificaciones en un entorno submarino.

Por último, en el quinto apartado, nos detendremos en las distintas topologías que para las agrupaciones distribuidas podemos encontrar. Estas en general persiguen algún tipo de ventaja en base a la disposición de los nodos para lo cual ha de tenerse en cuenta el despliegue de los mismos. Hemos de precisar que cuando hablamos de redes distribuidas no podemos referirnos a los distintos elementos que la componen como *sensores*. El referirlos de ese modo minimiza el alcance de sus capacidades, de ahí que elijamos nombrarlos como *nodos*. Además de estar dotados de varios sensores propiamente dichos los nodos son capaces de comunicarse entre ellos, memorizar información, ejecutar pequeñas aplicaciones locales, etc.

#### 2.1 Propagación en Entornos Acústicos Submarinos

Las ondas acústicas son las preferidas cuando se quiere emitir algún tipo de energía en este medio con el fin de establecer una comunicación, inspeccionar el entorno a efectos topográficos o de búsqueda de objetos, e incluso para medir alguna de sus características. Un ejemplo claro lo encontramos en la propia naturaleza de algunas de las especies que pueblan ese medio. Por ejemplo, los mamíferos marinos utilizan la emisión de ondas acústicas para la localización, identificación y seguimiento de sus presas, y también para la comunicación con sus congéneres, al menos de una manera básica.

Si restringimos nuestra aplicación al ámbito de la comunicación, tendríamos que decir que las ondas electromagnéticas se propagan muy mal en un medio como es el agua del mar, salvo en frecuencias muy bajas (30-300 Hz) [Akyildiz 2004] para

lo que se requieren antenas de grandes dimensiones, así como potencias de transmisión elevadas. En el mismo ámbito de aplicación la energía óptica no sufre una atenuación tan elevada, pero si se ve afectada por la dispersión, además se requiere gran precisión en el alineamiento de receptor y transmisor.

En el océano, la transmisión y propagación de ondas acústicas se ve afectada por factores tales como la temperatura, presión, composición química y también por aspectos relacionados con los contornos o límites del medio, superficie y fondo. En un medio homogéneamente idealizado, se supone que todas estas propiedades son constantes en cualquier dirección y para cualquier rango, y los límites están lo suficientemente lejanos como para no interactuar. Incluso podríamos en primera instancia suponer que las pérdidas por viscosidad (absorción) son nulas. Evidentemente según el caso estos supuestos habrán de reconsiderase.

La propagación del sonido en el agua es un fenómeno mecánico y depende de las propiedades mecánicas del medio, particularmente las propiedades de inercia y elasticidad, por tanto en estas condiciones una fuente mecánica como resultado de sus movimientos provocará una onda de compresión longitudinal, que transmitirá energía mecánica o acústica más allá de la fuente. Para el caso de una fuente oscilante, la onda consiste en regiones de compresión, dónde la presión supera el valor estático o de equilibrio, y regiones de dilatación con presiones inferiores al valor de equilibrio. Estas regiones se mueven o propagan lejos de la fuente a una velocidad constante determinada por las propiedades del medio. Cuando estas ondas se propagan con simetría esférica se les denomina ondas esféricas.

Si consideramos una pequeña región del campo de ondas, región de pequeñas dimensiones en comparación con la distancia, lejos de la fuente, sería posible apreciar que la curvatura de los frentes de onda es muy suave. A grandes distancias (en términos de longitud de onda) de la fuente los frentes de ondas esféricos pueden aproximarse como superficies planas, ondas acústicas planas, lo que simplifica su tratamiento matemático. La intensidad acústica para ondas planas y ondas esféricas indicadas en Ec.2.1.1.a y Ec.2.1.1.b respectivamente difieren en el termino  $1/r^2$ , factor que expresa la perdida de intensidad con la distancia por dispersión esférica.

$$I = \frac{p^{2}}{\rho \cdot c} \quad ; \quad I = \frac{1}{r^{2}} \frac{p^{2}}{\rho \cdot c}$$
(a) (b) (Ec.2.1.1)

En *Ec.2.1.1* p representa a la presión eficaz en Pa o N/m<sup>2</sup>, c a la velocidad de propagación de las ondas en el medio en m/s, r es la distancia desde la fuente en metros y  $\rho$  es la densidad del medio en Kg/m<sup>3</sup>.

Si consideramos un medio sin pérdidas por viscosidad el flujo de potencia, potencia acústica, W (vatios acústicos), sobre cualquier esfera a una distancia r se mantendrá constante y para el caso de una fuente isotrópica vendrá dado por Ec.2.1.2.



Figura 2.1.1. Pérdidas en el Trayecto para la propagación de una onda esférica de 1kHz (a) y 10 kHz (b).

$$W = 4 \cdot \pi \cdot r^2 \cdot I \tag{Ec.2.1.2}$$

Si hacemos el ejercicio de resumir todos aquellos aspectos que afectan a la propagación los podríamos agrupar en: *Pérdidas por Transmisión, Ruido y Reverberación, Multitrayecto* y *Dispersión Doppler*. Cada uno de ellos altera de manera distinta en la propagación de señales.

#### 2.1.1. Pérdidas por Transmisión

Los causantes principales de estas pérdidas son la Difusión Geométrica y la Atenuación.

#### • Difusión Geométrica

Hace referencia a la difusión de la energía acústica como resultado de la expansión del frente de ondas. Se incrementa con la distancia y es independiente de la frecuencia. Principalmente encontramos dos clases de difusión geométrica: *Esférica* producto de fuentes omnidireccionales puntuales, asociadas a zonas de gran profundidad. *Cilíndricas* (propagación prácticamente horizontal) asociadas a zonas de poca profundidad. Estas pérdidas (TL, Transmission Loss) se modelan mediante *Ec.2.1.3*, donde  $\mu$  representa la constante de difusión,  $\mu = 2$  para difusión *Esférica* y  $\mu = 1$  para difusión *Cilíndrica* y r en metros es la distancia.

$$TL = 10 \cdot \mu \cdot \log_{10} r \tag{Ec.2.1.3}$$

#### • Atenuación

Aparece como consecuencia, principalmente, de la absorción del medio debida a su vez a la conversión de energía acústica en calor. Se incrementa con la distancia y la frecuencia, las Figuras 2.1.1.(a) y 2.1.1.(b) muestran este fenómeno para dos emisiones esféricas a 500 metros de profundidad, una de 1 kHz y otra de 10kHz, respectivamente.

Si tenemos en cuenta la absorción el modelo presentado en la Ec.2.1.3 quedaría afectado con un nuevo factor,  $\alpha$  (dB/Km), que exprese la absorción en el medio, Ec.2.1.4.

$$TL = 10 \cdot \mu \cdot \log_{10} r + \alpha \cdot r \cdot 10^{-3}$$
 (Ec.2.1.4)

El coeficiente  $\alpha$  depende de la temperatura, salinidad, presión y pH. La expresión *Ec.2.1.5* permite determinar  $\alpha$  para una temperatura de 4°C, salinidad de 35 psu, pH de 8.0 y profundidad de 1000 m [Urick 1983].

$$\alpha(dB/Km) \approx 3.0 \times 10^{-3} + \frac{0.1 \cdot f^2}{1 + f^2} + \frac{44 \cdot f^2}{4100 + f^2} + 2.75 \times 10^{-4} \cdot f^2 \qquad (Ec.2.1.5)$$

donde f es la frecuencia en kHz.

Otra causa de la atenuación la encontramos en las reflexiones en la superficie y fondo del mar. Según la composición del fondo y la frecuencia de la onda acústica pueden aparecer grandes atenuaciones. Sin embargo, las reflexiones en la superficie, dependiendo del estado del mar, no provocan pérdidas por reflexión. También aparecen pérdidas por dispersión, provocadas por la rugosidad de la


Figura 2.1.2. Perfil de Velocidad encontrado en Latitud 28°4' Norte y Longitud 15° 16' Oeste, zona situada a unas 34 millas al norte de Gran Canaria (Islas Canarias, España).

superficie y fondo del mar, también por el desplazamiento del punto de reflexión en la superficie del mar por efecto del viento. Como consecuencia de las variaciones espaciales de la velocidad, Figura 2.1.2, aparece en la propagación submarina un fenómeno de gran importancia conocido como *refracción*.

La velocidad de propagación en el medio marino varia con la salinidad, la temperatura y la profundidad. En la Figura 2.1.2 podemos apreciar el perfil de velocidad encontrado a unas 34 millas al norte de Gran Canaria.

Una fuente acústica en un medio homogéneo, radiando igual energía en todas las direcciones, se propaga a la misma velocidad en todas direcciones. Los frentes de onda en cualquier instante y lugar conservarán una superficie esférica. Esto no ocurrirá así en medios no homogéneos, como es el caso del medio marino. Según vemos en la Figura 2.1.2, la velocidad de propagación disminuye hasta una profundidad de aproximadamente 700 metros, desde ahí empieza a incrementarse con la profundidad. Una de las expresiones típicas para la velocidad de propagación es la ecuación *Ec.2.1.6* de Medwin [Kinsler 1992].

$$c = 1449 + 4, 6 \cdot T - 0,055 \cdot T^{2} + 0,0003 \cdot T^{3} + (1,39 - 0,012 \cdot T)(S - 35) + 0,017 \cdot z \qquad (Ec.2.1.6)$$

donde c es la velocidad del sonido en m/s, T la temperatura en °C, S la salinidad en partes por mil y z la profundidad en m.

La Acústica de Rayos resulta de gran utilidad en el estudio de la Refracción. Básicamente, modelamos la pérdida de transmisión TL sobre la base del Trazado de Rayos (Ray Tracing). Esta técnica asume que es posible sintetizar la propagación de una onda con ayuda de un elevado número de rayos en distintas



Figura 2.1.3. Diagramas de rayos para un perfil de velocidad como el de la Figura 2.1.2, con fuente emisora de ondas acústicas a profundidades de 100 metros (a) y 700 metros (b).

direcciones. Cada rayo, representa un "canal" de energía proporcional al total de energía emitido por la fuente. Una presunción importante que simplifica bastante el problema, es suponer que la amplitud varía más lentamente con la posición que la fase (aproximación de geometría acústica). Luego, el cambio fraccional del gradiente de velocidad del sonido sobre una espacio igual a una longitud de onda, es pequeño comparado con el cociente  $c/\lambda$ , donde  $\lambda$  es longitud de onda en metros [Etter 1991]. Por tanto, su aplicación se verá restringida al dominio de "alta frecuencia", es decir a frecuencias que cumplan con la ecuación Ec.2.1.7.

$$f > \frac{10 \cdot c}{H} \tag{Ec.2.1.7}$$

donde f es la frecuencia en Hz y H es la profundidad en metros. Por ejemplo, para el caso de profundidades de 3000 metros y velocidad del sonido de 1500 m/s, estaríamos hablando de frecuencias superiores a los 50 Hz.

Para estos rayos sobre una cierta distancia corta, digamos local, se puede considerar que siguen una trayectoria rectilínea. Las superficies de fase constante serán los frentes de onda y las normales a estos los rayos. El avance de estos rayos usa la derivada local debida a las variaciones del medio para calcular la nueva dirección de rayo, proceso que se repite hasta completar el trayecto considerado.



**Figura 2.1.4.** Diagramas de rayos para un perfil de velocidad como el de la Figura 2.1.2, con fuente emisora de ondas acústicas a profundidades de 1200 metros (a) y 2000 metros (b).

La Figura 2.1.2 permite considerar al océano como un medio estratificado en función de la velocidad de propagación. Para cada estrato, encontramos características distintas. Aplicando la Ley de Snell [Burdic 1991] será posible componer la trayectoria a seguir por cada rayo. Como consecuencia de las sucesivas refracciones que sufren los rayos, y por tanto la onda, surgen así diversas trayectorias que dependerán fundamentalmente del perfil de velocidad y de la profundidad a la que se encuentre la fuente emisora.

En la Figura 2.1.3 podemos apreciar varios tipos de rayos, dependiendo de la profundidad a la que se encuentre la fuente. En la Figura 2.1.3.(a) en color azul, tenemos aquellos rayos que son refractados pero nunca llegan a reflejarse ni en la superficie ni en el fondo. En la misma figura pero con trazo rojo, tenemos aquellos que se reflejan en el fondo y luego en la superficie, este último tipo de rayos está sujeto a unas pérdidas superiores a las del resto. En la Figura 2.1.3.(b) aparece lo que se conoce como Canal o Conducto Sonoro Profundo, aquí los rayos son refractados sucesivamente agrupándose como si viajaran dentro de un espacio acotado. Este fenómeno justo se produce en las proximidades del mínimo de velocidad de propagación. Por encima tenemos una pendiente negativa que fuerza a los rayos hacia el fondo, mientras que por debajo del mínimo tenemos una pendiente positiva que provoca lo contrario. En estos canales o conductos la energía acústica puede propagarse con bajas pérdidas a grandes distancias. A la profundidad de 1200 metros, Figura 2.1.4.(a), el efecto del canal sonoro prácticamente desaparece, aunque los rayos continúan confinados en un cierto conducto, sin llegar a reflejarse ni en la superficie ni en el fondo.

Por último, en la Figura 2.1.4.(b) y por efecto de la pendiente positiva del perfil de velocidad, los rayos son dirigidos hacia la superficie. Aquí aparecen las llamadas Zonas de Convergencia, zonas de alta intensidad acústica [Jensen 2000], fenómeno que se repite en la distancia de una manera casi periódica. Por ejemplo, en el Atlántico Norte aparecen espaciadas unos 65 Km con ganancias de 20 dB sobre la propagación esférica [Jensen 2000].

$$TL = 10 \cdot \log \frac{r \cdot \Delta h}{\Delta \theta} \tag{Ec.2.1.8}$$

Las pérdidas por transmisión para rayos refractados vienen dadas por la ecuación *Ec.2.1.8*. Este será el caso de rayos separados inicialmente  $\Delta \theta$  que a la distancia *r* presentan una separación vertical  $\Delta h$ . En ausencia de refracción  $\Delta h \approx r \cdot \Delta \theta$ , en cuyo caso se reduce a la clásica dispersión esférica.

En aquellos casos en los que la energía viaja en un canal o conducto, Figura 2.1.3.(b), tendríamos que considerar que las pérdidas por transmisión se expresan mejor mediante Ec.2.1.9.

$$TL = 10 \cdot \mu_1 \cdot \log_{10} r_0 + 10 \cdot \mu_2 \cdot \log_{10} \frac{r}{r_0} + \alpha \cdot r \cdot 10^{-3} \quad \left(r_0 = \frac{H}{2 \cdot tg \beta_0}\right)$$
(Ec.2.1.9)

donde  $\mu_1 = 2$ ,  $\mu_2 = 1$ ,  $r_0$  es la *distancia de salto o transición*, en metros, H la profundidad del conducto, en metros, y  $\beta_0$  es la apertura angular del conducto, o dicho de otra manera el rango más menos de direcciones de incidencia que quedan recogidas en el conducto. Si interpretamos directamente la expresión Ec.2.1.9, entendemos que la propagación es esférica dentro del conducto hasta  $r_0$  y a partir de ahí esta se vuelve cilíndrica.

## 2.1.2. Ruido y Reverberación

Aunque de naturaleza y orígenes bien distintos, desde el punto de vista de la comunicación submarina ambos, Ruido y Reverberación, acarrean consecuencias similares y comparten la consideración de señales indeseables.

### • Ruido

En el medio marino no podemos hablar de un sólo tipo de ruido, aunque si de uno prolongado en el tiempo, *Ruido de Fondo* o *Permanente*. Si excluimos toda forma de ruido propio, fuentes de ruido transitorias y todo aquel identificable, nos quedamos con este ruido que será el nivel sonoro residual y permanente [Urick 1983].

La Figura 2.1.5 nos muestra el reparto espectral del ruido de fondo o permanente en función de la frecuencia, dividido en cinco regiones principales. La región I, de



Figura 2.1.5. Distribución espectral del Ruido de Fondo o Permanente en el medio marino (adaptado de [Urick 1983]).

frecuencias muy bajas, obedece al ruido de origen hidrostático (olas y mareas) y a la actividad sísmica y volcánica lejana, es con diferencia el de nivel acústico más elevado. La región II, comprendida entre 1 y 20 Hz, se debe a la turbulencia oceánica, su nivel decrece con la frecuencia. La región III, de 20 a 500 Hz, se corresponde con el ruido de tráfico distante, tiene un carácter fluctuante. La expresión Ec.2.1.10 presenta un modelo empírico para el nivel de ruido (NL, *Noise Level*) en esta región.

$$NL_{III} = NL_{100} - 20 \cdot \log(\frac{f}{100})$$
 (Ec.2.1.10)

donde  $NL_{100}$  varia de 60 a 90 dB re 1µPa/ $\sqrt{Hz}$  dependiendo de la densidad media de tráfico marítimo.

$$NL_{IV} = NL_{1K} - 15,9 \cdot \log(\frac{f}{1000})$$

$$\begin{cases} NL_{1K} = 41, 2 + 22, 4 \cdot \log v & \text{para } \delta T < 1^{\circ}\text{C y } v \ge 1 \text{m/s} \\ NL_{1K} = 41, 2 + 22, 4 \cdot \log v - 0, 26(\delta T - 1)^{2} & \text{para } \delta T \ge 1^{\circ}\text{C y } v \ge 1 \text{m/s} \end{cases}$$

$$(Ec.2.1.11)$$

La región IV, comprende desde los 500 Hz a los 100kHz, y se trata del ruido entorno al punto de medida originado en la superficie del mar, decrece con la frecuencia a un ritmo de -5 a -6 dB por octava. Por ser este rango de frecuencias el preferido en los sistemas sónar marinos es la región más documentada a nivel de modelos, uno de ello es el propuesto por Applied Physics Laboratory, University of Washington [Lurton 2002] Ec.2.1.11. También en esta región de frecuencias se concentran los sistemas de ecolocalización de los mamíferos marinos [Au 1993, Au 1977, Møhl 2000, Møhl 2003]. En la ecuación Ec.2.1.11tenemos que v es la velocidad del viento (en m/s) y  $\delta T$  es la diferencia de temperatura entre el agua del mar y el aire sobre la superficie del mar.

Por último la región V recoge el denominado ruido térmico originado por el movimiento molecular. En esta región el ruido crece con la frecuencia a un ritmo de 6 dB por octava y es el dominante a partir de los 100kHz. El modelo de ruido para esta región se recoge en Ec.2.1.12.

$$NL_{V} = -75 + 20 \cdot \log f \tag{Ec.2.1.12}$$

### • Reverberación

El mar contiene, en sí mismo y en sus limites (superficie y fondo), partículas de polvo, fluctuaciones intrínsecas, cardúmenes de peces y otros organismos vivos. Por otro lado, en lo referente al volumen contiene pináculos y montes submarinos sobre el lecho marino. Estas inhomogeneidades forman discontinuidades en las propiedades físicas del medio, y además interceptan y reemiten una porción de la energía acústica incidente sobre ellos. Esta acción se conoce como dispersión, y a la suma total de las contribuciones de todos los dispersores se la conoce como reverberación. La reverberación actúa como un ruido al añadir un componente indeseable y aleatoria a la señal. Sin embargo, sus orígenes son bien distintos. El nivel de reverberación se alimenta de la señal emitida, ya sea desde un sistema de comunicación submarina o un sónar activo, sin ella no existe. Otras características importantes son que decrece con el tiempo, una vez cesa la transmisión, y que posee características espectrales prácticamente idénticas a la señal emitida.

La reverberación puede agruparse, dependiendo del dispersor considerado, en tres clases: Superficie del mar, fondo del mar y volumen oceánico. Los modelos que existen para cuantificarlas son esencialmente empíricos. Por ejemplo, la Fuerza de Dispersión Superficial (Surface Scattering Strength,  $S_s$ ) medida por Chapman y Harris [Burdic 1991] viene dada por *Ec.2.1.13*.

$$S_{s} = 3, 3 \cdot \beta \cdot \log \frac{\theta}{30} - 42, 2 \cdot \log \beta + 2, 6$$

$$\beta = 107, 46 \cdot (v \cdot f^{1/3})^{-0.58}$$
(Ec.2.1.13)



**Figura 2.1.6.** Efecto de los niveles reverberantes y nivel de ruido en la propagación de señales submarinas.

donde v es la velocidad del viento en m/s, f la frecuencia en Hz y  $\theta$  la dirección de incidencia en la superficie. El nivel de reverberación deducido en [Burdic 1991] sería el de la *Ec.2.1.14*.

$$RL_{s} = S_{s} + SL - \frac{3}{2}TL + 10 \cdot \log \frac{c \cdot t_{p} \cdot \gamma_{B}}{2}$$
(Ec.2.1.14)

donde SL es el nivel emitido, TL son las pérdidas por transmisión considerando propagación esférica, c es la velocidad de propagación en el medio,  $t_p$  es la duración del pulso emitido y  $\gamma_B$  el ancho de haz efectivo en acimut. Observamos que el nivel de reverberación disminuye reduciendo la duración del pulso y el ancho de haz efectivo. Para el caso de la reverberación volumétrica tendríamos una expresión similar, Ec.2.1.15, aunque dependiente de una Fuerza de Dispersión Volumétrica ( $S_v$ , Volume Scattering Strength).

$$RL_{\nu} = S_{\nu} + SL - TL + 10 \cdot \log \frac{c \cdot t_p \cdot \Omega_B}{2}$$
(Ec.2.1.15)

A grandes distancias el factor limitante será el ruido de fondo, mientras que en distancias más cortas lo será el nivel reverberante, Figura 2.1.6. Esta aseveración no es ni definitiva ni categórica, ya que los niveles de reverberación son dependientes de la energía con la que se ha excitado al medio, concentración de la misma en un espacio angular determinado y duración de dicha excitación.



**Figura 2.1.7.** Escenario para el estudio de la reflexión superficial (a) y Anomalía de Transmisión para Campo de Interferencia [Urick 1983] para dicho escenario (b).

## 2.1.3. Propagación Multitrayecto

La propagación multitrayecto ocurre siempre y cuando sea posible más de un trayecto entre fuente y receptor [Urick1983]. Se da con mayor frecuencia para grandes alcances, en propagación por conductos submarinos (superficiales o profundos) y en aguas poco profundas. En ocasiones los trayectos están tan ampliamente separados, angularmente hablando, que sus efectos se pueden discriminar mediante el uso de sistemas directivos.

Los distintos trayectos que se forman en el caso más simple entre emisor y n receptor son tres: Directo, Reflexión en Superficie y Reflexión en el Fondo.

La reflexión sabemos tiene lugar cuando una onda desplazándose por un medio determinado alcanza la frontera con un segundo medio [Kinsler 1992], por ejemplo la superficie o el fondo del mar. Estas reflexiones según la dirección de incidencia, composición del medio y estado del medio, agitado o en calma, provoca pérdidas de energía. El coeficiente de reflexión característico del medio considerado cuantifica esas pérdidas. Para las reflexiones en la superficie del mar podemos considerarlo, según su estado, como un reflector perfecto (mar en calma) o como un dispersor (mar agitado). Si actúa como un reflector perfecto su coeficiente de reflexión es prácticamente la unidad, es decir el 100% de la energía se refleja, de modo que la superficie sólo cambia la dirección de propagación de la onda, reflector perfecto. Este caso ha sido estudiado para un escenario simple de sólo trayecto directo entre fuente y receptor más un única reflexión en la superficie [Urick1983], Figura 2.1.7.(a). En esas condiciones, la presión acústica total y la intensidad acústica total, promediada en el tiempo, en el receptor vendrán dadas según Ec.2.1.16.

$$P_{T} = P_{1} + P_{2} = \frac{P_{0}}{l_{1}} sen(\omega t) + \frac{\gamma \cdot P_{0}}{l_{2}} sen[\omega \cdot (t+\tau)]$$

$$I_{T} = \frac{\overline{P_{T}^{2}}}{\rho c} = \frac{\overline{P_{0}^{2}}}{\rho c} \left\{ \frac{1}{l_{1}} sen(\omega t) + \frac{\gamma}{l_{2}} sen[\omega \cdot (t+\tau)] \right\}^{2}$$
(Ec.2.1.16)

donde  $P_0$  es el máximo de presión acústica emitido por la fuente, en Pa,  $l_1$  y  $l_2$  son las longitudes de los trayectos directo y reflejado respectivamente, en metros,  $\omega$ la frecuencia de la onda, en rad/s,  $\gamma$  el coeficiente de reflexión de la superficie del mar, igual a 1 si el mar está en calma,  $\tau$  el retardo de la onda reflejada respecto de la directa, en segundos. En base a *Ec.2.1.16* y el escenario de la Figura 2.1.7.(a) podemos representar la *Anomalía de Transmisión* (TA, Transmission Anomaly) en la Figura 2.1.7.(b) [Urick 1983], para lo que se ha considerado que el coeficiente de reflexión en la superficie,  $\gamma$ , vale 1.

En la Figura 2.1.7.(b) podemos observar la zona denominada *Campo de Interferencia*. Se trata de una zona en la que aparecen una serie de máximos (6 dB) y mínimos profundos, distribuidos espacialmente en localizaciones dependientes de la relación  $l/l_0$ , donde  $l_0 = {}^{4 \cdot d_1 \cdot d_2}/_{\lambda}$ , para longitud de onda  $(\lambda)$  y profundidades de la fuente y el receptor  $(d_1 y d_2 \text{ en metros})$ , y l es la longitud del camino directo entre fuente y receptor, Figura 2.1.7.(a). A partir de ahí existe una segunda zona denominada *Campo Lejano*. Ésta presenta una caída uniforme dependiente de la cuarta potencia del alcance. De manera eminentemente práctica las pérdidas por transmisión, TL, en cada zona pueden expresarse mediante *Ec.2.1.17.a* para *Campo de Interferencia* y *Ec.2.1.17.b* para *Campo Lejano*.

$$TL = 20 \cdot \log_{10} l + TA + \alpha \cdot l \cdot 10^{-3} \qquad (a)$$
  
$$TL = 40 \cdot \log_{10} l + \alpha \cdot l \cdot 10^{-3} \qquad (b)$$

donde l es la distancia entre transmisor y receptor en metros.



Figura 2.1.8. Ejemplo de propagación multitrayecto donde observamos los trayectos principales considerando reflexiones de hasta segundo orden. Observamos Trayecto Directo (TD), Trayecto Superficie (TS), Trayecto Fondo (TF), Trayecto Superficie Fondo (TSF) y Trayecto Fondo Superficie (TFS).



Figura 2.1.9. Escenario considerado para los resultados expuestos en las figuras 2.10 y 2.11.

El fondo del mar es un medio reflectante y a la vez dispersivo. Posee características similares en naturaleza a las de la superficie del mar.

Sin embargo, sus efectos son más complicados que los de la superficie debido a su composición diversa y estratificada. Específicamente, el fondo del mar está estratificado, con densidades y velocidades del sonido que pueden cambiar de manera gradual o abrupta con la profundidad, incluso sobre distancias cortas. Además, es más variable que la superficie en sus propiedades acústicas debido a que su composición puede variar de rocas duras con gran poder reflector a lodo poco denso con gran poder absorbente. Sin embargo, con respecto a la superficie del mar es posible considerar que sus características permanecen constantes a lo largo del tiempo.



Figura 2.1.10. Señales emitidas y recibidas en el escenario de la Figura 2.1.9 para pulso de 8 ms de duración.

La propagación multitrayecto, Figura 2.1.8, provoca fluctuaciones en fase y llegándose amplitud en el receptor, al caso extremo ocasionar de desvanecimientos de la señal (fading). También produce distorsión en la señal como consecuencia de los distintos tiempos de propagación para cada trayecto. Otro efecto importante es la falta de correlación tanto en fase como en amplitud, que ocurre cuando son varios los receptores y están separados. En la Figura 2.1.10 tenemos un ejemplo de cómo cambia no solo la forma de onda, sino también la duración de la señal. En la Figura 2.1.9 se expone el escenario utilizado para los resultados representados en las Figuras 2.1.10 y 2.1.11. El escenario se compone de una fuente, cuadrado azul, y un receptor, asterisco, las imágenes de la fuente (círculos) hasta tercer orden, también están las trayectorias directa (trazo azul) y reflejadas en superficie y fondo (trazo discontinuo rojo). En la Figura 2.1.10 podemos ver los efectos sobre las señales cuando el pulso emitido tiene una duración significativa para el escenario. El pulso recibido es significativamente más ancho como consecuencia de la integración de la señal directa con reflexiones de superficie y fondo, también sus amplitudes son distintas, en resumen aparecen varias y severas distorsiones.



**Figura 2.1.11.** Señales emitidas y recibidas en el escenario de la Figura 2.1.9 para pulso de 2 ms de duración.

Igualmente, en la Figura 2.1.11 tenemos las señales resultantes para el caso en el que emitimos un pulso de duración más corta. Con pulsos más cortos es menos probable sufrir los efectos del multitrayecto. Logramos así una separación en el tiempo de la señal directa respecto de sus réplicas. Por ejemplo, los clics emitidos por los cachalotes son de muy corta duración a fin de evitar los efectos del multitrayecto en sus procesos de ecolocalización [Møhl 2003].

## 2.1.4. Dispersión Doppler

Las señales acústicas submarinas están sujetas a cambios en la frecuencia. La frecuencia de la señal recibida difiere de la frecuencia de la señal emitida. Las causas pueden ser varias, movimientos relativos de la fuente, blanco, receptor y movimientos del medio de propagación (corrientes, oleaje, etc.). El fenómeno, bien conocido, es el denominado Efecto Doppler.

Si suponemos una fuente acústica desplazándose a una velocidad u (m/s) y un receptor moviéndose a velocidad v (m/s), ambos en la misma dirección y sentidos contrarios, es decir acercándose, el desplazamiento en frecuencia o *Desplazamiento Doppler* vendría dado por *Ec.2.1.18*.



Figura 2.1.12. Escenario Doppler considerado para la derivación de las expresiones Ec.2.1.19, Ec.2.1.20 y Ec.2.1.21.

$$\Delta f = \frac{u+v}{c}f \tag{Ec.2.1.18}$$

Un caso más general, adaptado de [Kinsler 1992], sería considerar una fuente sonora, por ejemplo un mamífero marino, y un buque dotado de un sistema sónar pasivo adecuado para la localización de esos animales, Figura 2.1.9. Ambos desplazándose con velocidades y direcciones diferentes. Supongamos, que el mamífero marino emite una señal de frecuencia fundamental  $f_1$ , debido a su movimiento la frecuencia percibida en el medio por un observador fijo, buque de observación, será  $f_w$ , Ec.2.1.19, mientras que si el buque también se desplaza se observará la frecuencia  $f_2$ , Ec.2.1.20.

$$f_w = f_1 \left( 1 + \frac{V \cdot \cos \theta}{c} \right) \tag{Ec.2.1.19}$$

$$f_2 = f_w \left( 1 + \frac{U \cdot \cos \phi}{c} \right) \tag{Ec.2.1.20}$$

Siempre que las velocidades del buque V y la del mamífero marino U, sean mucho menores que c, velocidad de propagación del sonido en el medio, el desplazamiento de frecuencia vendrá dado por Ec.2.1.21.

$$\Delta f = \frac{V \cdot \cos \theta + U \cdot \cos \phi}{c} f_1 \qquad (Ec.2.1.21)$$

La importancia que esta dispersión puede tener, la podemos resolver con un ejemplo práctico. Supongamos el siguiente escenario, un barco dotado de un sistema de localización y seguimiento de mamíferos marinos [Leaper 1992, Thode 2004, Thomas 1986], concretamente un Cachalote. Típicamente en este tipo de operaciones los barcos se desplazan a velocidades entre 2 y 10 nudos. Los cachalotes cuando nadan relajados lo hacen a velocidades entre 3 y 9 nudos, pudiendo llegar hasta 27 nudos cuando huyen [Col 2009, Wahlberg 2002]. Si aplicamos Ec.2.1.21 al supuesto de un barco y un cachalote en la misma dirección y sentidos contrarios, yendo ambos a los máximos de velocidad considerados. El barco iría a 5,1 m/s y el cachalote a casi 14 m/s. Si consideramos que la frecuencia fundamental de emisión es de 5 kHz, el desplazamiento en frecuencia ( $\Delta f$ ) al sustituir en Ec.2.1.21 sería de 63 Hz. Luego, este efecto será poco significativo en nuestra aplicación.

# 2.2 Propagación en Entornos Electromagnéticos Aéreos

El medio electromagnético es la vía de enlace preferida por múltiples sistemas de telecomunicación. Cada uno de esos sistemas proporciona servicios y cada servicio tiene, por lo general, asignada una banda del espectro electromagnético. A su vez, dentro de esa banda los distintos proveedores o usuarios del servicio disponen de una o varias frecuencias con su correspondiente ancho de banda. Esto constituye el o los canales a través de los que proporciona sus servicios. El uso del medio de acceso a estos servicios, el medio electromagnético, está regulado por distintos organismos nacionales e internacionales surgidos al efecto. Los equipos y dispositivos de telecomunicaciones necesarios para proporcionar estos servicios, en su mayoría, tienen como referencia para los fabricantes un estándar. Dicho estándar está recogido en un documento donde se refleja un conjunto de normas y recomendaciones técnicas que regulan, entre otros, aspectos relativos a los canales radioeléctricos habilitados al efecto, modulaciones, protocolos, etc.

El desarrollo incesante de Internet sus aplicaciones y servicios, asociado al de la tecnología de los sistemas de telecomunicación y la informática personal, han permitido el alumbramiento de aplicaciones tales como las *Redes Inalámbricas de Área Personal* (Wireless Personal Area Networks, WPANs). Asociado a este servicio existe el estándar IEEE 802 que en su parte 15.4 establece las especificaciones de Control de Acceso al Medio (Wireless Medium Access Control, MAC) y de la Capa Física (Physical Layer, PHY) para Redes Inalámbricas de Área Personal de Baja Velocidad (Low-Rate Wireless Personal Area Networks, LR-WPANs). El estándar en cuestión (IEEE 802.15.4) define el protocolo y la interconexión de los dispositivos vía radiocomunicación en el ámbito de las redes de área personal [IEEE 2006].

Nuestro interés por este sistema de telecomunicación viene motivado porque las WSN, empleadas y en parte estudiadas en esta tesis, operan en el área de las WPANs.

Frecuencia Central (MHz)	Rango de	Parámetros			
	Frecuencias (MHz)	Modulación	Tasa Binaria (Kb/s)	Código	
868	868-868,6	BPSK	20	Binario	
915	902-928	BPSK	40	Binario	
2.450	2.400 - 2.483, 5	O-QPSK	250	16-ary Ortogonal	

**Tabla 2.2.1.** Bandas de frecuencia, modulaciones y tasas binarias del estándar IEEE 802.15.4[IEEE 2006].



Figura 2.2.1. Ondas que van desde emisor a receptor por reflexión, difracción y dispersión.

El propósito principal del estándar IEEE 802.15.4 es abogar por un mínimo de complejidad, un ínfimo consumo de potencia y un bajo coste en las soluciones de interconexión inalámbrica sobre redes de baja velocidad. Todo ello dentro del considerado *Espacio de Operación Personal* (Personal Operating Space, POS), permitiendo velocidades de transferencia de datos de hasta 250 Kbps en alcances de hasta 10 m, siendo posible alcances mayores a velocidades más bajas.

El estándar IEEE 802.15.4 define tres bandas de frecuencias, con un total de 27 canales. Disponemos de dieciséis canales en una banda con frecuencia central de 2,45 GHz, es el caso de la WSN con las que trabajamos en esta tesis. Los restantes canales se reparten en diez en la banda de 915 MHz y uno en la de 868 MHz, Tabla 2.2.1.

Además, el empleo de la técnica Espectro Ensanchado por Secuencia Directa (Direct Sequence Spread Spectrum, DSSS) incrementa la fiabilidad y el ancho de banda de la comunicación en estos sistemas.

Es importante reseñar otra característica de la banda de 2,45 GHz. Se trata de una de las bandas reservadas internacionalmente para uso en áreas industrial, científica y médica (Industrial Scientific and Medical, ISM), por ejemplo los hornos microondas que operan en 2.450 MHz. Uno de los atractivos de esta banda es su uso por parte de los sistemas de comunicaciones sin necesidad de licencia.

Sin embargo, estos equipos deben ser tolerantes ante cualquier interferencia procedente de equipos ISM y a su vez no provocarlas sobre los equipos con licencia para esa banda. Una vez presentado el contexto en el que están inmersas las WSN que utilizamos en esta tesis, pasamos a modelar el medio físico que soporta las redes con que trabajaremos.

## 2.2.1 Modos de Propagación

Varios son los modos en que una onda electromagnética radiada desde un emisor puede alcanzar al receptor, Figura 2.2.1. Lo puede hacer en línea recta, este sería el caso en el que ambas antenas, receptora y transmisora, se ven es decir están en *línea de visión directa* (Line Of Sight, LOS) sin obstrucciones entre ellas. También lo puede hacer por *reflexión* en una o en varias superficies. Otro modo en que podría llegar sería por *difracción*, bordeando o superando un obstáculo. Podría alcanzar al receptor por *refracción* en la atmósfera, es decir no siguiendo una trayectoria rectilínea. Igualmente, si la onda sufre *dispersión* sobre alguna superficie, parte de la energía electromagnética podría dirigirse en la dirección del receptor y alcanzarlo de este modo.

Puede suceder que en un lugar de recepción determinado la onda electromagnética llegue mediante varios o todos los modos nombrados, estaríamos hablando de propagación multitrayecto. También puede suceder que sólo llegue por un modo concreto, por ejemplo en el caso de no existir LOS, por presencia de un obstáculo (edificio, montaña, etc.), sólo llegaría por *difracción*. Otro efecto que pudiera darse, en caso de velocidad relativa ente emisor y receptor, es el Doppler que produce un cambio de frecuencia.

En esta tesis trabajamos con redes WSN en distribuciones espaciales donde serán posibles los modos: *Línea de Visión Directa, Reflexión, Difracción* y *Dispersión*. Descartamos en nuestros trabajos el efecto de la refracción pues las distancias de propagación van a ser de varias decenas de metros, y del Doppler pues las velocidades a las que se viajarán los móviles con que trabajamos son muy pequeñas (p.ej., algunos m/s).

Veamos a continuación algunos aspectos importantes de los modos de propagación que nos resultan de interés.

## • Reflexión

La reflexión ocurre cuando una OEM propagándose incide sobre una superficie uniforme de grandes dimensiones en comparación con la longitud de onda de la señal RF. Para que tenga efecto debe cumplir la Ley de Snell [Balanis 1989], es decir el ángulo de incidencia y el de reflexión respecto al plano de reflexión son iguales. En la Figura 2.2.2 se muestra mediante rayos la onda incidente y la reflejada con direcciones de propagación representadas mediante los vectores unitarios  $u_i$  y  $u_r$ . Así mismo, también se muestran las componentes paralela y perpendicular del campo eléctrico al plano de reflexión. Una observación importante es que la componente perpendicular del campo OEM incidente, cambia de signo después de la reflexión. La señal reflejada es de polarización circular izquierda LCP si la incidente es puramente RCP (polarización circular derecha) [Balanis 1989].



Figura 2.2.2. Reflexión de una onda electromagnética de polarización circular.



**Figura 2.2.3.** Coeficiente de reflexión en función del material que integra al reflector, ángulo de incidencia y polarización de la onda respecto del plano de la superficie reflectante.

El coeficiente de reflexión depende del ángulo de incidencia y de las propiedades de los dos medios, aquí aire y superficie reflectante. Estas propiedades son la constante dieléctrica, la permitividad y conductividad tanto del material del reflector como del aire. Parte de la onda que incide es transmitida al medio reflector y parte es devuelta al aire. El coeficiente de reflexión es dependiente también de la polarización de la onda respecto al plano de la superficie reflectante. La Figura 2.2.3 nos muestra la variación del coeficiente de reflexión para varios materiales típicos de paredes exteriores de edificios [Delfino 2006].



Figura 2.2.4. Base esquemática del modelo "knife-edge" para estimar la atenuación por difracción en situaciones asimilables al esquema representado. T representa al punto de emisión y R al de recepción.

#### • Difracción

La Difracción ocurre cuando el trayecto entre el transmisor y el receptor se ve obstruido por un cuerpo denso con dimensiones comparables o mayores a la longitud de onda. Es un fenómeno que contabiliza la energía de la OEM que viaja desde el transmisor al receptor sin LOS entre los dos [Vaughan 2003]. Por tanto, el campo EM difractado es otro modo en que se puede alcanzar al receptor, incluso cuando entre este y el emisor se proyecta una sombra tal que presenta una obstrucción impenetrable.

Como primera aproximación, para estimar la atenuación ( $L_{\text{DIF}}$ ) que presenta para la OEM la difracción, podemos usar el modelo "*knife-edge*" (por arista o pantalla) [Woerner 1995]. La ecuación *Ec.2.2.1* presenta el modelo aplicable a la presencia de obstrucciones por elevaciones del terreno o incluso edificios, ver Figura 2.2.4.

$$L_{DIF}(dB) \approx \begin{cases} 6,02+9,11\nu'1,27\nu^2, & para \quad \nu \le 2,4 \\ 12,953+20 \cdot \log_{10} \nu, & para \quad \nu > 2,4 \end{cases}$$

$$v = \sqrt{\frac{2 \cdot d}{\lambda}} tg\alpha tg\beta = H \sqrt{\frac{2 \cdot d}{d_t \cdot d_r \cdot \lambda}}$$
(Ec.2.2.1)

donde *H* es la altura de la obstrucción en metros,  $d_t y d_r$  la distancias (en metros) transmisor-obstáculo y receptor-obstáculo respectivamente,  $d = d_t + d_r$ . Los ángulos  $\alpha y \beta$  son los que forman las rectas que unen transmisor y receptor, respectivamente, al borde superior de la arista. Al factor v se le conoce como parámetro de difracción de *Fresnel-Kirchhoff*.

#### • Dispersión

La dispersión, también conocida como reflexión especular, tiene lugar sobre aquellas superficies reflectoras que presentan rugosidades comparables a la longitud de onda de la señal [Delfino 2006], en estas condiciones la energía reflejada se dispersa en todas direcciones En general, las superficies rugosas son aquellas que cumplen el criterio de Rayleigh, por tanto, una superficie genérica se considera rugosa si:

	$\phi = 90^{\circ}$	$\phi = 45^{\circ}$	$\phi = 10^{\circ}$	$\phi = 0^{\circ}$
h=100cm, $\sigma = 29$ cm	-328	-25,7	-27,9	-0,16
h=50cm, $\sigma$ = 14,5 cm	-328	-25,1	-4,3	-0,04
h=10cm, $\sigma$ = 2,89 cm	-5,9	-2,7	-0,16	0
h=1cm, $\sigma$ = 2,89 mm	-0,5	-0,03	0	0

 

 Tabla 2.2.2. Variación en dB del coeficiente de reflexión para rugosidad de distribución uniforme y frecuencia de 900 MHz.

$$h \ge \frac{\lambda}{8 \cdot sen\phi}$$

donde h es la máxima profundidad de las protuberancias o rugosidades,  $\lambda$  es la longitud de onda y  $\phi$  el ángulo de incidencia. En un entorno urbano los obstáculos que típicamente actúan como dispersores son farolas, placas de calles, follaje, etc. En este tipo de superficies el coeficiente de reflexión se reduce en función de un factor de atenuación introducido por Rayleigh [Delfino 2006, Vaughan 2003].

$$\rho_{rugosa} = \rho_{plana} \cdot \exp\left[-2\left(\frac{2\pi}{\lambda}\sigma \cdot sen\phi\right)^2\right]$$

donde  $\rho_{\text{rugosa}}$  es el coeficiente de reflexión para una pared rugosa y  $\rho_{\text{plana}}$  es el coeficiente de reflexión para una superficie que no presente dispersión y  $\sigma$  es la desviación estándar de la rugosidad superficial. Un ejemplo, teórico pero clarificador, sería suponer una rugosidad de distribución uniforme. Las alteraciones de la superficie varían de -h/2 a h/2 (h es la altura profundidad máxima de las rugosidades). La desviación estándar será:  $\sigma = 0,289 \cdot h$ . Según la Tabla 2.2.2, obtenida para 900 MHz ( $\lambda = 33,3$  cm) se deduce que existe una gran diferencia entre los casos de incidencia rasante a incidencia normal y que la rugosidad debe estar bastante por debajo de la longitud de onda para no tener efecto con incidencia oblicua y rasante.

### • Múltiples Trayectos

Cuando una OEM alcanza un determinado lugar de recepción a través de varios de los modos citados, se le denomina como modo o propagación de múltiples trayectos, también multitrayecto o multicamino. En la propagación EM esta es una característica importante que afecta a la calidad del enlace de comunicación. Para las frecuencias de microondas este modo se manifiesta como una mezcla de reflexiones especulares en superficies tales como el suelo, difracción en los bordes de los edificios, montañas, etc., así como dispersión difusa debido a superficies reflectoras de textura rugosa o no uniforme (paredes, paneles, muros, vallas, postes, barreras, etc.). El fenómeno en si mismo provoca que se reciban varias réplicas de la señal en lugar de una versión única. Al tratarse de distintos trayectos o recorridos cada réplica sufrirá atenuaciones y retardos distintos, por tanto en el instante de su llegada, fases y amplitudes serán distintas para cada una. Por tanto, las ondas que llegan al receptor lo hacen con amplitudes y fases



Figura 2.2.5. Figura de ruido en función de la frecuencia y origen para T0=290°K (adaptada de [McPherson 1979]).



Figura 2.2.6. Absorción atmosférica en función de la frecuencia debida a la molécula de oxígeno y al vapor de agua (adaptada de [McPherson 1979]).

con distribución aleatoria, al combinarse el resultado es una señal fluctuante en tiempo y espacio. Luego, en una determinada localización podríamos tener una señal muy diferente a la obtenida en otra localización a muy corta distancia de la anterior.

## 2.2.2 Ruido, Interferencia y Absorción

### • Ruido

El ruido de procedencia externa en radiofrecuencia, "*sky noise*" se clasifica según su origen en cuatro tipos, tres con un origen claramente externo: Atmosférico, Cósmico o Galáctico y el procedente de la Actividad Humana (man-made noise) que tiene dos versiones, Urbana y Suburbana. El cuarto es el propio del sistema de comunicación, el ruido de la antena y el receptor, Ruido Térmico.

El "*sky noise*" es fuertemente dependiente de la frecuencia, aunque para bandas estrechas se le puede considerar constante con la frecuencia. En la banda de nuestro interés, 2,45 GHz, predomina el ruido de receptor y antena (ruido térmico) y el de actividad humana, Figura 2.2.5.

### • Interferencias

Las interferencias al igual que el ruido son una señal indeseada. En la banda ISM donde trabajamos en esta tesis existe equipamiento comercial, teléfonos inalámbricos, cámaras de seguridad y toda una suerte de dispositivos de consumo no inmersos en red. Además, la comparten varios servicios de telecomunicación. Por ejemplo, coexisten los del estándar IEEE 802.15.4 (LR-WPANs, de nuestro interés), Bluetooth y las del estándar IEEE 802.11b Redes Inalámbricas de Área Local (WLAN). Por tanto, los focos interferentes con los que nos podemos encontrar son variados. También se puede considerar como interferencia a las réplicas llegadas a través de los múltiples trayectos posibles, aquí nos referiremos únicamente a las originadas en otros dispositivos emisores.

Un ejemplo de sus efectos nos lo reporta [Lee 2006]. La experiencia consistió en poner un Nodo típico de los usados en WSN, próximo, 10 metros, a una estación base (dispositivo IEEE 802.11b). El efecto de las interferencias fue una reducción en la tasa de paquetes recibidos del 23% (23% de paquetes perdidos). Aquí la solución no pasa solo por hacer a los sistemas más robustos frente a las interferencias, sino que necesitan ser capaces de coexistir y operar cuando estén juntos. Sin embargo, no debemos de olvidar que contamos con que los fabricantes de estos dispositivos aplican técnicas de espectro ensanchado. Técnicas que proporcionan cierta resistencia a los efectos de las interferencias, aunque las soluciones no hay que buscarlas sólo en la capa física en [Lee 2006] proponen la creación de un Agente de Optimización (Optimization Agent, OA ) actuando como un intercambiador de información entre las distintas capas OSI.

En el caso de los canales inalámbricos las interferencias más típicas son las cocanal (Co-Channel Interference, CCI) y las de canal adyacente (Adjacentchannel interference, ACI).

### Absorción

La atenuación por absorción que sufre una onda electromagnética al propagarse por el aire, se agrupa en dos causas principales. La primera, absorción atmosférica debida a la molécula de oxígeno y a la del vapor de agua. La Figura 2.2.6 nos muestra que en la banda de nuestro interés (2,45 GHz), la absorción se



Figura 2.2.7. Modelo genérico de canal inalámbrico.

encuentra por debajo de 0,01 dB/Km para el oxígeno e irrelevante para absorción por vapor de agua. Y la segunda causa la encontramos en la lluvia. Esta atenuación depende, básicamente, de la frecuencia y de la intensidad de la precipitación. Un desarrollo del modelo empírico clásico para el cálculo de esta atenuación lo encontramos en [Olsen 1978].

> $A(dB/Km) = a \cdot R^{b}$  $a = G_{a} \cdot f^{E_{a}};$  para f < 2,9 GHz  $G_{a} = 6,39 \cdot 10^{-5}, E_{a} = 2,03$  $b = G_{b} \cdot f^{E_{b}};$  para f < 8,5 GHz  $G_{b} = 0,851, E_{b} = 0,158$

donde a y b dependen, entre otros factores, de la frecuencia f y temperatura de la precipitación, R es la intensidad de la precipitación en mm/hr. A la frecuencia de 2,45 GHz se pueden alcanzar los 0,02 dB/Km para lluvia de intensidad 152,4 mm/hr [Olsen 1978].

Por último, podríamos citar aquí la atenuación ejercida por la vegetación como parte de la absorción del medio. En el rango de frecuencias de nuestro interés sus efectos presentan cierta relevancia con atenuaciones del orden de los 0,4 dB/m a 3 GHz y 0,1 dB/m a 1 GHz [Willis 2005].

## 2.2.3 Modelos de Propagación

Nuestro interés y la importancia del estudio de la propagación de ondas electromagnéticas (OEM) y los modelos de predicción para la estimación de la potencia recibida, reside en que son una de las piedras angulares de varios algoritmos de localización y seguimiento a desarrollar en esta tesis.

Un modelo de propagación se puede expresar en una ecuación (con frecuencia dada en dB) que describe la relación entre potencia recibida y transmitida a través del efecto conjunto del canal de propagación radioeléctrica, la electrónica de los dispositivos, las antenas, etc. En comunicaciones inalámbricas existen los modelos del *Canal Radioeléctrico Inalámbrico* que pueden definirse mediante *Modelos Físicos* o *Modelos Estadísticos*. Otros efectos de interés sobre la comunicación son el ruido, las interferencias y el movimiento relativo entre emisor y receptor en forma de efecto Doppler.

Mención especial merecen los obstáculos en el camino de propagación. Es el caso del suelo, paredes, montañas, vegetación, etc. Estos provocan fenómenos tales como reflexiones, dispersión y difracción (Figura 2.2.1), y efectos añadidos tales como absorciones, posibles cambios de polarización, etc. Si al lugar de recepción la señal llega procedente de varias direcciones, producto de otras tantas reflexiones, aparece la denominada propagación multitrayecto (*multipath*). Esto puede causar fluctuaciones de amplitud y fase, dando lugar a lo que se conoce como *desvanecimiento por multitrayecto (multipath fading*). También pueden aparecer variaciones en la dirección de procedencia observada.

### • Propagación en Espacio Libre

En este modelo se considera que el espacio entre transmisor y receptor está libre de objetos que puedan absorber, reflejar, difractar o dispersar la energía electromagnética. También, se supone en este modelo que el medio es perfectamente uniforme y no absorbente. Además, se considera que el suelo se encuentra muy alejado o bien que su coeficiente de reflexión es nulo o despreciable. Respecto de las antenas se considera que tanto la antena receptora como la transmisora son isotrópicas [Vaughan 2003] y que la antena receptora se encuentra en la zona de *campo lejano* de la antena transmisora. Con estas condiciones la potencia recibida en dBm para espacio libre vendrá dada por *Ec.2.2.2*, por tanto la atenuación por pérdidas de propagación (Path Loss, PL); crecen con el inverso del cuadrado de la distancia entre transmisor y receptor, y con la frecuencia.

$$P_{R}(dB) = P_{T}(dB) + 20 \cdot \log_{10} \left(\frac{\lambda}{4 \cdot \pi \cdot d}\right) = P_{T}(dB) - PL(dB)$$
$$PL(dB) = 20 \cdot \log_{10} d + 20 \cdot \log_{10} \left(\frac{4 \cdot \pi}{\lambda}\right)$$
$$(Ec. 2.2.2)$$

donde  $P_{\rm R}$  y  $P_{\rm T}$  son las potencias recibida y transmitida en dB, d la distancia, en m, que en línea recta separa receptor y transmisor, y  $\lambda$  la longitud de onda. Si las antenas receptora y transmisora presentasen directividad se incluirán las ganancias en dB respectivas de cada una  $G_{\rm R}$  y  $G_{\rm T}$ .

$$P_R(dBm) = P_T(dBm) + G_R(dB) + G_T(dB) - PL(dB)$$

La expresión de PL también podría ser vista incluyendo un parámetro,  $\alpha$  (constante de atenuación), en espacio libre  $\alpha = 2$ . Esto permite generalizar la expresión a otro escenario con constante de atenuación distinta a la de espacio libre.



Figura 2.2.8. Parámetros geométricos del modelo de dos rayos. En foto tenemos un transmisor montado en un trípode y un receptor montado en la verja de la ventana.

$$PL(dB) = 10 \cdot \alpha \cdot \log_{10} d + 20 \cdot \log_{10} \left(\frac{4 \cdot \pi}{\lambda}\right)$$
 (Ec.2.2.3)

La ecuación *Ec.2.2.3* es derivada de la conocida como modelo de Friis y se ha dicho, entre otras limitaciones, que el receptor tiene que estar en la región de *campo lejano (far-field)* de la antena transmisora (*far-field*). Esta región también llamada de Fraunhofer de define como aquella superior a una distancia  $d_{\rm F}$  (distancia de Fraunhofer) relacionada con la dimensión mayor de la apertura numérica de la antena transmisora, además de con la longitud de onda de la señal portadora.

$$d_F = \frac{2 \cdot D^2}{\lambda}$$

donde D es la dimensión física real de la antena y  $\lambda$  la longitud de onda. Por tanto, la ecuación anterior es válida si se cumple la siguiente condición:

$$d_F >> D$$
 y  $d_F >> 1$ 

### • Modelo de dos rayos

Este modelo es útil para conocer la reflexión que tienen las señales sobre la superficie de la tierra, se basa en óptica geométrica. En el modelo se considera la transmisión de las señales en LOS junto con la propagación de la onda reflejada sobre la superficie de la tierra. Es un modelo que al tomar en cuenta más factores se acerca más a la realidad, por tanto será más adecuado para predecir PL. El terreno, dadas las separaciones entre transmisor y receptor manejadas en esta tesis, se puede considerar plano.

En general las expresiones que encontramos en la literatura al efecto [Vaughan 2003, Pahlavan 2002] están orientadas a los casos donde la distancia d (ver Figura 2.2.8) es mucho mayor que las alturas de la antena receptora  $(h_{\rm R})$  y transmisora  $(h_{\rm T})$  sobre la superficie terrestre. En nuestras aplicaciones esto no es así. En [Willis 2005] podemos encontrar la siguiente expresión más adecuada a nuestro caso.

$$PL(dB) = 20 \cdot \log_{10}\left(\frac{4 \cdot \pi}{\lambda}\right) - 20 \cdot \log_{10}\left|\frac{e^{-jkL_{D}}}{L_{D}} + \Gamma(\alpha)\frac{e^{-jkL_{R}}}{L_{R}}\right|$$

donde  $\Gamma$  es el coeficiente de reflexión,  $\alpha$  el ángulo de incidencia y k el número de ondas ( $k = 2 \pi/\lambda$ ). Igualmente en [Stoyanova 2007] *Ec.2.2.4*, encontramos una expresión de utilidad para su nuestro caso, con la diferencia de que se ha considerado que la reflexión en el suelo es perfecta ( $\Gamma$ =-1), no es tan genérica como la anterior pero si más práctica.

$$PL = 10 \cdot \log_{10} \left( \left( \frac{\cos \Delta \theta}{L_D} - \frac{1}{L_R} \right)^2 + \left( \frac{sen\Delta \theta}{L_D} \right)^2 \right)$$

$$\Delta \theta = \frac{2 \cdot \pi \cdot (L_R - L_D)}{\lambda}$$
(Ec.2.2.4)

#### • Desvanecimientos

Existen dos tipos de desvanecimientos (fading) que caracterizan a las comunicaciones móviles: Desvanecimiento a gran escala (*large-scale fading*) y a pequeña escala (*small-scale fading*) [Sklar-I 1997]. El desvanecimiento a gran escala representa la atenuación promedio de la potencia de señal o pérdidas por trayecto debidas a desplazamientos sobre grandes áreas. El desvanecimiento a gran escala se ve influenciado por elevaciones y obstáculos presentes en el área de movimiento que circunda a transmisor y el receptor (colinas, bosques, vallas publicitarias, grupo de edificios, etc.). El receptor se suele representar oculto por las elevaciones o los obstáculos. Las estadísticas existentes sobre los desvanecimientos a gran escala facilitan la estimación de las pérdidas por trayecto en función de la distancia.

Los desvanecimientos a pequeña escala se refieren a cambios drásticos en la amplitud y fase de la señal, como consecuencia de pequeños cambios en la posición relativa entre receptor y transmisor (tan pequeños como media longitud de onda). A este tipo de desvanecimiento se le denomina *Desvanecimiento Rayleigh*, si las múltiples reflexiones son grandes en número y no hay componente LOS (Non Line-Of-Sigt, NLOS), la envolvente de la señal recibida tiene naturaleza estadística, lo que se representa mediante la función densidad

TIPO DE DEGRADACIÓN	Técnica de Reducción	
Selectiva en Frecuencia	Ecualización adaptativa	
	Espectro Ensanchado	
	Señal redundante	
Desvanecimiento Rápido	Codificación y entrelazado	
	Modulaciones robustas	
Desvanacimiento Plano y Lonto	Algún tipo de diversidad	
Desvanecimiento Plano y Lento	Código corrector de errores	

 Tabla 2.2.3. Relación de medidas técnicas para combatir el desvanecimiento según el tipo de degradación.

de probabilidad de Rayleigh. Cuando exista una componente dominante presente, como por ejemplo la componente LOS, (LOS+NLOS), la envolvente del desvanecimiento a pequeña escala se describe mediante una función densidad de probabilidad de Riciana. Este tipo de desvanecimiento se presenta a través de dos mecanismos: Dispersión temporal de la señal y una conducta variante del canal con el tiempo como consecuencia del movimiento [Sklar-I 1997].

En la dispersión temporal se presentan dos categorías de degradación: Desvanecimiento Selectivo en Frecuencia y No-Selectivo o Plano. El selectivo en frecuencia aparece cuando  $T_{\rm m} > T_{\rm s}$ , el retardo máximo ( $T_{\rm m}$ ) entre réplicas es mucho mayor que el tiempo de símbolo ( $T_{\rm s}$ ). El retardo máximo se entiende como el tiempo transcurrido entre la recepción del primer y último componente, está relacionado con la inversa del ancho de banda de coherencia. Condición que ocurre si los componentes multitrayecto de un símbolo se extienden más allá de la duración de un símbolo, causando interferencia inter-simbólica (InterSymbol Interference, ISI). Se dice que el canal exhibe desvanecimiento no selectivo en frecuencia o plano si  $T_{\rm m}$ <T<sub>s</sub>.

En este caso, todos los componentes multitrayecto de un símbolo llegan dentro del tiempo de símbolo, por lo tanto no son separables. La degradación puede aparecer como consecuencia de la suma destructiva entre componentes con distinta fase. Esto provoca una sustancial reducción de la relación señal a ruido ( Signal to Noise Relation,SNR).

Cuando el canal es variante las categorías de degradación son *Desvanecimiento Rápido (fast fading)* y *Lento (slow fading)*. Si  $T_o < T_s$ , donde  $T_o$  es el tiempo de coherencia del canal y  $T_s$  el tiempo de duración de un símbolo. La condición viene a decir que el tiempo en el que el canal se comporta de una manera correlada es pequeño en comparación con el tiempo de duración de un símbolo. Por tanto, el *Desvanecimiento Rápido* puede causar que el pulso en banda base sea distorsionado, como resultado perderemos SNR lo que frecuentemente produce una tasa de error irreducible. Esos pulsos distorsionados provocan problemas de sincronización en los receptores. Si  $T_o > T_s$  quiere decir que el estado del canal permanecerá sin cambios durante el tiempo de transmisión de un símbolo. Luego, los pulsos de los símbolos no sufrirán distorsión, al igual que en el caso del desvanecimiento plano la principal degradación será perdidas en SNR.

En la Tabla 2.2.3 recogemos una serie de técnicas para combatir algunas de las degradaciones que se sufren por desvanecimiento [Sklar-II 1997].

### • Modelos Deterministas y Estadísticos

La utilidad específica de los modelos reside en su capacidad para predecir la potencia de la señal recibida a distancia, o la que necesitamos transmitir para alcanzar determinado objetivo, p.ej. no interferir otra zona. Básicamente las alternativas están fundamentadas en modelos deterministas o físicos y estadísticos o empíricos. Los modelos, también se pueden clasificar en tres grandes tipos como función de la escala del escenario considerado para la aplicación: Modelo de Gran Escala (*Large Scale Models*), Modelo de Pequeña Escala (*Small Scale Model*) y los Modelos de Propagación en Interiores (*Indoor Propagation Models*). Además, cuando se trata de propagación en exteriores (*Outdoor Propagation models*) el tipo de entorno; urbano, suburbano o campo abierto también forman parte de la definición del modelo.

Los modelos empíricos o estadísticos están basados en el análisis estadístico de un gran conjunto de medidas. Por lo general en los modelos más simples la estimación de las pérdidas de propagación con la ayuda de un conjunto de diagramas basados en medidas empíricas [Hata 1980]. Los parámetros principales de estos modelos son: Frecuencia, distancia y altura de antenas, como parámetros iniciales. El entorno también se caracteriza mediante la selección del tipo de ciudad, tipo de zona suburbana o rural.

En un estadio intermedio se encuentran los semi-deterministas modelos más complejos basados en cálculos teóricos y estadísticos en conjunción con medidas de campo. En este caso el impacto del entorno puede modelarse con algo más de precisión con el añadido de aspectos teóricos. Estos modelos requieren parámetros adicionales sobre el entorno lo que les hace más específicos, esto conlleva la necesidad de rehacer los cálculos cuando las condiciones cambian.

Los modelos deterministas están basados en la simulación electromagnética del entorno de simulación. El objetivo de la simulación es tratar de estimar todas las características del canal de radiofrecuencia incluyendo, retardos, polarización y dirección de cada uno de los componentes de los múltiples trayectos. Se entiende que son modelos dependientes del entorno, por ello es difícil encontrar un modelo capaz de adaptarse a todos los entornos. Métodos como Diferencias Finitas en el Dominio del Tiempo (Finite Difference Time-Domain, FDTD) se usan como medio para obtener la respuesta al impulso, también Ray Tracing constituye una opción dentro de los modelos deterministas.

Cuando se trata de espacios pequeños, inferiores a la consideración de microcélulas en telefonía móvil, el modelo Ray Tracing permite simular físicamente la propagación de las ondas de radio, en este caso se tienen en cuenta los mecanismos de propagación con mayor exactitud [Vaughan 2003]. Al tratarse de longitudes de onda pequeñas podemos estudiarlas mediante geometría óptica, asumiendo que las ondas se propagan en línea recta. El modelo considera cada uno de los trayectos, lo que lleva a un gran nivel de exactitud, siempre y cuando los coeficientes de reflexión sean exactos. Este mismo grado de exactitud también implica un alto costo computacional conforme crece el número de localizaciones a contemplar.

Entorno	Frecuencia	α	σ (dB)
Fabrica de planta diáfana	1300 MHz	2,2	7,9
Matorrales secos de gran altura	1900 MHz	3,6	8,4
Edificio de oficinas de planta diáfana	1900 MHz	2,6	14,1
Playa de arena prácticamente plana	$915~\mathrm{MHz}$	4,2	4,0
Edificio de oficinas con particiones no macizas	1900 MHz	3,8	12,7
Edificio de oficinas con particiones macizas	$1500 \mathrm{~MHz}$	3,0	7,0
Interior de una calle	900 MHz	3,0	7,0
Planta diáfana con LOS	914 MHz	1,9	6,5
Planta diáfana con NLOS	914 MHz	2,4	5,5

**Tabla 2.2.4.** Valores de la constante de atenuación (α) y la desviación estándar (σ) para distintos entornos y frecuencias, adaptada de [Woerner 1995, Andersen 1995].



Figura 2.2.9. Resultado de las medidas de pérdidas por propagación en función de la distancia en un área suburbana con antena emisora a 25 m e altura y receptora móvil a 2 metros de altura, el trazo continuo representa la recta de regresión de los datos (adaptado de [Erceg 1999]).

La mayoría de los modelos actuales aparecen como parte integrante de la tecnología de las telecomunicaciones móviles, donde su papel ha sido y es fundamental en la planificación, principalmente de los servicios móviles de telecomunicación. Un primer modelo es el de propagación en espacio libre, que al no ser realista, únicamente permite hacer una estimaciones muy someras. Cuanto mayor sea la altura de la antena transmisora más se parecen los resultados empíricos a los predichos mediante Ec.2.2.2 [Hata 1980]. Para aplicaciones en comunicaciones móviles, las pérdidas en función de la distancia son proporcionales a la constante de atenuación ( $\alpha$ ) Ec.2.2.3, de modo que su valor depende de la frecuencia, altura de las antenas y entorno de propagación. Por ejemplo, en entornos urbanos las calles pueden actuar como guía de ondas con valores  $\alpha$  por debajo de 2, mientras que si existen obstrucciones sus valores estarían muy por encima de 2.

Sin embargo, este modelo resulta incompleto. Las mediciones de campo realizadas en entornos urbanos, como por ejemplo las mostradas en [Andersen 1995, Stoyanova 2007, Woerner 1995, Erceg 1999, Willis 2005] hacen necesario algún parámetro que introduzca la variabilidad en la señal recibida, aspecto constatado en la práctica, ver Figura 2.2.9, las causas las hemos comentado en apartados anteriores.

$$PL(dB) = 10 \cdot \alpha \cdot \log_{10} d + 20 \cdot \log_{10} \left(\frac{4 \cdot \pi}{\lambda}\right) + X_{\sigma}(dB) \qquad (Ec. 2.2.5)$$

donde  $X_{\sigma}$  es una variable aleatoria de media nula, la precisión del modelo será función de la desviación estándar de dicha variable aleatoria. En la Tabla 2.2.4 podemos ver valores de  $\alpha$  y  $\sigma$  para distintos entornos y frecuencias.

Para alcanzar valores pequeños de  $\sigma$  se hace necesaria una información más específica acerca del entorno o coberturas mucho más cortas. Así basándose en las medidas de Okumura (1968), en [Hata 1980] encontramos el siguiente modelo conocido como modelo Okumura-Hata.

$$PL(dB) = 69,55 + 26,16 \cdot \log_{10} f(MHz) - 13,82 \cdot \log_{10} h_1 - a(h_2) + (44,9-6,55 \cdot \log_{10} h_1) \cdot \log_{10} d(Km) - K$$

donde  $h_1$  y  $h_2$  son las alturas, dadas en metros, de la estación base y la móvil respectivamente, d es la distancia del enlace, f la frecuencia central. El termino  $a(h_2)$  es una corrección de la altura de la antena y ganancia que depende del entorno. El factor K se usa para corregir el tipo de entorno (urbano de ciudad grande o mediana, suburbano y espacios abiertos). Ecuación cuya utilidad está acotada a frecuencias que van de 150 a 1500 MHz, aunque se utiliza hasta los 3 GHz, distancias de 1 a 100 Km, alturas de antena base entre 30 y 100 m y de antena móvil de 1 a 10 m. Este modelo es uno de los más usados en ambientes urbanos. Otros modelos similares en el ámbito de aplicación son el modelo CCIR (Comité Consultivo Internacional de Radiocomunicaciones, actualmente ITU-R), el Cost 231 (extensión del Okumura-Hata hasta 2 GHz ) y el modelo Walfisch-Ikegami que distingue entre propagaciones LOS y NLOS de aplicación en ambientes urbanos densamente poblados.

En esta tesis las distancias y alturas a considerar están bastante por debajo de las acotadas en la mayoría de los modelos. Las nuevas aplicaciones de servicios de comunicaciones personales, puntos de acceso inalámbricos, redes WSN, etc. emplean distancias más cortas y alturas de antenas mucho menores. El de PL en esa zona puede que no quede modelado adecuadamente con los modelos anteriores. En [Erceg 1999] encontramos los resultados de unas medidas de campo, Figura 2.2.9. Observamos que para distancias cortas aparecen valores que no se adaptan a los encontrados para distancias mayores, parecen seguir un patrón diferente. En la Figura 2.2.10 se presenta la variación de la constante de atenuación como función de la altura de la antena emisora [Erceg 1999].



Figura 2.2.10. Variación de la constante de atenuación en función de la altura de la antena emisora y el tipo de terreno (adaptado de [Erceg 1999]).

Directamente de esa figura, primeramente entendemos que para alturas inferiores a los 30 metros existe una gran variabilidad en los valores de la constante de atenuación, casi independientemente del tipo de terreno, circunstancia que se agrava para alturas por debajo de los 10 m. El terreno de categoría A es un terreno con colinas y alta densidad de árboles, el de categoría B es un terreno plano con alta densidad de árboles o con elevaciones medias y baja densidad de árboles, y por último el de categoría C es un terreno prácticamente plano con muy pocos árboles. En cualquier caso el intervalo de variación de  $\alpha$ , si nos fijamos en las medidas, es grande, prácticamente entre 3,5 y 6,5 para las alturas bajas de antena transmisora (por debajo de 30m). El modelo obtenido en [Erceg 1999], ver *Ec.2.2.6*, es valido con antenas transmisoras en alturas entre 10 y 80 metros y distancias de 0,1 a 8 Km.

$$PL(dB) = 20 \cdot \log_{10} \left( \frac{4 \cdot \pi}{\lambda} \right) + 10 \cdot \alpha \cdot \log_{10} d + X_{\sigma}(dB)$$

$$\alpha = (a + b \cdot h_b + \frac{c}{h_b}) + x \cdot \sigma_{\alpha}$$
(Ec.2.2.6)

donde a,b y c son constantes derivadas de las medidas para cada categoría de terreno,  $h_b$  es la altura de la antena transmisora,  $\sigma_{\alpha}$  es la desviación estándar de  $\alpha$  (derivada de los datos de las medidas) y x es un variable gaussiana N[0,1]. Es decir la parte entre paréntesis que vemos en la definición de  $\alpha$  es su valor medio y el resto es su variación aleatoria. No es frecuente encontrar modelos que incidan en el detalle de la variabilidad de la constante de atenuación ( $\alpha$ ) y además lo modelen.

Otro enfoque para modelar lo encontramos en [Franceschetti 2004, Hu 2007], donde emplean modelos estocásticos basados en la teoría de caminos aleatorios. En [Hu 2007] calculando la probabilidad de que un reyo estocástico sufra cierto número de colisiones en una localización espacial específica, obtienen un modelo de Trayecto Aleatorio cuyos resultados muestran una desviaciones más que aceptables, a diferencia de otros modelos, incluso para distancias cortas.

## 2.2.4 Técnicas de Transmisión y Modulación en LR-WPANs

Todos o varios de los fenómenos que hemos presentado en las secciones anteriores podrían darse. No es objeto de esta tesis presentar todas las soluciones posibles. Nos centraremos en las que están presentes en los dispositivos que utilizamos para nuestros experimentos. El nodo inalámbrico modelo Telos B de la firma Crossbow Technology, que entre otras cuestiones cumple con el mencionado estándar IEEE 802.15.4.

### • Técnicas de Modulación DSSS y O-QPSK

El uso de las técnicas de espectro ensanchado en los sistemas de comunicación vía radio, proporciona un medio efectivo para mejorar la fiabilidad de los canales que presentan alto grado de interferencias, así como propagación multitrayecto. Precisamente su resistencia a las interferencias le hace adecuada para esquemas de accesos múltiples, permitiendo más de un usuario con acceso en el mismo canal.

Los sistemas de espectro ensanchado usan técnicas de modulación especiales que dispersan la energía de la señal transmitida sobre una amplia banda de frecuencias. Luego, la información a ser transmitida modula a la portadora mediante cualquiera de las técnicas de modulación digital, en nuestro caso esta es la de Desplazamiento de Fase de 4 Símbolos Compensados (Offset Quadrature Phase Shift Keying, O-QPSK). La técnica de espectro ensanchado empleada es la conocida como Espectro Ensanchado por Secuencia Directa (Direct Sequence Spread Spectrum, DSSS).

En la técnica DSSS la señal en banda base es multiplicada por una secuencia pseudo-aleatoria. Esta secuencia posee una tasa de bit muy superior a la de la señal en banda base, lo que dispersa el espectro de la señal, haciéndolo parecer como un ruido de banda ancha. Cada conjunto de 4 bit constituye un símbolo que se transforma en una secuencia de 16 bits, así cada octeto pasa a 32 bits. La señal dispersada de ese modo se modula seguidamente mediante O-QPSK y se transmite. Con esta modulación los saltos de fase a lo sumo serán de 90°, lo que se traduce en unas fluctuaciones de amplitud muy por debajo de las que aparecen en QPSK. El estándar IEEE 802.15.4 utiliza justamente ese esquema de modulación para la banda de 2.450 MHz [IEEE 2006], Figura 2.2.11. En esa banda de nuestro interés están los canales del 11 al 26, de forma que la frecuencia central de cada canal se calcula mediante la siguiente expresión:



Figura 2.2.11. Diagrama de bloques de las funciones de ensanchado y modulación de la capa física del IEEE 802.15.4 para la banda de 2.450 MHz (adaptado de [IEEE 2006]).



Figura 2.2.12. Frecuencias centrales, ancho de banda y canales en el estándar IEEE 802.15.4 en la banda de 2.450 MHz [IEEE 2006].

 $F_c(MHz) = 2405 + 5(k-11)$  para k=11,12,...,26

La forma en que se distribuyen los canales a lo largo de la banda, ancho de banda de cada canal y la separación entre canales lo podemos ver en la Figura 2.2.12, donde de forma gráfica se muestra la distribución de los canales en el ancho de banda asignado y sus características más relevantes.

#### • Transmisor-Receptor Integrado

La implementación rápida de una unidad transmisora y receptora que cumpla los requisitos de la capa física del estándar IEEE 802.15.4., para sistemas de baja potencia es posible gracias a que en el mercado podemos encontrar soluciones integradas al efecto. Un ejemplo es el circuito integrado CC2420, Figura 2.2.13, de Chipcon Products (Texas Instruments), unidad que incorpora el modulo inalámbrico Telos B como transmisor-receptor.

Se trata de una solución integrada en un único chip que con el añadido de unos pocos componentes pasivos externos cumple todos los requisitos de la capa física del estándar IEEE 802.15.4 en la banda de 2,45 GHz. Este chip ha sido diseñado



Figura 2.2.13. Diagrama de bloques simplificado del CC2420 (adaptado de [Texas 2007]).



Figura 2.2.14. Espectro modulado del CC2420 [Texas 2007].

para aplicaciones inalámbricas de bajo consumo y voltajes de alimentación reducidos (típico en sistemas alimentados mediante pilas). Incorpora un módem DSSS que proporciona una ganancia de 9 dB y es capaz de alcanzar velocidades de transferencia de datos de hasta 250 kbps.

Una funcionalidad interesante que incorpora es la de poder ejercer de monitor del estado de la batería, a través de la consulta de un registro interno que contiene el estado de la misma. También mide la potencia de la señal recibida (Receive Signal Strength Indication, RSSI) y si esta supera un umbral programado, información que a su vez se agrega en la trama de comunicación con el microcontrolador. Realiza el cálculo de la correlación promediada de los 8 primeros símbolos que siguen al SFD (Start of Frame Delimiter), este valor de 7 bits, muy a groso modo, podría entenderse como una medición de la tasa de error de chip. Este parámetro también se agrega en la trama de comunicación con el microcontrolador, si así se programa. El valor de correlación puede utilizarse solo o con RSSI para calcular el indicador de calidad del enlace (Link Quality Indicator, LQI).

Dispone de un regulador de voltaje interno que acepta una tensión no regulada de 2,1 a 3,6 V y provee un nivel regulado de 1,8 V, con el que opera el chip.

La frecuencia de operación al igual que la potencia de transmisión son programables a través de unos registros determinados. La frecuencia puede ser programada con 1MHz de resolución. La sensibilidad típica en recepción es de -95 dBm. La potencia es variable y puede ser configurada desde aproximadamente - 24dBm hasta 0 dBm. La Figura 2.2.14 permite ver como puede ser el grado de interferencia en canales adyacentes, con una atenuación 40 dB respecto a las frecuencias centrales de los canales adyacentes superior e inferior.

El CC2420, posee dos buffers, uno de transmisión, TXFIFO, y otro de recepción, RXFIFO, a los que se accede por medio de dos registros desde el controlador externo. Para facilitar el uso adecuado de estos registros y evitar la pérdida de datos, este chip incorpora una serie de líneas adicionales, con las que informar del estado de los registros a microcontrolador. Incorpora también capacidades de corrección de errores, encriptado y desencriptado.

# 2.3 Tipos de Sensores e Información Básica de Interés

En las agrupaciones concentradas cuando empleamos el término sensor, estrictamente nos estamos refiriendo a algún dispositivo capaz de captar una magnitud física, por ejemplo, presión acústica, temperatura, aceleración, fuerza, campo eléctrico, etc. Claramente, la magnitud que sea debe ser susceptible de percibirse en el medio que rodea al sensor. La tarea del sensor será la transformación en tensión o corriente eléctrica de esa magnitud física. Seguidamente, esa señal eléctrica se acondiciona y se traslada al sistema de procesamiento, de manera individualizada. En la mayoría de los casos esto se hace mediante cables o mediante algún sistema inalámbrico.

En una agrupación de sensores distribuidos, denominar a los elementos (dispositivos) que la componen como sensores sin más, minimiza el alcance de sus capacidades. La denominación de *nodos* sería más acertada, así que a lo largo de esta tesis usaremos ese término. Los nodos pueden estar dotados de varios sensores, estrictamente hablando, además disponen de capacidades tales como: comunicación entre nodos, memorización de información, acondicionamiento y digitalización de las señales de los sensores, ejecución de pequeñas aplicaciones locales, etc. Sin embargo, el objetivo final es el mismo, obtener información de campo de algún tipo de energía, parámetro físico, etc. Además, un nodo puede disponer de varios tipos de sensores con distintas capacidades de transducción. Por ejemplo, el modulo inalámbrico Telos B que integra los nodos de la red usada en esta tesis, opcionalmente, puede incorporar sensores de temperatura, luz, humedad, etc. De ahí que algunos autores han acuñado el término "sensores inteligentes" (smart sensors) para referirse a estos módulos [Al-Ali 2005]. La capacidad de comunicación entre nodos, permite que la central de proceso de datos pueda encontrarse muy alejada del lugar donde físicamente se encuentran éstos. Podría llegarse al caso extremo de encontrarse en otro continente.

Según el tipo de información básica que obtengamos de los sensores, sean estos integrantes de una agrupación concentrada o de un conjunto de nodos pertenecientes a una distribuida, podríamos hablar de Modalidades de Señal, esto es función no sólo de la naturaleza de esa señal, sino también de las condiciones del entorno donde esté inmerso. Un posible conjunto de modalidades y aplicaciones en las que usarlas podría ser el siguiente:

- Sísmica (p.ej., paso de vehículos)
- Acústica (p.ej., voz, sónar)
- Magnética (p.ej., aparcamiento, vigilancia)
- Radiofrecuencia (p.ej., radar)
- Óptica (p.ej., infrarrojos)
- Imagen (p.ej., robots, personas)
- Ultrasonidos en Interior (p.ej., robots, personas)
- Eventos (p.ej., temperatura-fuego en monitorado ambiental)
- Combinación de varias (p.ej., radiofrecuencia y ultrasonidos)

## 2.3.1 Sensores en Agrupaciones Concentradas – Información Básica

El uso más clásico y extendido de estas agrupaciones es la focalización o filtrado espacial de algún tipo de radiación energética. Esta radiación se entiende que alcanza el lugar donde físicamente está desplegada la agrupación. El filtrado espacial puede perseguir la detección, o la localización, o el seguimiento, o la identificación del emisor de esa radiación, o todas a la vez.

Los sensores pueden tomar distintas formas, por ejemplo:

(a) Antenas en radar, radiocomunicaciones y radio astronomía

- (b) Hidrófonos en sistemas sónar
- (c) Geófonos en sismología
- (d) Sondas de ultrasonidos
- (e) Detectores de rayos X en imágenes médicas

En todas y cada una de las diversas aplicaciones, los sensores se diseñan con la mente puesta en un objetivo básico: Proveer de un transductor entre el entorno en el cuál la agrupación está inmersa y la parte del sistema dedicada al procesado de señal. Naturalmente, la forma en que se establece esta transducción depende de la aplicación de interés. Así en radar, radiocomunicaciones y radioastronomía, encontramos antenas que son unos dispositivos electromagnéticos. En sónar, sismología e imágenes médicas, los hidrófonos, geófonos y sondas de ultrasonidos que son transductores electroacústicos diseñados para responder a las ondas de presión recibidas.

En esta tesis vamos a trabajar con radiaciones de origen EM y acústico. Concretamente con las agrupaciones concentradas lo haremos con las de origen acústico en el medio submarino.

Los dispositivos capaces de transformar la energía acústica en eléctrica, estando inmersos en el medio marino, son los hidrófonos. La información básica que facilitan son señales eléctricas proporcionales a las variaciones de presión acústica captadas en el medio. Según las características de la señal a captar seleccionaremos un hidrófono con una sensibilidad, margen dinámico y margen de frecuencias, adecuados. En la Tabla 2.3.1 podemos ver las características fundamentales de un hidrófono, AQ-4, diseñado para uso en agrupaciones. Otros condicionantes más cercanos a la plataforma donde se aplique serán aspectos tales como: dónde van a ir colocados, su peso, como se van a sujetar, que tiempo estarán sumergidos, a qué profundidades, saber si el sistema sufrirá algún tipo de tracción, etc., serán de importancia. Por ejemplo, en el caso de una agrupación que vaya a ser arrastrada desde un barco, no podemos usar cualquier hidrófono. Para estos casos será necesario elegir hidrófonos que sean poco sensibles a la aceleración.

La tecnología usada en estos transductores es la piezoeléctrica mediante cerámicas sintéticas, Figura 2.3.1(a). Para su uso en un hidrófono prácticamente se construye un condensador que tiene como dieléctrico una cerámica piezoeléctrica. Dependiendo del tipo de cerámica y de la orientación del corte de la pieza serán sus características eléctricas. Por su naturaleza eléctrica se trata de dispositivos de alta impedancia de salida por lo que se hace necesario disponer de un preamplificador muy próximo. Esto conlleva que el preamplificador esta preparado para soportar ser sumergido junto con el hidrófono, Figura 2.3.1(b), con lo que debe estar acondicionado para tal circunstancia.

Los hidrófonos pueden presentarse como unidades individuales o ya ensambladas en una agrupación (array en el argot, en adelante lo usaremos indistintamente), generalmente lineal.
Sensibilidad en dBV re 1 µPa ±1dB	-201 dB
Sensibilidad a la aceleración en dBV/G	-70 dB Ponderado A
	-60 dB Lineales
Respuesta en frecuencia ±1.5 dB	1 Hz - 15 kHz
Pérdida de sensibilidad en función de la profundidad.	0,8 dB
Medida a1.732 metros	
Profundidad metros Máxima de Operación /	3.300/6.600
Destrucción	
Índice de Directividad en el eje de ±1 dB	15 kHz
Capacidad en pF ±25%	2.400
Peso en gramos aire/agua	4 / 2,9
Tamaño en cm diámetro / longitud	1,30/3,30

Tabla 2.3.1. Características del hidrófono AQ-4 [Benthos 2008].



Figura 2.3.1. Hidrófono AQ-4 (a) y módulo preamplificador AQ-302 (b) [Benthos 2008].



Figura 2.3.2. Array lineal de dos hidrófonos. El array está dotado de una fuente sonora para calibración del sistema.

Los arrays son unos sistemas de sensores de gran utilidad en la ingeniería del sónar activo y pasivo. Estos sistemas se suelen encontrar desplegados en el lecho



Figura 2.3.3. Diagrama de bloques general de un nodo inalámbrico.

marino, superficie del mar, generalmente en disposición perpendicular a la superficie (array vertical), y en numerosas ocasiones los encontramos arrastrados a cierta distancia desde un barco, Figura 2.3.2 [Hernández 2002], plataforma donde se encuentran los sistemas que procesan sus señales. En su construcción se tienen en cuenta aspectos tan dispares como la profundidad a la que deben ir sumergidos y la adaptación acústica al medio, además de las necesidades de estanqueidad y resistencia a la corrosión del medio. El arrastre se suele realizar mediante cables de acero. Unido a este se encuentra el cable (cable de múltiples pares) por donde viajan las señales eléctricas: alimentación y las captadas por cada uno de los hidrófonos. Los cables y conectores deben estar especialmente diseñados para su uso en el medio marino, garantizando la estanqueidad de todo el sistema, aislamiento eléctrico y resistencia a la corrosión.

# 2.3.2 Nodos Inalámbricos en Agrupaciones Distribuidas-Información Básica

La utilidad de las redes distribuidas de sensores en el ámbito de las WSN son muchas en la actualidad, y surgirán muchas más en el futuro. Por tanto, las capacidades de los módulos inalámbricos que integran sus nodos deben adaptarse a dichas necesidades, eso si partiendo de un tronco común.

Cada nodo tiene la habilidad de interactuar con el entorno físico, procesar independientemente los datos y comunicarse con otros nodos. Por lo general, los nodos tienen un tamaño reducido y son autónomos. A groso modo constan de los bloques: Fuente de alimentación, transmisor-receptor de radiofrecuencia, microcontrolador, memoria y modulo de sensores, Figura 2.3.3 [Puccinelli 2005, Holger 2005].



**Figura 2.3.4.** Identificación física de los dispositivos integrados en la cara frontal del Módulo Inalámbrico Telos B.



Figura 2.3.5. Identificación física de los dispositivos integrados en la cara trasera del Módulo Inalámbrico Telos B.

Con esa composición una red de nodos dispersa por un área geográfica, con capacidad de comunicación y cierto grado inteligencia, puede utilizarse para detectar y caracterizar la presencia o el vertido de agentes: químicos, biológicos, radiológicos, nucleares, explosivos, etc. Esto se puede realizar en distintos entornos y medios: zonas rústicas, bosques, océanos, etc. También pueden alcanzar utilidad en la vigilancia del tráfico en autopistas o en zonas congestionadas. También tienen utilidad en redes de vigilancia para incrementar la seguridad en mercados, comercios, aparcamientos, garajes, etc., como otro de los ámbitos de aplicación. La posibilidad de disponer de varios sensores en cada nodo permite conocer varias magnitudes físicas (temperatura, grado insolación, humedad relativa, presión atmosférica, etc.) en distintas localizaciones, propiciando un conocimiento superior sobre, por ejemplo situaciones ambientales complejas o simplemente conjugar actividades concurrentes. Otro ejemplo, los avances en la tecnología de los sistemas micro electromecánicos o micro sistemas (MicroElectroMechanical Systems, MEMS) y la miniaturización de los circuitos integrados han hecho emerger diminutos sistemas con distintas "habilidades" 2005].Estos sistemas incorporan interfaz [Arampatzis inalámbrica. microcontroladores y microsensores, que en conjunto son capaces de realizar una gran variedad de funciones programables: vigilancia de sucesos, medida de magnitudes físicas, localización y seguimiento de objetos, etc. Estos sistemas representan un caso extremo de uso de nodos sensores.

Para los objetivos de esta tesis usaremos una red WSN cuyos nodos serán módulos inalámbricos Telos B de la firma Crossbow Technology, Figura 2.3.4. y 2.3.5 [Crossbow 2009] La plataforma Telos es el resultado de 12 meses de investigación y desarrollo en la Universidad de California, Berkeley. Se trata de un diseño que parte de las experiencias adquiridas en el diseño de anteriores módulos inalámbricos. Los objetivos principales perseguidos en su creación han sido: operación con ultra-baja alimentación, fácil de usar y robustez en su implementación hardware y software [Polastre 2005].

A continuación vamos a dar un breve repaso a sus características más relevantes para cada uno de los bloques principales presentados en la Figura 2.3.3 (Captación, Comunicaciones, Fuente de Alimentación y Proceso de Datos).

## • Captación

Aquí se encuentran los ojos y oídos del nodo [Culler 2004]. Los distintos sensores de los que puede ir dotado son opcionales, se integran según la aplicación a que se vaya a destinar. Lo típico en el Telos B es el sensor de Humedad Relativa y Temperatura, con rangos que van de 0 al 100% RH y -40 a 123,8°C. La salida que proporcionan es digital. También opcionalmente, puede llevar una gran variedad de sensores de luz con un máximo de dos por módulo, normalmente suelen ser un sensor del espectro visible y otro para radiación fotosintética activa.

## • Comunicaciones

Hemos de distinguir dos tipos de vías de comunicación: el puerto USB y por radiofrecuencia.

El puerto USB se utiliza para comunicarse con el ordenador que actúa de *host*, para ello utiliza un chip controlador USB de la firma Future Technolgy Devices International Ltd. (FTDI). La comunicación se efectúa vía una USART incorporada en el microcontrolador MSP430. Además, de las tareas clásicas:



Figura 2.3.6. Diagrama de bloques simplificado del demodulador del CC2420, adaptado de [Texas 2007].



Nivel de Radiofrecuencia (dBm)

Figura 2.3.7. Valores RSSI típicos en función de la potencia de entrada, adaptado de [Texas 2007].

cambio de parámetros, recogida de datos, indicación de alarmas, etc., también a través de este puerto se realiza la programación del nodo.

Para las comunicaciones mediante radiofrecuencia se usa el circuito integrado CC2420 de Chipcon. El citado chip cumple con las especificaciones IEEE 802.15.4 proporcionando las funciones PHY y algunas MAC. Este chip facilita una comunicación inalámbrica fiable, con una sensibilidad que excede las especificaciones de la IEEE 802.15.4, operando con bajos niveles de potencia. El control sobre el CC2420 se ejerce desde el microcontrolador MSP430 a través del puerto SPI, una serie de líneas digitales de entrada-salida e interrupciones. También controla el apagado y encendido de este subsistema a fin de ahorrar al máximo la energía. La potencia de radiación es programable a través de la escritura en un registro del CC2420 al igual que la frecuencia de operación.



Figura 2.3.8. Diagramas de radiación del Telos B con montaje horizontal (a)

Una característica que será de aprovechamiento en esta tesis es la capacidad de facilitar un indicador digital de la potencia de señal recibida (Received Signal Strength Indicator, RSSI). Este valor se agrega en la trama de comunicación con el microcontrolador. El valor RSSI se calcula, según el esquema de bloques de la Figura 2.3.6, a la salida de la etapa de frecuencia intermedia, en el demodulador, y su valor es promediado sobre periodos de 8 símbolos (128  $\mu$ s). El valor que encontramos en el registro correspondiente no está dado directamente en dBm, es necesario aplicar una constante de valor aproximado a -45, valor hallado empíricamente durante el desarrollo del sistema. Para obtener el valor en dBm hemos de aplicar la siguiente expresión.

$$P(dBm) = RSSI VAL - 45$$

Una gráfica de la lectura del RSSI\_VAL en función de la potencia de entrada se presenta en la Figura 2.3.7. En ella se puede apreciar que la lectura del RSSI desde el CC2420 es muy lineal (±3 dB), con un rango dinámico de 100 dB. Además, la precisión es de ±6dB [TI 2007].

También se calcula un valor de correlación promedio de los 8 primeros símbolos de cada trama, valor que groso modo puede interpretarse como una medición de la tasa de error de símbolo. Este valor también se añade a la trama de comunicación con el microcontrolador y puede utilizarse independientemente o en conjunción con el valor RSSI, para el cálculo del indicador de calidad del enlace (Link Quality Indicator, LQI).

Otro elemento sustancial es la antena. Se trata de un diseño en forma de F invertida (Planar Inverted-F Antenna, PIFA) [Vaughan 2003]. Aunque es usual que a todos los efectos su radiación se considere omnidireccional, su patrón directivo no es ajusta exactamente una radiación igual en todas direcciones, Figura 2.3.8. Además, podemos ver cómo existen diferencias apreciables en estos patrones directivos según su orientación respecto del plano de tierra, Figura 2.3.8(a) y 2.3.8(b). También puede incorporarse una antena externa para lo que dispone del espacio para ubicar un conector SMA, de esta forma el comportamiento radiante no se vera afectado por la presencia de las baterías.

## • Fuente de Alimentación

La alimentación se consigue mediante dos baterías tipo AA. El rango útil de operación está establecido entre 2,1 y 3,6 V, sin embargo este voltaje debe ser como mínimo de 2,7 V cuando se necesita programar las memorias flash, tanto la del microcontrolador como la externa. Precisamente muchos fallos en la programación de estos dispositivos sobrevienen por no disponer de la alimentación adecuada, aspecto que hay que garantizar, sobre todo cuando se realiza la programación de las mismas.

Cuando conectamos el modulo a un ordenador a través del puerto USB, la alimentación se toma desde el propio ordenador, haciendo innecesaria la batería. A través del conector de expansión se puede alimentar al modulo, siempre que este voltaje no exceda de 3,6 V. El consumo del modulo puede variar de 23 mA, microcontrolador y sistema radio operando, a 21  $\mu$ A con el microcontrolador en estado latente.

## Proceso de Datos

El elemento central de este bloque es el microcontrolador (MicroController Unit, MCU) MSP430 F1611 de Texas Instruments. Se trata de un procesador RISC (Reduced Instruction Set Computer) de muy bajo consumo, que contiene 10 kB de memoria RAM , 48 kB de memoria flash y 128 bytes adicionales para almacenamiento de información. Sobre todas sus características destaca su bajo consumo en estado activo y latente, lo que le permite poder operar durante años con sólo un par de baterías del tipo AA y su capacidad para pasar del estado latente al activo en tan sólo 6µs. Internamente dispone de puertos de entradasalida, temporizadores, unidades SPI y UART, 8 puertos ADC externos y 8 internos, además de un modulo DAC de 12 bits y 2 puertos.

En estas sección también encontramos una memoria flash externa con capacidad para 1.024 kB para almacenamiento de datos y código externo, esta memoria se encuentra segmentada en 16 segmentos de 64 kB cada uno.

Por último, indicar que en esta tesis usamos una WSN cuyos nodos fijos, móviles y sumidero están realizados con el módulo inalámbrico Telos B que acabamos de describir, de ahí que le hallamos dedicados estas páginas a fin de contemplar cuáles son sus capacidades, que independientemente del uso que haremos de ellas, se puede ir más allá.

# 2.4 Agrupaciones Concentradas de Sensores

Una buena forma de estudiar las agrupaciones concentradas de sensores es acudiendo al campo de la óptica. Se suele denominar *apertura* a un único sensor o a una agrupación de ellos [Ziomek 1995]. En la misma línea en [Johnson 1993] se define como *apertura* el caso donde los sensores recogen la energía de la señal

sobre áreas finitas, pero continuas, mientras que un array o agrupación consiste en un grupo de sensores espaciados. En la apertura el área de captación de cada sensor es de dimensiones significativas en comparación con la longitud de onda de la señal. Sin embargo, el área de captación de los sensores de un array es muy pequeña respecto de la longitud de onda de la señal. En esta tesis vamos a trabajar con sensores de área pequeña respecto de la longitud de onda y, por tanto, trabajamos con agrupaciones de sensores.

Las señales que nos ocupan en este caso son ondas propagándose dentro de un medio, en nuestro caso campo acústico o electromagnético. Particularmente, usaremos agrupaciones concentradas en el estudio de campos acústicos en el medio submarino. El uso práctico de agrupaciones de sensores de presión acústica para determinar información relativa a la dirección angular desde donde emite una fuente sonora, se conoce y usa desde muy antiguo [p.ej., Urick 1983, Burdic 1991, Hernandez 2002]. Sus fundamentos teóricos (Lord Rayleigh, 1878) tienen mucho más de un siglo. Sin embargo, no fue hasta mucho tiempo después, justo en el transcurso de las guerras mundiales (1914-1945), cuando empezaron a aplicarse técnicas de procesamiento de la señal para mejorar, ampliar y automatizar sus utilidades, en algunos casos de manera muy rudimentaria.

Las utilidades fundamentales de este tipo de sistemas son:

- 1) Reducción del ruido ambiente, por tanto incremento de la SNR
- 2) Resolución de ondas planas incidentes desde distintas direcciones. Esto supone una mejora la relación señal a interferencia, SIR.
- 3) Estimación de la dirección de incidencia de una onda plana.

Las señales serán función de la posición que ocupan en el espacio y del instante de tiempo considerado. La señal en sus dimensiones espacio-tiempo la expresamos como s(x,y,z,t) o s(r,t) si consideramos que el vector r representa a la tripleta (x,y,z). Si suponemos que la fuente de ondas esféricas de la Figura 2.4.1 es monocromática, la señal que alcanza al sensor i, situado en el origen de coordenadas sería:

$$s(\vec{r},t) = \frac{P}{|r|} \exp\left\{j(\omega t - k \cdot \vec{r})\right\}$$

donde P es la amplitud máxima,  $|\mathbf{r}|$  es la distancia, k es el número de onda, t el tiempo y  $\omega$  la frecuencia. La salida del sensor, señal eléctrica, vendría dada por la siguiente expresión:

$$x_{i}(t) = g_{i}(\phi, \theta) \cdot s(\vec{r}, t)$$
$$= g_{i}(\phi, \theta) \cdot \frac{P}{|r|} \exp\{-jk \cdot \vec{r}\} \cdot \exp\{j\omega t\} = a_{i}(\phi, \theta) \cdot s(t)$$



**Figura 2.4.1.** Agrupación Lineal Uniforme (ULA, Uniform Lineal Array) de M sensores, fuente de ondas esféricas a distancia |r| incidiendo desde la dirección ( $\phi$ , $\theta$ ) y ecuaciones para traslación de coordenadas esféricas a rectangulares.

con  $a_i(\phi, \theta) = g_i(\phi, \theta) \exp\{-jk \cdot \vec{r}\} y$   $s(t) = (A / r) \exp\{j\omega t\}, a_i(\phi, \theta)$  es la respuesta compleja en la dirección de incidencia y  $g_i(\phi, \theta)$  es la respuesta compleja en amplitud del sensor en la dirección de incidencia. Si consideramos sensores omnidireccionales para cualquier valor de  $\phi$  o  $\theta$  entonces  $g_i(\phi, \theta) = 1$ . En la literatura de procesado de señales a la dirección de incidencia se le conoce como *dirección de llegada o incidencia* (Direction Of Arrival, DOA). La DOA siempre se mide respecto a la normal a la agrupación o array, mientras que el acimut se mide respecto al eje X [Naidu 2001].

Los sensores de una determinada agrupación pueden estar ubicados de manera regular o irregular a lo largo y ancho de un espacio determinado. Las agrupaciones regulares se presentan sencillas a la hora de situar los sensores, además las funciones matemáticas resultante son fáciles de analizar, lo que permite el uso de algoritmos como el de la FFT en el cálculo, tanto del espectro espacial como de la salida de la agrupación [Johnson 1993].

Según como sea la colocación de los distintos sensores podemos referirnos a agrupaciones Unidimensionales o Lineales, Bidimensionales o Planas y Tridimensionales o Volumétricas. En los apartados siguientes expondremos cada una de ellas, estudiaremos su función directiva y estableceremos el modelo de señal para los casos de interés.

# 2.4.1 Agrupaciones Lineales

En este tipo de agrupaciones todos los sensores están dispuestos sobre una línea, como por ejemplo en la Figura 2.4.1, donde los sensores están alineados sobre el eje Y. Un caso especial de agrupación regular por su amplio uso es aquella en que los sensores están equiespaciados. Esta separación está relacionada con la longitud de onda de la frecuencia de interés, siendo típico un valor de media longitud de onda o menor.

Una agrupación puede verse como una apertura sobre la que se ha realizado un muestreo espacial [Ziomek 1995]. Esto es, una apertura excitada sólo en puntos o en áreas localizadas.

Con un enfoque en el dominio espacial y frecuencial, para una apertura situada en campo lejano de las fuentes emisoras, la función de directividad o patrón de haz, vendría dada por:

$$D(f, \mathbf{a}) = TF_{r_a} \{ A(f, \mathbf{r}_a) \} = \int_{-\infty}^{\infty} A(f, \mathbf{r}_a) \exp(j2\pi \mathbf{a} \mathbf{r}_a) d\mathbf{r}_a$$
$$\mathbf{r}_a = (x_a, y_a, z_a); \quad \mathbf{a} = (f_X, f_Y, f_Z)$$

$$A(f,\mathbf{r}_a) = g(f,\mathbf{r}_a) \exp[j\psi(f,\mathbf{r}_a)]$$

donde f es la frecuencia,  $\mathbf{r}_a$  es el vector de coordenadas  $(x_a, y_a, z_a)$  que da la localización espacial de la incidencia,  $\boldsymbol{\alpha}$  es el vector de las frecuencias espaciales en las direcciones X,Y, y Z, respectivamente, con unidades en ciclos por metro y dadas por el cociente entre los cósenos directores, u, v y w y la longitud de onda,  $\lambda$ .

$$f_X = \frac{u}{\lambda} = \frac{\operatorname{sen} \phi \cdot \cos \theta}{\lambda}, \quad f_Y = \frac{v}{\lambda} = \frac{\operatorname{sen} \phi \cdot \operatorname{sen} \theta}{\lambda}, \quad f_Z = \frac{w}{\lambda} = \frac{\cos \theta}{\lambda}$$

La función  $A(f, \mathbf{r}_a)$  es la respuesta en frecuencia compleja de la apertura, siendo g la respuesta en amplitud y  $\psi$  la respuesta en fase, ambas funciones reales.

Si particularizamos estas expresiones para una agrupación lineal de *M* sensores (p.ej., *M* número impar) distribuidos a lo largo del eje Y, tal y como aparece en la Figura 2.4.1, quedaría:

$$D(f, f_Y) = TF_{y_a} \left\{ A(f, y_a) \right\} = \int_{-\infty}^{\infty} A(f, y_a) \exp(j2\pi f_Y y_a) dy_a$$

Donde la directividad,  $D(f,f_y)$ , está expresada en función de la frecuencia y de las coordenadas esféricas  $\theta$  y  $\phi$ ,  $D(f,f_y) \rightarrow D(f,\theta,\phi)$ .

A fin de disponer de una expressión lo más general posible para una agrupación lineal, vamos a considerar que los M sensores no son idénticos, cada uno tiene una respuesta compleja en frecuencia, además de no estar igualmente espaciados. En este caso la respuesta en frecuencia compleja de la agrupación lineal sería:

$$A(f, y_a) = \sum_{n=-N}^{N} c_n(f) \cdot e_n(f, y_a - y_n), \quad N = \frac{M-1}{2}$$



Figura 2.4.2. Ancho de haz en función de la dirección de apuntamiento (ψ<sub>0</sub>) y del número de sensores en una agrupación lineal (a). Relación entre lóbulo principal y secundario, agrupación de 2 sensores (trazo continuo) y de 4 sensores (trazo discontinuo) separación de media longitud de onda (b).

donde  $y_n$  es la coordenada del sensor n,  $c_n(f)$  la ponderación compleja asociada con el sensor n,  $e_n(f, y_a)$  es la respuesta en frecuencia compleja del sensor n. Luego, la respuesta en frecuencia de una agrupación es igual a la superposición lineal de las respuestas en frecuencia ponderadas de todos y cada uno de los sensores. Por lo tanto, la directividad será:

$$D(f, f_Y) = \sum_{n=-N}^{N} c_n(f) \cdot E_n(f, f_Y) \cdot \exp(j2 \cdot \pi \cdot f_Y \cdot y_n)$$

$$E_n(f, f_Y) = TF_{y_a} \left\{ e_n(f, y_a) \right\}$$

donde  $E_n$  es la directividad para campo lejano del sensor n. Para un sensor de omnidireccional:

$$e_{n}(f, y_{a}) = \delta(y_{a})$$
  

$$E_{n}(f, f_{Y}) = TF_{y_{a}} \{e_{n}(f, y_{a})\} = F_{y_{a}} \{\delta(y_{a})\} = 1$$

Con lo que la función directividad de la agrupación quedaría:

$$D(f, f_Y) = \sum_{n=-N}^{N} c_n(f) \cdot \exp(j2 \cdot \pi \cdot f_Y \cdot y_n)$$

Si los *M* sensores están igualmente espaciados,  $y_n=n \cdot d$ , n=-N,...0,...N, donde *d* es el espacio en metros entre ellos, y la ponderación en amplitud  $c_n(f) = 1$  para todos:

$$D(f, f_Y) = 1 + \sum_{n=1}^{N} \left[ \exp(-j2 \cdot \pi \cdot f_Y \cdot n \cdot d) + \exp(j2 \cdot \pi \cdot f_Y \cdot n \cdot d) \right]$$

$$D(f, f_Y) = \frac{\operatorname{sen}(\pi \cdot f_Y \cdot M \cdot d)}{M \cdot \operatorname{sen}(\pi \cdot f_Y \cdot d)}$$

#### Características y Limitaciones

En las agrupaciones lineales existe un problema potencial con la aparición de máximos adicionales, lóbulos de difracción (grating lobes). Estos son lóbulos no deseados similares al principal que aparecen en la región visible (0 a 360°). Con el objetivo de garantizar que sólo haya un lóbulo principal dentro de la región apuntando en la dirección deseada, el espaciado entre sensores debe visible, seguir un criterio. Este criterio está basado en una versión espacial del teorema del muestreo de la teoría de la comunicación. El teorema del muestreo dice que para evitar el *solapamiento* (aliasing) de una señal en el dominio del tiempo, ésta debe ser muestreada a una tasa de  $f_s = 1/T_s \ge 2f_{\text{max}}$  ciclos por segundo, donde  $f_{\text{max}}$ es la frecuencia más alta del espectro de la señal y  $f_{\rm s}$  la frecuencia de muestreo. La versión espacial sería  $f_{Y_s} = 1/d \ge 2f_{Y_{max}}$ , donde  $f_{Y_s}$  es la frecuencia de muestreo en muestras por metro, d es el periodo de muestreo (espaciado entre sensores, en metros), y  $f_{\text{Ymax}}$  es la componente en frecuencia espacial más alta en ciclos por metro contenida en el espectro angular de la señal. Como  $f_{y_{\text{max}}} = u_{\text{max}} / \lambda_{\text{min}}$ , como u está acotado entre -1 y 1, su valor máximo será la unidad. Por tanto,  $d \le \lambda_{\min}/2$ ,



**Figura 2.4.3.** Agrupación lineal sobre la que inciden tres fuentes, las fuentes a y c son distinguibles, mientras que las a y b son indistinguibles al igual que todas aquellas otras que estén sobre la superficie del cono.

donde  $\lambda_{\min}$  es la longitud de onda mínima asociada con la componente de frecuencia máxima. Si el espaciado entre sensores satisface esa condición se evitará la aparición de los lóbulos de difracción.

El ancho del lóbulo principal, visto como la separación entre el máximo y una caída de 3 dB, aporta una idea de la resolución angular que se puede alcanzar con la agrupación. En el mismo sentido, el ancho del lóbulo principal medido entre cruces por cero [Burdic 1991], viene dado por la siguiente expresión:

$$\theta_{B} = sen^{-1}\left(\frac{\lambda}{N \cdot d}\right)$$

La idea que subyace, es exactamente la misma que podemos tener de un filtro cuando hablamos de frecuencia de corte, banda de transición y banda atenuada. Según la expresión anterior, el ancho de haz disminuye conforme mayor es el número de sensores en la agrupación. Sin embargo, su valor no es constante. El ancho de haz, Figura 2.4.2(a), aumenta conforme lo hace la dirección de apuntamiento desde el *Broad-side* hacia el *End-fire*, Figura 2.4.3. En la Figura 2.4.2(a) observamos que a mayor número de sensores esta variación se hace menor hasta hacerse mínima.

La aparición de lóbulos secundarios que apuntan en direcciones distintas de la del lóbulo principal, suponen una merma en la relación señal a ruido alcanzada en la salida de la agrupación, también en la relación señal frente a interferencias, SIR. A mayor diferencia de amplitudes entre el lóbulo principal y los secundarios, menor será esta merma, Figura 2.4.2(b).

Como consecuencia de las simetrías de muchas agrupaciones, habrá ondas que propagándose a la misma velocidad pero desde distintas direcciones, produzcan exactamente la misma salida [Johnson 1993]. En ese caso, la determinación de su procedencia será ambigua. Geométricamente cada conjunto de direcciones ambiguas conforman un cono, Figura 2.4.3.

Las características y el comportamiento de una agrupación lineal y por extensión de cualquier otra, parten de considerar que los sensores de la agrupación se encuentran fijos en su posición. Sin embargo, hay situaciones donde los sensores están sujetos mediante sujeciones no rígidos (cuerdas, cables metálicos, etc.), esto les da cierto grado de libertad y a su vez conlleva una deformación de la agrupación. Mientras, la separación entre sensores permanece inalterada. Por ejemplo, esto puede ocurrir con las agrupaciones inmersas en el medio marino, donde están sometidas a corrientes marinas, oleaje, etc. Las consecuencias están estudiadas en [Naidu 2001], y van desde el ensanchamiento y deformación del lóbulo principal hasta lo más grave, la ubicación errónea del lóbulo principal.

#### • Modelo de Señal

La señal a la salida de una agrupación de sensores es una señal multidimensional y como mínimo tendremos tantas como sensores. Sea una agrupación lineal de M sensores sobre la que inciden L señales, donde suponemos que las fuentes y el ruido de fondo son estadísticamente independientes. La envolvente compleja de las señales recibidas por la agrupación lineal viene dada por:

$$\mathbf{y}(t) = \sum_{k=1}^{L} g(\theta_k, \omega) \cdot s_k(t) + \mathbf{n}(t)$$

donde  $\mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_M(t)]^T$ , es el vector de las salidas de cada uno de los *M* sensores y  $g(\theta_k, \omega) = [g_1(\theta_k, \omega), g_2(\theta_k, \omega), \dots, g_M(\theta_k, \omega)]^T$  es la respuesta de cada uno de los sensores en una dirección genérica  $\theta_k$  desde donde incide la señal  $s_k(t)$ . Una expresión más completa para la respuesta del sensor sería la siguiente:

$$g_i(\theta_k, \omega) = c_i(\theta_k, \omega) \cdot \exp[-j\omega\tau_i(\theta_k)]$$

donde  $c_i(\theta_k, \omega)$  es la respuesta compleja en amplitud del sensor en una dirección última expresión la podemos explicitar genérica Esta algo más:  $c_i(\theta_k, \omega) = |C_i(\omega)| \exp[j\varphi_i(\omega)] D(\theta_k, \omega)$ , donde  $D(\theta_k, \omega)$  es la función directividad del sensor. En el caso de sensor omnidireccional para cualquier frecuencia  $D(\theta_k, \omega) =$ 1, para  $\forall \theta \in [0^{\circ}, 360^{\circ}]$ . Los factores  $|C_i(\omega)| \neq \varphi_i(\omega)$  hacen referencia a la respuesta en amplitud y fase en función de la frecuencia, respectivamente, para el sensor *i*ésimo. Sin pérdida de generalidad haremos una suposición muy extendida que consiste en considerar a todos los sensores con respuesta plana en amplitud, lineal en fase y omnidireccionales en su directividad:  $g_i(\theta_k) = \exp[-j\omega\tau_i(\theta_k)]$ , donde  $\tau_i(\theta_k) = i (d/c) \operatorname{sen}(\theta_k)$  es el retardo de propagación entre el sensor *i*-ésimo y el sensor tomado como referencia para una fuente localizada en  $\theta_k$ , con una

separación d entre sensores consecutivos, siendo c la velocidad de propagación de las ondas en el medio considerado.

En el campo del Procesado de Agrupaciones de Señales (Array Signal Processing, ASP), cuando se trata de estudiar el problema clásico de la DOA relativa de una fuente radiante, el modelo de señal en forma matricial más extendido para una agrupación lineal [Krim 1996], es el siguiente:

$$\mathbf{y}(t) = \mathbf{A}(\theta) \,\mathbf{s}(t) + \mathbf{n}(t) \tag{Ec.2.4.1}$$

donde  $A(\theta) = [g(\theta_1), ..., g(\theta_L)]$  ( $M \times L$ ) es la matriz de dirección,  $s(t) = [s_1(t), ..., s_L(t)]^T$  el vector de las fuentes de señal y  $n(t) = [n_1(t), ..., n_M(t)]^T$  el vector que representa un ruido aditivo. El vector  $g(\theta_i) = [g_1(\theta_i), ..., g_M(\theta_i)]^T$  contiene la respuesta compleja en amplitud y espacial de los M sensores apuntando en la dirección genérica  $\theta_i$ . Para el caso de una agrupación lineal uniforme  $A(\theta)$  vendría dada por *Ec.2.4.2*. El problema así planteado, como decíamos, se propone como objetivo principal determinar la DOA ( $\theta$ ) de las señales emitidas por las fuentes.

$$\mathbf{A}(\theta) = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ e^{j\phi_1} & e^{j\phi_2} & \cdots & e^{j\phi_L} \\ \vdots & \vdots & & \vdots \\ e^{j(M-1)\phi_1} & e^{j(M-1)2\phi_2} & \cdots & e^{j(M-1)\phi_L} \end{bmatrix}$$
(Ec.2.4.2)

siendo  $\phi_i = \omega \cdot \tau(\theta_i) = k \cdot d \cdot \operatorname{sen} \theta_i$ , k el número de onda  $(2 \cdot \pi/\lambda)$ , d la distancia entre sensores y  $\theta_i$  la dirección de incidencia de la i-ésima fuente.

El modelo presentado en el dominio del tiempo es el modelo base, que puede ser transformado al dominio de la frecuencia. En esta tesis lo usaremos ya que presenta mayor robustez frente al ruido y permite el tratamiento de fuentes de banda ancha [Hayken 1991], además existen estimadores eficientes desde el punto de vista computacional. Desde el modelo base en forma matricial Ec.2.4.1 obtenemos la formulación frecuencial aplicando la transformada de Fourier.

$$\mathbf{y}(t) \xrightarrow{TF} \mathrm{TF}\left\{\sum_{k=1}^{L} g(\theta_k) \cdot s_k(t) + \mathbf{n}(t)\right\}$$

$$\mathbf{Y}(\omega_h) = \sum_{k=1}^{L} g(\theta_k, \omega_h) \cdot S_k(\omega_h) + \mathbf{N}(\omega_h)$$

donde  $\mathbf{Y}(\omega_h) = [Y_1(\omega_h), \dots, Y_M(\omega_h)]^T$  y  $g(\theta_k, \omega_h) = [g_1(\theta_k, \omega_h), \dots, g_M(\theta_k, \omega_h)]^T$  con  $g_i(\theta_k, \omega_h) = c_i(\theta_k, \omega_h) \exp[-j\omega_h \tau_i(\theta_k)]$ . En forma matricial el modelo mostrado en *Ec.2.4.1* quedaría:



Figura 2.4.4. Agrupación plana rectangular (UPA, Uniform Planar Array) (a) y plana circular (UCA, Uniform Circular Array) (b).

$$\mathbf{Y}(\omega_h) = \mathbf{A}(\mathbf{\theta}, \omega_h) \cdot \mathbf{S}(\omega_h) + \mathbf{N}(\omega_h)$$

con 
$$\boldsymbol{\theta} = [\theta_1, ..., \theta_L]$$
,  $\mathbf{A}(\boldsymbol{\theta}, \omega_h) = [g(\theta_1, \omega_h), ..., g(\theta_L, \omega_h)]$ ,  $\mathbf{S}(\omega_h) = [S_1(\omega_h), ..., S_L(\omega_h)]^T$  y  
 $\mathbf{N}(\omega_h) = [N_1(\omega_h), ..., N_M(\omega_h)]^T$ .

# 2.4.2 Agrupaciones Bidimensionales

En las agrupaciones bidimensionales o planas los sensores que la integran están dispuestos, regular o irregularmente, sobre un plano. Ejemplos típicos de geometrías planas son la rectangular y la circular.

Supongamos una agrupación plana sobre el plano XY, Figura 2.4.4(a), la función directividad sería:

$$D(f, f_X, f_Y) = TF_{x_a} TF_{y_a} \{ A(f, x_a, y_a) \}$$
  
=  $\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(f, x_a, y_a) \exp[j2\pi (f_X x_a + f_Y y_a)] dx_a dy_a$  (Ec.2.4.3)

Sin pérdida de generalidad, consideremos una agrupación plana con un número impar de sensores MxN la respuesta compleja en frecuencia de esta agrupación sería:

$$A(f, x_a, y_a) = \sum_{m=-M'}^{M'} \sum_{n=-N'}^{N'} c_{mn}(f) \cdot e_{mn}(f, x_a - x_n, y_a - y_n)$$
$$N' = \frac{N-1}{2}, \qquad M' = \frac{M-1}{2}$$



Figura 2.4.5. Ilustración Espacial del Diagrama de Directividad de una UPA.



Figura 2.4.6. Ancho de haz y atenuación de lóbulos secundarios en una agrupación plana rectangular.

Sustituyendo en Ec.2.4.3, tendríamos:

$$D(f, f_X, f_Y) = \sum_{m=-M'}^{M'} \sum_{n=-N'}^{N'} c_{mn}(f) \cdot E_{mn}(f, f_X, f_Y) \exp[j2\pi(f_X x_m + f_Y y_n)]$$
$$E_{mn}(f, f_X, f_Y) = TF_{x_a} TF_{y_a} \{e_{mn}(f, x_a, y_a)\}$$

donde  $E_{mn}$  es el patrón de haz para campo lejano del sensor mn. Finalmente, si todos los sensores son omnidireccionales y están igualmente espaciados una

distancia  $d_x$  y  $d_y$  metros según el eje X y Y, respectivamente, la función directividad resultante sería:

$$D(f,\theta,\phi) = \sum_{m=-M'}^{M'} \sum_{n=-N'}^{N'} c_{mn}(f) \cdot \exp[j\frac{2\pi}{\lambda}(\sin\phi\cdot\cos\theta\cdot m\cdot d_x + \sin\phi\cdot\sin\theta\cdot n\cdot d_y)]$$

Con las mismas consideraciones realizadas para alcanzar la expresión anterior, pero para una agrupación circular de M sensores distribuidos tal y como aparece en la Figura 2.4.4(b) [Ioannides 2005], la función de directividad vendría dada por la siguiente expresión.

$$D(f,\theta,\phi) = \sum_{m=0}^{M} c_n(f) \cdot \exp\left\{j\frac{2\pi}{\lambda}R \cdot \cos\left[\phi - \frac{2\cdot\pi(m-1)}{M}\right] \cdot \sin\theta\right\}$$

## • Características y Limitaciones

La característica más relevante es la de poder apuntar en acimut y elevación simultáneamente, lo que hace posible un "filtrado" más selectivo de la direcciones espaciales.

La principal limitación es la incapacidad para distinguir el semiespacio de procedencia de la señal, Figura 2.4.5. Aunque, en espacios con límites, como por ejemplo el medio marino, esto puede carecer de importancia si la agrupación se dispone paralela a la superficie del mar y próxima a esta, o desplegada en el lecho marino si este fuera suficientemente plano.

También en este caso aparecen lóbulos secundarios, que limitan la SNR y la SIR de la agrupación, aunque afecta de manera distinta a la rectangular y a la circular. Con igual número de sensores y separación entre sensores, las agrupaciones circulares tienen lóbulos principales más estrechos, es decir menor ancho de haz en caídas a 3 dB. Por el contrario, los lóbulos secundarios de las agrupaciones rectangulares son de menor amplitud, Figura 2.4.6. Luego, mientras las agrupaciones circulares pueden ser más selectivas, las rectangulares se comportan algo mejor en el rechazo al ruido e interferencias. Otro aspecto a destacar es el número de lóbulos secundarios, que es mayor en el caso de las agrupaciones circulares que en las rectangulares, aunque son más estrechos en las circulares.

Cuando se desfasan las señales de sus sensores para apuntar en otras direcciones, diferentes de la normal al plano que contiene la agrupación, sus lóbulos principales se deforman haciéndose más anchos y perdiendo así resolución.

## • Modelo de Señal

La estimación del acimut y la elevación de llegada en un semiespacio es posible con una agrupación plana, p.ej. rectangular. Consideremos una agrupación rectangular de MxN sensores alineados en el plano X-Y tal y como se muestra en

la Figura 2.4.4(a). En la misma observamos que los sensores están regularmente espaciados y separados dx y dy entre sí, según cada uno de los ejes coordenados. La salida en el dominio de la frecuencia para la señal que hay presente en la agrupación procedente de la *i*-ésima fuente se puede expresar como:

$$\mathbf{Y}^{(i)}(\omega_h) = \sum_{m=1}^{M} \sum_{n=1}^{N} g(\theta_i, \phi_i, \omega_h) S_i(\omega_h) + \mathbf{N}(\omega_h)$$

donde

$$\mathbf{Y}^{(i)}(\omega_{h}) = \begin{bmatrix} Y_{11}^{(i)}(\omega_{h}) & Y_{12}^{(i)}(\omega_{h}) & \cdots & Y_{1N}^{(i)}(\omega_{h}) \\ Y_{21}^{(i)}(\omega_{h}) & \cdots & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ Y_{M1}^{(i)}(\omega_{h}) & \cdots & \cdots & Y_{MN}^{(i)}(\omega_{h}) \end{bmatrix}$$

es la salida para la fuente *i*-ésima, con  $Y_{MN}^{(i)}(\omega_h)$  como la componente a la frecuencia  $\omega_h$  presente a la salida del sensor de índice *MN* como respuesta a la fuente *i*-ésima, y

$$\sum_{m=1}^{M} \sum_{n=1}^{N} g(\theta_i, \phi_i, \omega_h) = \begin{bmatrix} g_{11}(\theta_i, \phi_i, \omega_h) & g_{12}(\theta_i, \phi_i, \omega_h) & \cdots & g_{1N}(\theta_i, \phi_i, \omega_h) \\ g_{21}(\theta_i, \phi_i, \omega_h) & \cdots & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ g_{M1}(\theta_i, \phi_i, \omega_h) & \cdots & \cdots & g_{MN}(\theta_i, \phi_i, \omega_h) \end{bmatrix}$$

con

$$g_{mn}(\theta_i, \phi_i, \omega_h) = c_{mn}(\theta_i, \phi_i) \cdot \exp\left\{-j\omega_h \left[m\frac{d_x}{c} \operatorname{sen}(\theta_i) \cos(\phi_i) + n\frac{d_y}{c} \operatorname{sen}(\theta_i) \operatorname{sen}(\phi_i)\right]\right\},$$

$$N(\omega_h) = \begin{bmatrix}n_{11}(\omega_h) & n_{12}(\omega_h) & \cdots & n_{1N}(\omega_h) \\ n_{21}(\omega_h) & \cdots & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ n_{M1}(\omega_h) & \cdots & \cdots & n_{MN}(\omega_h)\end{bmatrix}$$

es la matriz de ruido de la agrupación a la frecuencia  $\omega_h$ , siendo  $n_{MN}(\omega_h)$  el ruido presente a esa frecuencia en el sensor de índices M N. La salida completa de la

agrupación considerando L fuentes incidiendo sobre la misma desde campo lejano será:

$$\mathbf{Y}(\omega_h) = \sum_{i=1}^{L} \mathbf{Y}^{(i)}(\omega_h) = \sum_{i=1}^{L} \mathbf{A}(\theta_i, \phi_i, \omega_h) \cdot S_i(\omega_h) + \mathbf{N}(\omega_h)$$

donde  $\mathbf{A}(\theta_i, \phi_i, \omega_h) = \sum_{m=1}^{M} \sum_{n=1}^{N} g(\theta_i, \phi_i, \omega_h).$ 

En el caso de una agrupación circular tendríamos un modelo similar con cambios en la matriz de dirección,  $\mathbf{A}(\theta_i, \phi_i, \omega_h)$  donde

$$g_n(\theta_i, \phi_i, \omega_h) = c_n(\theta_i, \phi_i) \cdot \exp\left\{-j\omega_h \left[\frac{R}{c}\cos(\phi_i - \frac{2\cdot\pi\cdot(n-1)}{M})\cdot\sin(\theta_i)\right]\right\}$$

con R como el radio de la agrupación y M el número de sensores desplegados. Por tanto la matriz de dirección  $\mathbf{A}(\theta, \phi, \omega_{\rm h})$  para el conjunto de los M sensores y L fuentes será:

$$\mathbf{A}(\theta,\phi,\omega_h) = \begin{bmatrix} g_1(\theta_1,\phi_1,\omega_h) & g_1(\theta_2,\phi_2,\omega_h) & \cdots & g_1(\theta_L,\phi_L,\omega_h) \\ g_2(\theta_1,\phi_1,\omega_h) & \cdots & \cdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ g_M(\theta_1,\phi_1,\omega_h) & \cdots & \cdots & g_M(\theta_L,\phi_L,\omega_h) \end{bmatrix}$$

Para le *i*-ésima fuente la salida en el dominio de la frecuencia será:

$$\mathbf{Y}(\omega_h) = \mathbf{A}(\theta, \phi, \omega_h) \cdot \mathbf{S}(\omega_h) + \mathbf{N}(\omega_h)$$

donde  $\mathbf{S}(\omega_h) = \left[S_1(\omega_h), .., S_L(\omega_h)\right]^T$ .

# 2.4.3 Agrupaciones Tridimensionales

Se trata de agrupaciones donde los sensores se encuentran distribuidos en un volumen, ejemplos típicos son las geometrías cilíndricas y esféricas, en las que centraremos esta introducción.

La función de directividad de una agrupación volumétrica arbitraria en su morfología viene dada por la siguiente transformada espacial en tres dimensiones:

$$D(f, f_X, f_Y, f_Z) = TF_{x_a}TF_{y_a}TF_{z_a} \left\{ A(f, x_a, y_a, z_a) \right\} =$$
$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(f, x_a, y_a, z_a) \times \exp\left[ +j2\pi (f_X x_a + f_Y y_a + f_Z z_a) \right] dx_a dy_a dz_a$$



Figura 2.4.7. Ejemplo de agrupación cilíndrica.

## • Agrupación Cilíndrica

Supongamos una agrupación cilíndrica, Figura 2.4.7, compuesta por  $2 \cdot M+1$  subagrupaciones circulares, dispuestas en planos horizontales  $z = m \cdot d$ , donde  $m = 0,\pm 1,\pm 2,...,\pm M$ , y d la separación vertical entre dos planos adyacentes [Hussain 2005]. Cada sub-agrupación circular tiene un radio a y esta compuesta de N sensores.

$$A(f, x_a, y_a, z_a) = \sum_{n=0}^{N} \sum_{m=-M}^{M} c_{mn}(f) \cdot e_{mn}(f, x_a - x_n, y_a - y_n, z_a - z_n)$$

Sustituyendo en la función de la directividad volumétrica tendríamos:

$$D(f, f_X, f_Y, f_Z) = \sum_{n=0}^{N} \sum_{m=-M}^{M} c_{mn}(f) \cdot E_{mn}(f, f_X, f_Y, f_Z) \exp[j2\pi(f_X x_m + f_Y y_n + f_z z_n)]$$
$$E_{mn}(f, f_X, f_Y, f_Z) = TF_{x_a} TF_{y_a} TF_{z_a} \{e_{mn}(f, x_a, y_a, z_a)\}$$

Finalmente si todos los sensores son omnidireccionales y están regularmente espaciados, la función de directividad resultante sería:



Figura 2.4.8. Ejemplo de agrupación esférica.

$$D(f,\theta,\phi) = \sum_{n=0}^{N} \sum_{m=-M}^{M} c_{mn}(f) \cdot \exp\left\{j\frac{2\pi}{\lambda} \left[R \cdot \cos(\phi - \phi_n) \cdot \sin\theta + m \cdot d \cdot \cos\theta\right]\right\}$$

donde  $\phi_n = 2 \cdot \pi (n/N)$ .

## • Agrupación Esférica

Si consideramos una agrupación esférica con un número par o impar de sensores (MxN), idénticos, igualmente espaciados, omnidireccionales y repartidos sobre la superficie de una esfera de radio R, Figura 2.4.8. La respuesta compleja en frecuencia de esta agrupación sería:

$$A(f,r,\phi,\theta) = \frac{\delta(r-R)}{r^2} \sum_{m=1}^{M} \sum_{n=1}^{N} c_{mn}(f) \frac{\delta(\phi-\phi_m)}{\operatorname{sen}\phi} \delta(\theta-\theta_n)$$

donde  $\phi_m = (m-1) \cdot \Delta \phi$  y  $\Delta \phi = 180^{\circ}/(M-1)$ , para  $M \neq 1$ , siendo  $\theta_n = n \cdot \Delta \theta$  donde  $\Delta \theta = 360^{\circ}/N$ . La respuesta compleja de la agrupación es igual a la superposición de las respuestas en frecuencia de cada uno de los sensores de la agrupación. Sustituyendo en la expresión general para las agrupaciones volumétricas,

obtendríamos el patrón de haz para fuentes en campo lejano de una agrupación esférica.

$$D(f,\phi,\theta) = \sum_{m=1}^{M} \sum_{n=1}^{N} c_{mn}(f) \cdot \exp\left\{j\frac{2\pi \cdot R}{\lambda} \left[ \sin\theta \sin\theta_{m} \cos(\phi - \phi_{n}) + \cos\theta \cos\theta_{m} \right] \right\}$$

Es interesante observar que si M=1 y  $\theta_m=90^\circ$  la expresión resultante se reduce a la que se obtiene para una agrupación circular de radio R.

#### • Características y Limitaciones

No presentan ambigüedad en la determinación de la dirección de incidencia, por lo tanto tenemos la posibilidad de apuntar en cualquier dirección dentro de un hemisferio completo. Sin embargo, su realización práctica no es fácil. En el caso particular de la agrupación cilíndrica presenta un ancho de haz distinto para acimut y elevación. El ancho de haz presenta ensanchamiento cuando apuntamos en direcciones sobre el endfire de la agrupación.

En las agrupaciones esféricas el ancho de haz presenta simetría de revolución, es decir el ancho de haz permanece constante en acimut y en elevación. Al igual que en las cilíndricas el ancho de haz crece cuando apuntamos hacia el endfire.

## 2.4.4 Ancho de Banda de una Agrupación y Señales de Banda Ancha

El ancho de banda de una agrupación depende del tiempo necesario para que un frente de onda la recorra al completo. Para una ULA y definiendo este ancho de banda como un medio de la distancia entre los primeros nulos de su diagrama de directividad, se obtiene [Naidu 2001]:

$$\Delta\omega(Hz) = \frac{2\cdot\pi}{M} \frac{c}{d\cdot \mathrm{sen}\,\theta} = \frac{2\cdot\pi}{\tau}$$

donde  $\tau$  es el tiempo requerido para recorrer la agrupación en segundos, M el número de sensores y d la separación en metros entre sensores consecutivos. Sin embargo, cuando la fuente incide desde el Broad-side el ancho de banda es "infinito". En el caso de una UCA sería el necesario para recorrer el diámetro del círculo, independientemente del ángulo de acimut. La consecuencia más relevante de esto es que para ULAs largas o UCAs de gran diámetro, gran parte de la energía de una fuente de banda ancha se pierde, a menos que se apunte en la dirección de la fuente.

Los modelos de señal que hemos mostrado en los apartados anteriores, se adaptan mejor a los casos en que las fuentes incidentes son de banda estrecha. Idealmente si la señal emitida por la fuente es monocromática, de frecuencia  $f_c$ , al calcular su DFT sólo la línea correspondiente a la a esa frecuencia sería de valor distinto de cero. Tan solo una onda continua, no modulada, verificaría estrictamente esta propiedad. En general hablamos de señales de banda estrecha cuando su ancho de banda, B(Hz), es mucho menor que su frecuencia central,  $f_c$  (Hz), también son aquellas en las que el producto tiempo de observación T (s) por ancho de banda es mucho menor que uno. Por el contrario, una señal de banda ancha se define como aquella cuyo producto tiempo de observación por ancho de banda es mayor que uno. Aunando estas definiciones en el contexto de una agrupación de sensores, la siguiente expresión establece la frontera entre banda ancha y banda estrecha.

$$\frac{D}{\lambda_c} \ll \frac{f_c}{B} \tag{Ec.2.4.6}$$

donde D (m) sería la máxima dimensión de la agrupación,  $\lambda_c$  (m) la longitud de onda de la frecuencia central  $f_c$  (Hz) y B (Hz) el ancho de banda de la señal. En resumen, Ec. 2.4.6 nos viene a decir que la agrupación, en términos de longitudes de onda, ha de ser menor que la relación entre la frecuencia central y el ancho de banda de la señal, para considerar que estamos en banda estrecha. En la práctica un buen orden de magnitud sería diez veces o un ancho de banda por debajo de 1/6 de octava.

Una separación, si se quiere más precisa, de la frontera entre banda ancha y banda estrecha la podemos encontrar en [Zatman 1998]. Donde en base a una definición vaga del concepto de banda estrecha que dice: *cuando hay correlación entre las señales recibidas en los extremos opuestos de una agrupación*. Deriva una expresión analítica más precisa para clasificar, si un entorno de señales determinado debe considerarse de banda estrecha o banda ancha. De esa primera definición básica y para una ULA se puede llegar a considerar banda estrecha si sinc $(b \tau_{1M}) \simeq 1$ , donde *b* es el ancho de banda de la señal en Hz, y  $\tau_{1M}$  es el retardo entre el primer y último elemento de la ULA (*M*). Una frontera más precisa se obtiene a partir de la siguiente definición para banda estrecha, "si el ancho de banda de una señal es tal que el segundo autovalor de la matriz de covarianzas de la señal más ruido, entonces esa señal puede describirse como de banda estrecha".

# 2.5 Despliegue de Nodos Sensores y Topología de la Red en Agrupaciones Distribuidas

En este apartado de la tesis vamos a introducir algunos conceptos relacionados con las redes de sensores. Si bien no es objeto de nuestro trabajo profundizar en estos temas sí es necesario hacer algunas consideraciones de interés que nos servirán cuando abordemos el capítulo 4. En concreto, veamos algunos aspectos del despliegue y la topología de red extraídos de [uSWN D8 2008].

# 2.5.1 Despliegue de Nodos Sensores

El objetivo del despliegue en una red inalámbrica de sensores es cumplir una serie de requisitos relativos a la cobertura y el número óptimo de nodos a la vez que se hace una adaptación a las restricciones que sean de aplicación. Así, consumo energético, fiabilidad, coste, escalabilidad, latencia, etc. son ejemplos de restricciones aplicables. Entendemos, pues, que en el despliegue no sólo se tiene en cuenta el lugar donde se localizan los nodos sino que además se considera cómo conectarlos o intercambiar información entre ellos. Hemos de precisar que la aplicación (bien final o intermedia) es uno de los aspectos más importantes y en esta tesis es la localización y seguimiento de nodos móviles el aspecto principal. No abordamos una aplicación final específica (aspecto que queda abierto) sino que abordamos la localización y el seguimiento como problemas canónicos en este contexto.

Hay varias formas de clasificar un escenario. De nuestro interés está una primera clasificación en que el despliegue es manual [Beutel 2005]. Otra es aquella en la que hay nodos fijos en una ubicación determinada o de naturaleza móvil que se desplazan dentro del área de influencia de la red.

## • Requisitos principales a considerar

- **Tamaño de la red**. Está intimamente ligado al área en la que se hará el despliegue y hace referencia al número óptimo de nodos a desplegar.
- Escalabilidad. Una vez hecho el despliegue inicial puede ser de interés aumentar el tamaño de la red. En una red escalable ha de cuidarse con detalle la influencia de las ubicaciones, mecanismos de enrutamiento, latencias, etc.
- Movilidad de los nodos. Un aspecto a considerar desde el principio es la movilidad de los nodos fijos, esto es, si una vez desplegados inicialmente se verán cambiados de ubicación en un futuro. Nuestros nodos fijos permanecerán siempre así. De cambiar de ubicación lo harán a sitios cuya posición es conocida.
- Tiempo de vida y consumo energético. Este requisito es muy restrictivo pues hace referencia a que los nodos están alimentados por batería que, lógicamente, tienen una vida limitada y ésta depende del consumo que se haga de los recursos energéticos que aporta.
- Heterogeneidad. El hardware y el software involucrados en la red dependen en gran medida del tipo de parámetros físicos a medir.
- Calidad de Servicio. Hace referencia al comportamiento del sistema y cómo realiza éste las tareas que tiene asignadas.
- Tipo de Sensores. Cada aplicación requiere de unos sensores específicos (p.ej., de parámetros medioambientales) y estos imponen una serie de

condiciones sobre aspectos como alcance de las comunicaciones entre nodos, número de nodos, etc. relacionadas con las cualidades de los sensores.

• Hardware de los Nodos. Dependiendo de la aplicación se ha de hacer una selección de en función de la disponibilidad en el mercado, requisitos de los clientes, diseño ad-hoc, etc.

## • Ubicación de los Nodos Sensores

Entendemos por ubicación la acción de poner los nodos en determinados sitios. En este contexto, usualmente se le llama también localización. Hemos de precisar que localización aquí es 'poner un nodo en un sitio' y dejarlo fijo salvo que sea necesario moverlo. Distinguimos así del sentido principal que tiene a lo largo de esta tesis en que consideramos un móvil del que no conocemos su ubicación y ha de estimarse. Por su naturaleza móvil se hace necesario también hacerle un seguimiento. En el despliegue esta visión no tiene este sentido.

Grosso modo podemos distinguir dos grandes tipos de despliegue.

- **Despliegue Aleatorio**. Este tipo de despliegue se usa cuando la zona es inaccesible o planea dificultades que hacen más conveniente esta modalidad (p.ej., aplicaciones militares, parajes inaccesibles). La precisión alcanzada a la hora de cubrir un área puede ser deficitaria y por eso se tiende al uso de nodos redundantes. No hablamos de un patrón de localizaciones sino de una distribución uniforme, gaussiana, etc.
- **Despliegue Determinista**. A diferencia del caso anterior el área de despliegue sí es accesible y, por tanto, tenemos control (total o parcial) sobre las ubicaciones posibles [Tilak 2002, Xu 2006, Chiu 2004, Chen 2005]. Una vez decidida la localización se sabe el lugar exacto en que están los nodos. Si entran nuevos nodos que se sitúan sin un conocimiento exacto de su localización, entonces, se deben usar técnicas de localización. Podemos hablar de despliegues regulares en los que se sigue una geometría determinada e irregular en los que el sistema impone restricciones para la regularidad, necesidad de alta probabilidad de detección de accesos, etc.

## • Métodos de Localización

A la hora de diseñar un despliegue, la localización hace referencia a determinar con la mayor precisión posible la posición de un nodo fijo (p.ej., que acaba de entrar nuevo en la red) del que desconocemos la misma.

Los métodos más destacados para estimar la localización podemos distinguirlos en una de las siguientes categorías.

◆ Dependientes de una medida de distancia. En esta categoría podemos distinguir dos tipos de nodos. En primer lugar, los de tipo ancla cuya posición es conocida con precisión. Y en segundo lugar, los nodos desconocidos. La posición de los ancla se puede saber mediante GPS, referencias cartesianas conocidas, etc. En esencia, los algoritmos de ese tipo



Figura 2.5.1. Ejemplo de localización basada en medidas de distancia.

funcionan de la siguiente manera. Un nodo desconocido recibe un paquete de un ancla para saber si le tiene en su radio o anillo de acción. En caso de ser así la mayoría de algoritmos usan niveles de potencia (p.ej., mediante valores de RSSI) o diferencias de tiempo entre ondas acústicas y de RF. Dentro de esta categoría la versión más popular es la trilateralización [Savvides 2001] y otros que estudiaremos en el capítulo 4. Con este tipo de algoritmo se utilizan varios nodos de los que la posición es conocida con exactitud y mediante medidas de distancia respecto de los nodos conocidos al nodo a localizar se plantea un sistema de ecuaciones que da como resultado la localización buscada. En la Figura 2.5.1 podemos ver un ejemplo donde se aprecian varios nodos ancla (en negrita) y desconocidos (en blanco) con sus anillos de acción.

- Contaje de saltos. Este método se usa en redes donde la densidad de nodos es baja y no es posible buena precisión en las estimaciones de localización. En el algoritmo DV-HOP [Niculescu 2003] se usa una técnica basada en enrutamientos vectores de distancia en el que se hace una cuenta del número de saltos desde el nodo desconocido al ancla. Cada nodo mantiene una tabla de posiciones 2D o 3D según el caso y sólo hace intercambios de actualizaciones con los nodos vecinos. Un nodo ancla, después de acumular distancias a otros anclas, hará una estimación de la distancia promedio entre nodos visibles entre sí a un solo salto.
- Patrones estadísticos. En estos algoritmos es necesario hacer una campaña de medidas, por ejemplo, de niveles de RSSI, que se guardan en una base de datos. Se genera así lo que podemos denominar una firma radioeléctrica de referencia para la zona de despliegue. Cuando llega un nivel de RSSI de un nodo desconocido se compara estadísticamente con los noveles de referencia buscando el de mayor verosimilitud. Determinada la posición a la que se hizo esa medida se sabe la localización del nodo desconocido.



Figura 2.5.2. Ejemplo de seguimiento con agentes móviles.

### • Métodos de Seguimiento

Retomamos ahora el sentido principal que tiene a lo largo de esta tesis el concepto de localización, esto es, determinar dónde está un nodo desconocido y hacerle un seguimiento atendiendo a que se desplaza por la zona de cobertura de la red. Dado que en el capítulo 4 estudiamos en detalle el método de seguimiento basado en el filtrado de Kalman, dedicamos esta sección a una visión general de otros métodos de interés.

- Seguimiento mediante agentes móviles. En esta modalidad se produce una cooperación entre nodos sensores [Tseng 2003]. Dentro del radio de acción de cada nodo fijo de la red este puede detectar la existencia de un objeto móvil y estimar la distancia a él. Una vez que un objeto es detectado en la red se inicia un agente móvil con el objeto de seguir el camino recorrido por el móvil. Un agente de este tipo es móvil en la red pues está programado para elegir el nodo fijo más cercano al objeto móvil. En una filosofía así se usan normalmente tres agentes que hacen un seguimiento permanente del móvil. En la Figura 2.5.2 podemos ver un ejemplo de seguimiento con agentes.
- Seguimiento basado en detección binaria cooperativa. En esta modalidad se produce una cooperación entre nodos sensores [Mechitov 2003] pero sólo a nivel de saber si el objeto móvil está presente o no. Mediante la combinación de datos en nodos fijos vecinos se puede superar la capacidad de posicionamiento y seguimiento mayor que si sólo se usa un sensor.
- Seguimiento predictivo distribuido. En este tipo de seguimiento se hace una aproximación basada en clusters [Yang 2003]. Se distinguen tres tipos de sensores: sensores en los bordes, los situados dentro de un margen de distancia a los bordes y sensores que no están en los bordes. Los sensores de los bordes están permanentemente funcionando y tiene como

misión principal detectar la entrada de un objeto móvil. Mientras no haya detección los sensores interiores están hibernando pero cuando se hace una detección comienza una serie de tareas de tipo medir-predecir-comunicarmedir. Esto se hace forma distribuida por parte de los sensores fijos ubicados a lo largo de la trayectoria del móvil.

# 2.5.2 Topología de la Red

Podemos considerar la topología como el arte de organizar el conocimiento en red. Esta topología se establece mediante el protocolo de construcción de la topología o en base a la especialización de los nodos. Esta información se usa mediante los procesos de enrutamiento entendiendo por tal la técnica para seleccionar los nodos implicados en la comunicación entre una fuente y un destino.

Varias son las principales diferencias que encontramos en WSN al compararla con otras redes, como por ejemplo las clásicas redes de cable rígido. Primeramente, el hecho de que la comunicación use un canal inalámbrico naturalmente crea una red plana en la que cada nodo puede acceder directamente a todos los nodos en su radio de comunicación. Segundo, normalmente se forman redes densas las cuáles pueden crear amplias posibilidades de conectividad. Por esa razón, las comunicaciones inalámbricas conducen a problemas de capacidad de canal al contrario que con las redes cableadas donde la capacidad del canal puede virtualmente ser tan alta como sea posible.

Esto nos conduce a una segunda cuestión que está relacionada con el despliegue visto en el apartado 2.5.1. La densidad de los nodos puede ser alta y cada nodo podría, en principio, comunicar directamente con cualquier otro nodo. Aunque esta alta densidad puede ser vista como una desventaja, debido a la redundancia de posibles enlaces que podrían aumentar la fiabilidad, esto no es una solución viable cuando la estrategia MAC es muy difícil de diseñar en un contexto de redes muy densas.

El control de topología debe proporcionar respuestas a aquellas cuestiones y puede definirse como la restricción de vecinos para incrementar las prestaciones, ahorro de energía y mejora de la fiabilidad. Esto puede lograrse usando diferentes clases de técnicas. La selección puede implementarse con el uso de diferenciaciones hardware software. Las diferenciaciones software 0 generalmente se hacen en redes físicamente homogéneas. En este caso la situación es más dinámica y esto ayuda a la red a ser reactiva a los cambios, como averías, inserción de nodos o movimiento de nodos. Cuando se emplea diferenciación hardware, pueden usarse múltiples canales para comunicación, dependiendo de la clase del nodo.

Examinaremos a continuación algunas topologías de redes inalámbricas bien conocidas y avaluaremos algunas de sus prestaciones. Para simplificar el análisis, únicamente consideraremos la red como la subred asociada a un único *gateway*, que actúa como interfaz entre la subred y otra red como Internet.

Es importante tener en cuenta que si en un entorno cableado la topología es una idea más próxima al hardware por lo que puede describirse mediante la presencia de enlaces cableados, en el caso de la topología inalámbrica es más difícil de captar puesto que es una noción más virtual y, por tanto, puede entenderse de distintas y variadas maneras. Frecuentemente se le considera como un conjunto de nodos accesibles para comunicación. Este grupo usualmente se limita a una selección de nodos vecinos. Esta selección se hace por múltiples propósitos, como por ejemplo:

- Para limitar la memoria de almacenamiento
- Para usar solamente la distancia más corta de comunicación, mediante la fijación de la potencia de transmisión al mínimo, etc.

## • Los K vecinos más próximos

La selección de vecinos ayuda a optimizar el control de la topología y simplifica los algoritmos de actualización de la información sobre el "vecindario". Una primera estrategia puede ser reducir el radio de comunicación para mantener contacto únicamente con los k vecinos más próximos o simplemente ignorar a los otros nodos. Por ejemplo, en [Salhieh 2005] se expone la evaluación de una topología considerando que el conocimiento sobre los vecinos está compuesto de los k vecinos más próximos de un nodo. k representa el factor el factor de conectividad. En esta estrategia se cambia analíticamente el número de vecinos para cada nodo con el enfoque puesto en el número de procedimientos de transmisión y recepción requeridos para la ejecución de una aplicación, tratando de encontrar el mejor factor de conectividad para la carga de una aplicación dada.

La misma clase de estrategia se usa en [Hou 1986] donde los autores buscan definir un radio óptimo de comunicación para comunicaciones entre dos nodos. Este planteamiento es de alguna manera equivalente a los métodos de los k vecinos porque hay un radio que permite considerar k vecinos. El artículo considera una MAC basada en Aloha y tres estrategias de enrutamiento para calcular un radio adecuado. Estas estrategias de enrutamiento se denominan: Most Forward with Fixed Radius, (MFR), Nearest with Forward Progress, NFP, Most Forward with Variable Radius (MVR).

Aunque este planteamiento es interesante, puede ser difícil extrapolarlo al mundo real de las redes inalámbricas, debido a que el artículo está escrito bajo el supuesto de que la comunicación, interferencia y conocimiento del radio del vecino fueran idénticos lo que no es así en todos los casos. Por tanto, esta visión es en parte restrictiva, debido al hecho de que la selección del vecino no debe ser restringida a los vecinos más próximos, sino que por el contrario propone una diversidad de nodos en el área de comunicación. Una mejor solución podría ser mantener una combinación de vecinos próximos por un lado y los más distantes por otro. Por ejemplo, este es el caso del método de enrutamiento Descubriendo el Camino Asistido por Amigos (Friend Assisted Path Discovery, FAPD) [Blazevic 2002].

Veamos ahora de forma más gráfica varias clases de topología.

## • Topología de Malla

En esta topología, que podemos ver en la Figura 2.5.3, cada nodo es autónomo y está conectado a alguno o a todos los nodos restantes de modo que la información



Figura 2.5.3. Ejemplo de topología Plana o en Malla.



Figura 2.5.4. Ejemplo de Organización Jerárquica o en Árbol.

local puede difundirse entre dos nodos conectados cualesquiera. Se le puede llamar "Plana", porque ningún nodo posee un papel particular en esta organización. Cada nodo tiene la habilidad de lanzar paquetes en la red.

Esto aparece simbólicamente en la Figura 2.5.3, donde cada nodo aparece en rojo, simbolizando las capacidades de enrutamiento. Los enlaces se representan mediante segmentos sólidos. La red está completamente conectada siendo una de las arquitecturas usadas extensivamente en la práctica. Sin embargo, esta arquitectura comporta una pesada carga debido al número interconexiones de comunicación necesarias en una red con N nodos.

## • Topología Jerárquica

En una organización jerárquica los nodos están situados a varios niveles y cada nodo puede comunicar sólo con sus respectivos 'padres' e 'hijos'. En cada nivel los nodos reciben información de los que tienen debajo, procesan la información de acuerdo a su posición en la jerarquía y transfiere información al nivel superior. El nodo que está en el nivel superior (nodo raíz) de la jerarquía toma las decisiones más adecuadas a partir de la información recibida y podría ordenar a sus subordinados que tomen acciones según sea necesario. En la Figura 2.5.4 tenemos un ejemplo de este tipo de topología.

## • Topología Backbone

Es una topología de tipo jerárquico en la que se consideran dos tipos de nodo. El primer tipo de nodos forma una red base o cadena principal (backbone, también



Figura 2.5.5. Ejemplo de Organización Jerárquica en Columna Vertebral.



Figura 2.5.6. Topología Grupos Jerarquizados.

columna vertebral) con nodos que se encargan de realizar tareas de procesado intranodo y tareas de tráfico.

El segundo tipo de nodos incluye cualquier otro nodo. Como ejemplo particular podemos destacar la topología en estrella en la que hay un solo nodo en la cadena principal de tal forma que todos los nodos comunican con el mismo, el máster. En la Figura 2.5.5 podemos ver una red de tipo 'backbone'. Una topología en estrella es la usada para esta tesis por su simplicidad.

## • Grupos Jerarquizados

En esta topología, también llamada 'clustered hierarchical', la estructura es tal que aquí los nodos están organizados en base a muchos árboles binarios con unos

nodos raíz totalmente conectados. El la Figura 2.5.6 podemos ver un ejemplo de esta topología.

## • En Grupos o Cluster

En esta topología los nodos están organizados geográficamente en grupos o cluster. La idea principal es que un grupo determinado de nodos tiene asignado



Figura 2.5.7. Topología de Grupos o Cluster.

un papel especial. Cada grupo está controlado por un nodo concreto denominado 'clusterhead' que tiene la misión de controlar el uso de recursos locales, hacer que las tablas de enrutamiento sean estables, hacer los protocolos más escalables, etc. Dentro de cada grupo la comunicación entre los nodos y el clusterhead está muy simplificada. En la Figura 2.5.7 podemos ver un ejemplo.

# CAPÍTULO 3

Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cachalotes

El procesado de las señales acústicas obtenidas mediante agrupaciones concentradas de sensores, ha sido y es objeto de estudio y análisis dado su interés en múltiples aplicaciones [Krim 1995, Krim 1996, Brandstein 2001, Van Trees 2002, Papadias 2006 y AMI 2007]. Con frecuencia, a la hora de abordar un tipo de aplicación surge la necesidad de dar solución a problemas científicos para alcanzar un funcionamiento adecuado. Es el caso de esta tesis pues varias de sus líneas de investigación se enmarcan dentro de un campo de interés biológico, medioambiental ecológico. Específicamente, nos concentraremos v en particularizar el procesado de las señales de una agrupación de sensores inmersa en el medio marino aplicado a un tipo concreto de cetáceos, estos son, los Cachalotes. Con esta idea en mente, nos planteamos objetivos relativos a localización, seguimiento e identificación de individuos de esta especie y en la

consecución de los mismos hacemos aportaciones científicas generalizables. Establecemos así un camino de ida y vuelta entre investigación básica dentro del procesado de agrupaciones concentradas e investigación aplicada al caso específico de cetáceos.

La disponibilidad del medio marino, en lo relativo a su accesibilidad para la realización de experimentos y pruebas, no cabe duda de que es ante todo muy costoso. Además, si el fin en sí mismo no reporta un beneficio económico tangible, todavía se hace más complicado. Otro aspecto que es importante reseñar es que el tema puede despertar el interés de un amplio sector de la comunicad científica (ingenieros, físicos, biólogos, zoólogos, etc.), por lo que también es en sí misma una ardua tarea la de conjugar esfuerzos e intereses para hacerlo "rentable" desde algún punto de vista. Por lo tanto, el diseño e implementación de alguna herramienta de simulación, en aquel ámbito en que la tecnología disponible lo haga factible, puede ser de gran avuda. Así lo hemos entendido en los orígenes de esta tesis al desarrollar nuestra propia herramienta de simulación. Una herramienta de este tipo debe aplicar el conocimiento general que sobre la materia se tiene, más el adquirido o particular de la aplicación a la que se destine la investigación que la demanda. De ahí que nuestro segundo apartado y contribución será justamente el diseño e implementación de un simulador del entorno marino. Este simulador se aplicará al estudio y análisis del procesado de señales acústicas captadas mediante agrupaciones de sensores inmersas en el medio marino, en el se integrarán todos aquellos fenómenos de propagación, característicos del medio, que afecten a las señales procedentes de las fuentes acústicas submarinas de interés. Siguiendo con esta misma idea, hemos desarrollado también una base de datos o corpus sonoro consistente en grabaciones tomadas in-situ a bordo de barcos. Esta base de datos está procesada para obtener información sobre condiciones de grabación, tipos de señales, individuos, etc.

El siguiente aspecto que abordamos en este capítulo es el relativo a la detección y localización de fuentes mediante técnicas DOA, es decir, en base a un conjunto finito de muestras de las señales captadas determinar la dirección donde se localizan la fuente o fuentes emisoras de esas señales. Esto lo tendremos que realizar con unos medios limitados; pequeño número de sensores y un número limitado de muestras. Además, hemos de contemplar que las señales de nuestro interés son de banda ancha. A este aspecto dedicamos el tercer apartado.

Cuando las fuentes de interés son susceptibles de desplazarse resulta de fundamental la posibilidad de efectuar su seguimiento. Más aún si cabe, cuando las fuentes son animales cuyo comportamiento se quiere analizar. Por lo tanto, entendemos que en este contexto la posibilidad de hacer un seguimiento es imprescindible, así que en el cuarto apartado abordamos el problema del seguimiento de fuentes a partir de la determinación de sus DOAs.

Siguiendo con el mismo contexto del párrafo anterior, hemos de entender que en general podemos encontrar manadas y que sería deseable poder estudiar el comportamiento de un individuo. Para poder hacerlo es necesaria una tarea de previa de identificación que permita incorporar la identidad de uno o varios individuos en los algoritmos de DOA. Así, en el quinto apartado se dedica al proceso de identificación de individuos de tal forma que se podrá incorporar a la localización. Una vez abordados cada uno de los problemas exponemos un algoritmo que aúna localización, identificación y seguimiento de fuentes específicas.

Dedicamos un apartado, el sexto, a la presentación de los experimentos y resultados que apoyan los desarrollos teóricos de los aparatados anteriores.

Por último, exponemos particularmente todas y cada una de las contribuciones, que en el ámbito del procesado de las agrupaciones concentradas de sensores se han realizado en esta tesis.

# 3.1 Aplicaciones Acústicas para el Estudio de los Cetáceos

Entre los mamíferos marinos el grupo de los cetáceos, además de numeroso, está ampliamente distribuido por todos los mares [Reid 2003, Jefferson 2006, Wikimedia 2009]. El hábitat de estos mamíferos va desde ríos y zonas costeras hasta mar abierto. Los hay que viven permanentemente en mar abierto, siempre lejos de las zonas costeras. Otros que viven más próximos a la costa y están aquellos que normalmente viven lejos de la costa pero se acercan a estas en determinadas épocas del año. También concurren en la mayoría de ellos la característica de emitir sonidos, con distintas aplicaciones: comunicación, ecolocalización e identificación entre ellos, principalmente. Esta particularidad ha propiciado el uso de medios técnicos acústicos para captar estos sonidos con diferentes fines. Así, podemos encontrar aplicaciones que van desde simplemente escuchar los sonidos que emiten con el objeto de catalogarlos, censarlos e interpretarlos, como p.ej. en [Thomas 1986B, Gordon 1991, Leaper 1992], hasta la realización de su detección, localización y seguimiento mediante métodos pasivos, p.ej. en [Thomas 1986a, Nosal 2007]. En estas primeras referencias encontramos sistemas sonar pasivos adaptados y dotados de agrupaciones de hidrófonos, con un procesado básico de la señal, más orientado a su análisis que a otros aspectos. Las metodologías y algoritmos aplicados realizan las tareas de localización, identificación y seguimiento por separado, y normalmente no en tiempo "real", o al menos no emplean herramientas que en un tiempo prudencial sean capaces de dar un resultado conjunto e in situ, p.ej. al problema de la localización y seguimiento individualizado basado en sistemas pasivos.

Para el estudio de muchos de los cetáceos los sistemas acústicos son un complemento a las técnicas de observación. Sin embargo, el caso de los cachalotes es especial, ya que permanecen sumergidos a grandes profundidades, más de 500 m, durante largos periodos de tiempo. Por lo que el tiempo que pasan en la superficie y a la vista es más bien breve. Luego, este cetáceo presenta una serie de características que hacen poco factible su estudio únicamente mediante la observación visual. Por todo ello, las metodologías que usan técnicas acústicas resultan de las más adecuadas cuando están sumergidos.

Ahondando más en sus características, encontramos diversas publicaciones donde reportan inmersiones de 40 minutos o más, alternadas con descansos en la superficie de 8 a 10 minutos [André 2000, Wahlberg 2002]. Desde el punto de
vista puramente acústico se les pueden considerar unos parlanchines, ya que cuando están bajo el agua emiten sonidos de manera casi continua, incluso cuando están en la superficie lo hacen aunque con mucha menor frecuencia. Para estos animales están catalogados diversos tipos de sonidos, siendo el denominado clic el sonido más usual de un cachalote durante la búsqueda de alimento a grandes profundidades. El clic es un sonido cuyas propiedades se adaptan a la ecolocalización a grandes distancias, gran amplitud, carácter impulsivo y corta duración. Cuando se encuentran muy próximos a su presa emiten los que se conocen como creaks, clics repetidos a intervalos mucho más cortos. Para comunicarse, emiten las denominadas *codas*, un patrón repetitivo de clics, y los clangs o gunshots escuchados, estos últimos, exclusivamente a los machos. Una base de datos con los distintos tipos de sonidos de cachalotes, acompañada de un análisis en frecuencia de los mismos se puede encontrar en [Hernández 2002]. Como ejemplo de la frecuencia con que emiten sonidos, en [Wahlberg 2002] informan de inmersiones de 36 minutos de duración con la emisión de un total de 2634 *clics*, lo que supone más de un *clic* por segundo.

En el estudio de la vida y costumbres de los cachalotes (p.ej., inmersiones, conducta acústica) se han usado distintos enfoques: observación visual con cámaras de foto y de video, registradores de profundidad e hidrófonos adosados a lomos de los cachalotes, observaciones mediante sonar activo y pasivo, y registros acústicos. Sin embargo, únicamente las técnicas de localización y seguimiento acústicas basadas en la escucha pasiva, tienen la ventaja de permitir el estudio simultáneo de la conducta en inmersión y el comportamiento acústico [Wahlberg 2002], sin que pueda considerarse a esta como una técnica invasiva que condicione la conducta de los individuos. Los cachalotes, al emitir sonidos de alta intensidad con mayor énfasis en frecuencias del rango audible durante la mayor parte del tiempo de inmersión, son unos buenos candidatos para utilizar con ellos localización acústica. También son varios los autores que desde 1985 empezaron a utilizar técnicas acústicas para censar poblaciones de cachalotes, p.ej. [André 1997], ya que de entre todas las especies de cetáceos es la que mejor se adapta a estas técnicas y la menos indicada para un censo visual, aunque no existen en este sentido referencias a cómo se identifica acústicamente a cada individuo.

Respecto a los cetáceos y su hábitat natural, existen múltiples preocupaciones desde el punto de vista de la conservación. Es el caso, por ejemplo, de las especies que habitan en aguas próximas a Canarias. Por ejemplo, es conocida la relación existente entre maniobras militares navales y algunos varamientos masivos de cetáceos. Uno de ellos ocurrido en aguas de Fuerteventura (Islas Canarias) en septiembre de 2002 coincidiendo con unas maniobras militares navales. Otros efectos sobre el hábitat de estos mamíferos se debe al incremento del tráfico marítimo, sobre todo de los denominados "Fast-Ferrys" [Stephanis 2000]. Estos buques alcanzan altas velocidades, lo que disminuye dramáticamente los tiempos de maniobra tanto para los cetáceos como para los propios buques a la hora de evitar colisiones. A consecuencia de estas los cetáceos resultan seriamente dañados, cuando no muertos o gravemente heridos. En este sentido han surgido a lo largo del tiempo diferentes iniciativas conducentes a la eliminación si cabe de este problema. Así podemos hablar del "CIBRA Digital Signal Processing Passive Acoustic Monitoring Workstation [Pavan 2004], se trata de un sistema para detección y escucha de señales acústicas de banda ancha de mamíferos marinos. Los orígenes de este sistema se remontan a 1999 durante la realización del proyecto SOLMAR (Sound, Oceanography and Living Marine Resources). Sistema que fue amplia y extensivamente probado durante el desarrollo del proyecto europeo de investigación y desarrollo SIRENA (Service Infrastructure for Real time Embedded Applications) desde 2003 a 2005. El sistema fue desarrollado con un enfoque multisensorial, incorporando desde la escucha en distintas bandas de frecuencias y profundidades, información GIS, datos oceanográficos y de navegación, observaciones visuales, etc.

El sistema IMAPS (Integrated Marine Mammal Monitoring and Protection System), [Gentry 2003, Lucifredi 2005, Lucifredi 2006] se presenta con el objetivo de establecer una solución global para el problema de la protección de los cetáceos. Su premisa de partida es que las distintas tecnologías empleadas en esta tarea son individualmente inadecuadas. De modo que el sistema propuesto se presente con una arquitectura capaz de integrar: radar, sonar activo, sonar pasivo y sistema visual, todos ellos bajo un mismo control y colaborando con un objetivo concreto, la detección y clasificación de mamíferos marinos.

En este mismo ámbito existe otra propuesta denominada Whale Anti-Collision System (WACS) [André 2004, Delory 2007]. En este caso se trata de un sistema sonar pasivo a desplegarse a lo largo de las rutas marítimas de interés. Los objetivos básicos son dos proporcionar seguridad a la navegación y la conservación de las especies en peligro. Este sistema integraría agrupaciones de pasivas con capacidad para localización tridimensional y estaría en una boya. La idea es desplegar estas boyas a lo largo de la ruta considerada, además las boyas estarán comunicadas entre sí y con los barcos que atraviesen la ruta mediante un sistema de información que llevarían a bordo, a través del que serían avisados de la presencia de cetáceos en la ruta. El sistema podría complementarse sistemas sonar activos para la localización de aquellos cetáceos más silenciosos o que sus señales acústicas (ultrasónicas) sean más difíciles de detectar desde sistemas pasivos.

# 3.2 Entorno de Simulación de Propagación Acústica Submarina

El diseño de nuestro entorno de simulación surge con el objetivo de disponer de señales en cualquier agrupación de sensores que consideremos, para poder así usarlas en nuestra investigación. Particularmente, simulamos un escenario submarino de propagación acústica, donde la o las fuentes emisoras excitan el medio provocando la aparición de distintos modos de propagación hacia un lugar de recepción determinado. Las fuentes de interés son mamíferos marinos, Cachalotes exactamente, aunque es fácilmente extensible a otros mamíferos e incluso a otro tipo de fuentes. Los receptores serán hidrófonos.

Conforme estudiamos las características de propagación del medio, apartado 2.1, observamos la necesidad de introducir múltiples parámetros para caracterizarlo: perfil de velocidad, refracción y efecto en la curvatura de rayos, ruido, etc. Además, proporcionamos las posiciones de fuente y receptor, sus características,



Figura 3.2.1. Diagrama de bloques del Sistema de Propagación Submarina Cetus3D.

técnica de procesado, procesos a aplicar, etc. El resultado final es un sistema software que integra tres componentes fundamentales: una interfaz de usuario, un Sistema de Propagación Acústica Submarina en espacio tridimensional y un Sistema de Procesado. Al primero lo podemos considerar autónomo. Sin embargo, el Sistema de Procesado no puede trabajar sin los datos proporcionados por el Sistema de Propagación Acústica Submarina

## • Sistema de Propagación Acústica Submarina

Es la parte encargada de la realización de todos los cálculos y tareas concernientes al transporte de la energía acústica desde la fuente al receptor teniendo en cuenta los posibles modos de propagación que permiten alcanzar la posición del receptor.

Nuestro simulador en lo referente a la propagación acústica submarina se enmarca dentro de los que utilizan el método de los rayos (Ray Tracing) [Etter 1991, Jensen 2000], para establecer los distintos modos de propagación, pudiendo realizar trazados en línea recta o curva.

El diagrama de bloques del simulador en base a los requisitos generales que hemos citado de manera muy sucinta, se muestra en la Figura 3.2.1. El sistema al completo lo integran cuatro grandes bloques donde introducimos los parámetros de los diversos elementos que conforman el simulador. De ellos tres se integran en el Sistema de Propagación Acústica Submarina: *Parámetros del Medio, Parámetros de Fuente y Agrupación de Sensores*.



**Figura 3.2.2.** Formas de operación: Fuente Activa a Boya con Agrupación (a) y Fuente Activa a Fuente Pasiva y desde ahí a Boya con Agrupación (b).

A través de *Parámetros del Medio* cargamos el perfil de velocidad deseado y otros parámetros tales como estado del mar, tráfico marítimo e intensidad de lluvia, todos íntimamente relacionados con el ruido del escenario. A partir del perfil de velocidad es posible determinar la presencia o no de canales submarinos y obrar en consecuencia, también nos marcara la curvatura que sufren de los rayos.

Sin pérdida de generalidad, los datos del medio marino que utilizamos corresponden a una franja de océano de 10 Km de ancho y 71 Km de largo entre Santa Cruz de Tenerife y Agaete (Gran Canaria).

El siguiente bloque lo hemos denominado *Parámetros de Fuente*, desde aquí accedemos a la base de datos de clics de cachalotes para cargar la señal que

vamos a propagar por el escenario, también la localizamos dentro del escenario. Luego encontramos el bloque *Agrupación de Sensores*, elegimos el tipo de agrupación y la localizamos dentro del escenario. Hasta aquí hemos descrito brevemente los bloques que están íntimamente ligados con lo que puramente es el Sistema de Propagación Acústica Submarina. Con estos datos ya podemos lanzar simulaciones y obtener gráficos. Estos principalmente son los del escenario con las trayectorias de los rayos que llegan al receptor (agrupación de sensores), espectro de lo clics, perfil de velocidad en uso, disposición de la agrupación de sensores en uso y las señales recibidas en cada uno de los sensores que componen la agrupación.

En el simulador hemos situado la agrupación de sensores en una boya, que podemos situar en cualquier posición de nuestro escenario. Igualmente la fuente puede colocarse en cualquier lugar dentro del escenario. Se han implementado dos maneras de operar: *activo-boya*, Figura 3.2.2(a), esto es, se emite desde una fuente activa (cachalote) y los distintos modos de propagación se reciben en la boya con agrupación. La *activo-pasivo-boya* donde suponemos la presencia de un segundo cachalote, que no emite, pero que es susceptible de reflejar la energía emitida por el cachalote que actúa de fuente activa, Figura 3.2.2(b).

Los cachalotes como fuentes de sonido presentan una alta directividad. En la cabeza de estos animales se encuentra un órgano llamado Espermaceti, una de cuyas partes denominada *Junk* está íntimamente ligada al sistema de producción de sonidos en este cetáceo [Norris 1972, Møhl 2001, Møhl 2002]. En [Beedholm 2006] este órgano ha sido modelado como un radiador tipo pistón circular, de ahí que uno de los datos a proporcionar sea el diámetro de este órgano. Los sonidos que se incorporan para las fuentes son sonidos reales captados en el medio marino y convenientemente acondicionados e incorporados en una base de datos [Hernández 2002, Millán 2005].

A partir de la información contenida en cada uno de los tres bloques podemos construir modelos tridimensionales del sonido que emiten las fuentes submarinas. Es decir dispondremos de modelos que nos permitirán observar los principales fenómenos que afectan a la propagación del sonido, trayectorias, atenuaciones, retardos, etc.

## • Sistema de Procesado

Consta de dos módulos: Modulo de Localización y Seguimiento y Modulo de Identificación. Además, incorpora un módulo de detección de presencia de señal previo que en principio no directamente accesible. Podríamos decir que es la parte "flexible" del simulador, ya que aunque estos módulos incorporan unos métodos determinados es relativamente fácil incorporar nuevos métodos desarrollados o en desarrollo, o simplemente en estudio.

El Modulo de Localización y Seguimiento incorpora los métodos DOA que nos permiten; a partir de las señales proporcionadas desde el Sistema de Propagación de Acústica Submarina determinar la dirección desde donde emite la fuente. Si la fuente estuviera en movimiento también sería posible estimar la trayectoria seguida. En el simulador ya existen una serie de métodos incorporados, pero como ya hemos dicho es posible ampliar e incorporar otros. Para ello todos los métodos han sido programados siguiendo un patrón de datos de entrada y salida común, sólo la metodología del proceso de esos datos para proporcionar una salida, será distinta.

El Modulo de Identificación está orientado a determinar a qué animal de los incorporados en la base de datos pertenece el sonido recogido en la agrupación. El método de identificación empleado se basa en los modelos ARMA o AR de la fuente, clics emitidos por los cachalotes, y también en los resultados de la localización de la dirección de llegada. A este modulo se pueden incorporar otros métodos o variantes de los existentes.

# 3.3 El Problema de la Estimación de la Dirección de Llegada

El planteamiento central consiste en estimar las direcciones de llegada (DOA) a partir de un conjunto finito de datos. Estos son recogidos mediante una agrupación de sensores a donde llegan las emisiones de fuentes de señal situadas en campo lejano. Al conjunto de datos se le suele denominar "snapshot", término que específica la finitud del número de muestras posibles y procesables. La localización de fuentes y estimación DOA usando agrupaciones de sensores ha recibido muchas aportaciones por parte de los investigadores relacionados con el campo del ASP. En este apartado exponemos una visión de conjunto con los principales métodos existentes.

Existen dos grandes grupos de métodos, paramétricos y no-paramétricos [Krim 1996]. Entre los métodos paramétricos y los no paramétricos existen una serie de diferencias fundamentales. Entendemos por no-paramétricos aquellos basados en alguna forma de estimación espectral sin presuponer un modelo sobre producción, formas de onda, datos estadísticos, etc. de la fuente que genera la señal. Los métodos no paramétricos están basados normalmente en técnicas espectrales y son computacionalmente atractivos aunque no siempre proporcionan la suficiente precisión. Particularmente, en escenarios con señales altamente correladas es donde las prestaciones de estos métodos podrían ser insuficientes. Un ejemplo de método no-paramétrico sería un conformador de haz con el que vamos enfocando en distintas direcciones y en cada una de ellas vamos estimando la densidad de potencia, allí donde esta fuera máxima se entiende que está situada la o las fuentes y por tanto esa será la o las DOAs. El conformador de haz convencional es una extensión natural del análisis espectral de Fourier. Por ejemplo, el Periodograma es un estimador espectral que puede adaptarse para la estimación del espectro espacial dando lugar así al Periodograma Espacial [Van Veen 1988, Haykin 1991], aunque los métodos más relevantes se encuentran bajo el abanico de los denominados Mínima Varianza (MV) originalmente debidos a [Capon 1969] y al que dedicaremos un apartado. Otro enfoque puede ser el que ha llevado al método MUSIC [Su 1983] que está basado en la descomposición de la matriz de covarianzas de las muestras. Estos métodos pueden clasificarse dentro de los Conformadores de Haz (beamforming) y las técnicas basadas en Subespacio de Señal, y se les suele calificar como métodos de exploración.

A diferencia de los métodos no-paramétricos en los paramétricos las señales coherentes no imponen dificultades, al menos desde un punto de vista teórico. El precio a pagar por el incremento de la eficiencia y robustez es que los algoritmos requieren una búsqueda multidimensional para hallar las estimaciones, lo que conlleva mayor complejidad a la vez que mayor carga computacional. En los métodos paramétricos se explota al máximo el modelo de datos subyacente. De entre ellos el enfoque conocido como máxima verosimilitud, ML [Krim 1996], es uno de los que mejor se conoce y con mayor frecuencia se usa en ASP. Esta metodología requiere un planteamiento estadístico para el proceso de generación de datos, ya que se plantea la estimación de los parámetros que maximizan la probabilidad de los datos muestreados u observados. Existen para esta metodología dos supuestos diferentes, ambos referidos al emisor de señales, dando lugar a dos tipos de aproximación. Los métodos ML citados son DML (Deterministic ML) y SML (Stochastic ML) [Tsakalides 1995]. En DML a priori no se hacen supuestos estadísticos sobre la fuente de señal, se la trata como desconocida pero de naturaleza determinista. Generalmente el resultado es una estimación conjunta de las señales y las localizaciones de sus fuentes. En SML se modela a las señales como procesos aleatorios gaussianos, aunque es importante reseñar que es aplicable incluso si los datos no son gaussianos.

Otro enfoque más a la hora de distinguir los métodos de estimación de DOA es el siguiente. En lo relativo al proceso de generación de la señal este puede ser determinista o estocástico. En el primer caso, las formas de onda pueden ser deterministas desde el punto de vista del emisor si bien al llegar el receptor estarán afectadas por el ruido de fondo y el presente en los sensores. Esto les conferirá un carácter aleatorio desde el punto de vista del receptor. En el segundo caso el proceso de generación de la señal emitida es aleatorio en sí mismo. Existe, no obstante, un punto intermedio representado por un tipo de fuentes que genera la señal mediante un proceso determinista si bien emisores diferentes dan lugar a señales diferentes. Es el caso de fuentes naturales, p.ej., voz humana, sonidos de cetáceos. Dicho determinismo vendría representado por un modelo de producción (p.ej., AR, MA, ARMA) cuyo conocimiento enriquecerá el proceso de estimación que se lleve a cabo, p.ej. [Ziskind 1990, Ziskind 1992, Zhou 1992, Hernández 2002, Navarro-Mesa 2004 y Amiri 2007]. En esta tesis exploraremos esta idea de forma específica.

Antes de continuar hemos de plantear otra visión a la hora enfocar la estimación de DOA. Los métodos mencionados en los párrafos anteriores han sido diseñados para la estimación DOA de fuentes de banda estrecha. El interés por la localización de fuentes de banda ancha puede verse como una extensión natural pues muchas de las fuentes de señal lo son, p.ej. localización de voces mediante agrupaciones de micrófonos [Brandstein 2001]. Los algoritmos desarrollados para banda ancha pueden clasificarse en dos clases. Una primera clase la constituyen aquellos que conllevan dos etapas. Primero, estimación de la diferencia de tiempos de llegada, TDOA, entre los sensores. Y segundo se aplica un algoritmo de mínimos cuadrados, LS. La segunda clase usa el método de estimación paramétrica ML. Mientras que los de la segunda clase son capaces de estimar DOAs de varias fuentes, los de la primera, normalmente, no pueden hacerlo para Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



Figura 3.3.1. Esquema de un algoritmo de detección por umbrales.

más de una fuente.

# 3.3.1. Detección de Clics de Cachalotes

Las señales acústicas emitidas por los cachalotes no son continuas en el tiempo. Estas son de naturaleza transitoria y en general de corta duración [Møhl 2003]. El buen funcionamiento de cualquier método de estimación DOA, empieza por tratar de proporcionar datos de buena calidad, de ahí que la detección de clics sea un elemento previo indispensable.

El problema de detección principio-fin es muy común en aplicaciones de voz, p.ej., codificación, reconocimiento [Rabiner 1975, Lamel 1981, O'Shaughnessy 1987]. Así ha dado lugar a trabajos específicos [Navarro-Mesa 1997 y 1999].

Nuestro objetivo se centra en algoritmos de detección capaces de situar con fiabilidad los instantes de comienzo y final de clics.

Los algoritmos de detección principio-fin deben ser fiables, esto es, con bajas inserciones (falsa alarmas) u omisiones (pérdidas). También, deben ser lo más exactos posible situando las marcas de principio y de fin.

El algoritmo debe ser adaptativo para poder trabajar bien en ambientes cambiantes, especialmente cuando el ruido de fondo lo es. Los algoritmos que actúan bajo condiciones difíciles normalmente son complejos. La simplicidad es otra característica deseada, especialmente cuando está pensado para formar parte de un sistema complejo.

Uno de los mayores problemas con que se puede encontrar un algoritmo de detección es una hipotética dependencia respecto de datos de entrenamiento. A pesar de que un ajuste de los parámetros en una fase de entrenamiento es aceptable, no podemos asumir, ni siguiera de forma implícita, que unos datos de entrenamiento están siempre disponibles. Es común asumir que los primeros cientos de milisegundos de señal son silencio o ruido de fondo, p.ej., el algoritmo se basa en un cierto conocimiento a priori del ruido de fondo en el ambiente. En nuestro caso sabemos, del análisis de las señales, que dispondremos siempre de intervalos largos (varios centenares de milisegundos) en los que no hay señal.

En esta tesis adoptamos los algoritmos de detección basados en umbrales. Estos tienen una serie de bloques comunes (ver Figura 3.3.1): conversión analógicadigital, filtrado de la señal en la banda frecuencial de interés, segmentación en tramas (sin solapamiento), función de energía, función umbral y detección principio-fin. En nuestro caso hay que reseñar una particularidad, disponemos de varias entradas de señal. El algoritmo que nos proponemos utilizar se aplica a señales unidimensionales, luego una vez digitalizada y filtrada debemos elegir con cuál de las entradas vamos a realizar la detección. El método que facilite la elección debe ser sencillo a la par que efectivo. Una elección natural consiste en utilizar aquella entrada que presente máxima SNNR. Se trata de un método sencillo, existen multitud de algoritmos implementados para esta tarea. Se trata también de un método efectivo puesto que, cuanto mayor sea la SNNR mayor será la probabilidad de detección y menores las de falsa alarma y error.

Veamos ahora con más detalle cómo es el proceso de detección principio-fin.

## • Segmentación en Tramas

Para poder hacer un seguimiento de la evolución de la señal (p.ej., mediante la función de energía) necesitamos tomar la misma en intervalos cortos llamados tramas. La segmentación en tramas es un aspecto importante del algoritmo que debe tratarse con cuidado por dos motivos. Primero, los estimadores de las funciones de detección requieren de un número suficiente de muestras. Y segundo, para obtener unas buenas medidas, las tramas deben ser tales que se pueda considerar la señal estacionaria dentro de ellas, excepto cuando haya una señal de nuestro interés, p.ej. un clic. En esos instantes se produce un fuerte cambio de señal con incremento de su energía que aprovecharemos para hacer la detección. El tamaño final de las tramas estará fuertemente influido por unos resultados experimentales en los que buscamos satisfacer sobre todo la necesidad de obtener buena fiabilidad y pocas falsas alarmas.

## • Detección de Clics por Umbrales y Test de Detección

Pensemos en una situación sencilla de cara a la detección de principio-fin; señal de cachalote sobre un fondo de ruido estacionario de baja potencia comparada con la potencia de señal. Se podría argumentar a favor de un algoritmo de detección guiado por una idea como la siguiente: *"la manera en que uno debería atacar el problema a ojo debería ser adaptar la vista a la forma de onda típica del silencio y entonces localizar algún cambio significativo asociado a la presencia de la señal"*. La expresión práctica de ideas como estas conduce a la detección de señal por umbrales. Esta detección consiste en hacer un análisis por tramas de la señal observada. Sobre cada trama se aplicará una función de energía a las muestras de señal y por comparación de la función con un umbral se decide si hay señal o silencio. Si la función rebasa el umbral se activa la detección hasta que vuelve a

caer por debajo del mismo, instante en el que consideramos que ha vuelto el silencio.

El test de detección es como sigue: sea la señal submarina s(t) un proceso de media nula. Sea n(t) un ruido desconocido de media nula. Asumamos que los dos procesos s(t) y n(t) son estadísticamente independientes. La señal s(t) es observada en ruido aditivo n(t) como y(t)=s(t)+n(t) con tramas de duración T segundos. El objetivo del test es detectar la presencia de señal en las observaciones ruidosas. Esta detección se hará a partir de una función de energía calculada al efecto a la que se le piden valores altos cuando hay señal y bajos cuando hay silencio, con o sin ruido. De esta forma podremos comparar con un umbral y sacar hipótesis acerca de la presencia de señal.

Tenemos un problema de detección binaria clásica [Hippenstiel 2002]:

donde  $H_0$  denota la hipótesis nula y  $H_1$  denota la alternativa, presencia de clic.

## • Función de Detección Basada en la Energía

La función de detección por energía es una elección razonable cuando deseamos detectar la presencia de una señal sobre un fondo de ruido estacionario. El ruido se asume de media nula y varianza  $\sigma^2_{\rm T}$ . La señal también se asume de media nula y varianza  $\rho \cdot \sigma^2_{\rm T}$ , donde  $\rho$  es la relación señal a ruido. Sea una trama de la señal y(t) = s(t) + n(t) donde  $(t \in [0,T])$ . Si se observa y(t) en un instante 't' cualquiera, la estadística del test es

$$T_{E}(t) = \int_{\langle T \rangle} y^{2}(t) / \sigma_{T}^{2}$$
 (Ec.3.3.1)

Como podemos observar en Ec.3.3.1, se requiere el conocimiento de la varianza del ruido. En la práctica ésta se calcula tomando registros a partir de intervalos de silencio donde sólo hay ruido, y de éstos se obtiene una estimación de  $\sigma^2_{\rm T}$ .El test de detección consiste en rechazar  $\mathbf{H}_0$  si  $T\_E(t)$  es mayor que un umbral  $T_\alpha$ donde  $P(\chi^{2}N>T_\alpha/H_0) = \alpha$  es la probabilidad de falsa alarma y  $T_\alpha$  se puede determinar a partir de experimentos. La probabilidad de detección es la probabilidad de que  $T\_E(t)/(1+\rho)$  exceda  $T_\alpha$ . Atendiendo a estas dos situaciones se puede definir un algoritmo de detección con sólo hacer un seguimiento efectivo de los cambios de estado; silencio ( $\mathbf{H}_0$ ) y señal ( $\mathbf{H}_1$ ).

## • Determinación y Aplicación de los Umbrales

Sin duda, una estrategia en la que se compare la función de energía con un umbral fijo, puede ser adecuada en entornos donde el ruido es estacionario. Es más, tiene la virtud de utilizar un sólo umbral que una vez determinado queda fijo con lo cual todo resulta sencillo. Sin embargo, el supuesto de estacionariedad



Figura 3.3.2. Comportamiento de la función de energía y de los umbrales.

no es del todo realista. Se entiende así que los algoritmos prácticos deben expresar la idea de utilizar un umbral  $T_{\alpha}(t)$  cambiante con las condiciones del entorno, capaz de adaptarse a las nuevas condiciones que se le presenten.

Pensemos en la idea "la forma en que uno debería atacar el problema en un algoritmo automático....", citada previamente. Si aceptamos esto parece razonable aceptar también que el umbral  $T_{\alpha}(t)$  sea adaptativo y dependiente de los valores de la función de detección. Una función de umbral que ha dado buenos resultados, y que tomaremos para nuestro algoritmo, consiste en considerar simultáneamente media y desviación de la función de detección. O sea,  $T_{\alpha}(t)=Med(t)+Desv(t)$ , donde Med (media) y Desv (desviación) se definen como:

$$Med(t) = \frac{1}{T} \int_{\langle T \rangle} T_T(t) \qquad Desv(t) = \sqrt{\frac{1}{T} \int_{\langle T \rangle} \left[ T_T(t) - Med(t) \right]^2}$$

y T es la duración en segundos de la ventana para hacer los promedios. La elección de la longitud de la ventana de promedio T se debe hacer buscando una solución de compromiso entre precisión y fiabilidad.

Debemos hacer notar que nuestro algoritmo, aunque adaptativo y cambiante con el tiempo, trabaja con un único umbral. Otros algoritmos utilizan más (p.ej., dos o tres) de la misma forma que utilizan más características. No hemos optado por soluciones de este tipo pues, como veremos, los experimentos demuestran que se pueden obtener buenos resultados con un algoritmo tan sencillo como el nuestro.

## • Decisión Principio - Fin: posprocesado de la detección

Un buen método de adaptación de los umbrales no es suficiente para obtener buenos resultados. Por ejemplo, es común detectar segmentos demasiado cortos que no permitirán una buena estimación de DOA pues no conllevan un número significativo de muestras de señal. El objetivo principal que nos marcamos con el posprocesado es eliminar pulsos cortos de señal cuya duración permita sospechar que corresponden a ráfagas de ruido. En la Figura 3.3.2 presentamos un ejemplo real del comportamiento de nuestro detector frente a un clic de cachalote.

## 3.3.2. Estimación DOA No-Paramétrica

Los métodos de estimación enmarcados en este grupo, que podríamos denominar convencionales dada su amplia aceptación y uso, están basados en una serie de conceptos que no explotan la naturaleza del modelo de señal expuesto en el capítulo 2, tampoco explotan el modelo estadístico de las señales y el ruido.

#### • Método de Mínima Varianza

Este estimador fue propuesto por [Capon 1969 y Capon 1970] para aplicarlo en la estimación del número de onda en detectores sísmicos. Posteriormente en [Lacoss 1971], demostró que el método proporciona estimaciones insesgada de mínima varianza (MV) de las componentes espectrales de la señal. El desarrollo presentado considera un filtro FIR de coeficientes  $a_k$ ,  $0 \le k \le p$ , a determinar. Donde no se impone la restricción clásica (p.ej., AR) de que a<sub>0</sub> valga uno [Kay 1988]. La respuesta del filtro para una señal de entrada, s(t) donde  $t \in [0,T]$  sería:

$$y(t) = \sum_{k=0}^{p} a_k s(t - k \cdot T_s) \equiv \mathbf{s}(t)^T \cdot \mathbf{a}$$

donde  $\mathbf{s}(t) = [s(t), s(t-T_s), \dots, s(t-p \cdot T_s)]^T$  es la entrada, el superíndice ( $\cdot$ )<sup>T</sup> indica traspuesta,  $T_s$  es el periodo de muestreo en segundos y  $\mathbf{a} = [a_0, \dots, a_p]^T$  es el vector de coeficientes del filtro. Si suponemos que  $\mathbf{E}[\mathbf{s}(t)] = 0$ , la varianza de la salida será:

$$\sigma_{y}^{2} = \operatorname{Var}[y(t)] = \operatorname{E}\left[\left|y(t) - \operatorname{E}[y(t)]\right|^{2}\right] = \operatorname{E}\left[\left|\sum_{k=0}^{p} a_{k} s(t - k \cdot T_{s})\right|^{2}\right]$$

donde hemos considerado que  $E[y(t)] = E\left[\sum_{k=0}^{p} a_k s(t-k \cdot T_s)\right] = \sum_{k=0}^{p} a_k E[s(t-k \cdot T_s)] = 0$ , que en forma vectorial quedaría:

$$\sigma_{y}^{2} = \mathbf{E}\left[\left|\mathbf{s}(t)^{T} \cdot \mathbf{a}\right|^{2}\right] = \mathbf{E}\left[\mathbf{a}^{+} \cdot \mathbf{s}^{*}(t) \cdot \mathbf{s}^{T}(t) \cdot \mathbf{a}\right]$$

$$= \mathbf{a}^{+} \cdot \mathbf{\Gamma}_{ss} \cdot \mathbf{a}$$
(Ec.3.3.2)

donde  $\Gamma_{ss} = E[\mathbf{s}^T(t)\mathbf{s}^*(t)]$ es la matriz de covarianzas de la señal de entrada  $\mathbf{s}(t)$  y los superíndices (·)<sup>+</sup> y (·)<sup>\*</sup> indican traspuesta-conjugada y conjugada respectivamente. Si escogemos para el filtro unos coeficientes que a la frecuencia f cumplan la restricción de tener una respuesta normalizada en frecuencia a la unidad  $\sum_{k=0}^{p} a_k \cdot \exp(-j2\pi \cdot k \cdot f) = 1$ , que en forma vectorial  $\mathbf{A}^+(f) \cdot \mathbf{a} = 1$ , donde:

$$\mathbf{A}^{+}(f) = \begin{bmatrix} 1 & \exp(j2\pi \cdot f) \dots \exp(j2\pi \cdot p \cdot f) \end{bmatrix}$$

podemos llegar a una expresión óptima de los coeficientes en el sentido de minimizar  $\sigma_y^2$ . Obtenemos así un filtro FIR que pasa sin distorsionar la componente de frecuencia f, mientras que las componentes distantes a f se atenúan severamente. En [Lacoss 1971] se demuestra que el resultado de esta minimización conduce al vector de coeficientes:

$$\mathbf{a} = \frac{\mathbf{\Gamma}_{ss}^{-1} \cdot \mathbf{A}^{*}(f)}{\mathbf{A}^{T}(f) \cdot \mathbf{\Gamma}_{ss}^{-1} \cdot \mathbf{A}^{*}(f)}$$

Sustituyendo este resultado en Ec.3.3.2 obtendríamos la varianza mínima.

$$\sigma_{\min}^2 = \frac{1}{\mathbf{A}^T(f) \cdot \mathbf{\Gamma}_{ss}^{-1} \cdot \mathbf{A}^*(f)}$$

Una observación importante desde el punto de vista computacional es que  $\Gamma_{ss}^{-1}$ sólo se calcula una vez independientemente del rango de frecuencias considerado. Como realmente sólo disponemos de una estimación de  $\Gamma_{ss}$ ,  $\mathbf{R}_{ss}$ , la potencia espectral de mínima varianza quedaría:

$$P_{ss}^{MV}(f) = \frac{1}{\mathbf{A}^{T}(f) \cdot \mathbf{R}_{ss}^{-1} \cdot \mathbf{A}^{*}(f)}$$

A la vista de la expresión anterior se puede decir que este método es una implementación de banco de filtros, diferenciándose con otros estimadores que usan la misma técnica en que aquí se optimizan los coeficientes del filtro.

Pero nuestro interés no es el cálculo de la potencia o densidad de potencia espectral, sino la potencia o densidad de potencia espacial o angular.

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



**Figura 3.3.3.** Agrupación lineal de M sensores frente a una onda plana incidente desde la dirección θ.

Supongamos, el caso de una ULA de M sensores equiespaciados una distancia 'd' dispuestos según vimos en la Figura 3.3.3. La salida  $x_m(t)$  para un sensor genérico m (m=1,...,M) considerando la incidencia de una sola onda plana vendría dada por la siguiente expresión.

$$x_m(t) = s \left[ t - \tau_m(\theta) \right] + n_m(t)$$

donde  $n_m(t)$  es el ruido de fondo en el *m*-ésimo sensor,  $\tau_m(\theta)$  es el retardo de propagación hasta el *m*-ésimo sensor y s(t) es la señal de la fuente que llega a la agrupación. Si entre los sensores disponemos una separación constante de *d* metros, el retardo quedaría:  $\tau_m(\theta) = m \cdot (d/c) \operatorname{sen}(\theta)$ . Entonces, la salida de la agrupación sería:

$$y(t) = \sum_{m=1}^{M} w_m x_m(t) = \mathbf{x}(t)^T \cdot \mathbf{w}$$

donde  $w_m \in \mathbb{C}$  son unos coeficientes de ponderación que se aplican a la salida de cada uno de los sensores,  $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_M(t)]^T$  y  $\mathbf{w} = [w_1, \dots, w_M]^T$ . Para trabajar con fuentes de banda ancha resulta útil hacerlo en el dominio de la frecuencia, aplicando la transformada de Fourier sobre un intervalo de señal de T (segundos) la expresión anterior en este dominio sería:

$$Y(\boldsymbol{\omega}_k) = \sum_{m=1}^{M} w_m \cdot X_m(\boldsymbol{\omega}_k) = \mathbf{X}(\boldsymbol{\omega}_k)^T \cdot \mathbf{w}$$

siendo  $X_m(\omega_k)$  los coeficientes de Fourier de  $x_m(t)$  para la frecuencia  $\omega_k = 2\pi k/T$ y  $\mathbf{X}(\omega_k) = [X_1(\omega_k), X_2(\omega_k), \dots, X_M(\omega_k)]^T$ . Es importante recordar, que en general para valores de T grandes, los coeficientes de Fourier de las salidas  $Y(\omega_k)$  y  $Y(\omega_r)$  están incorrelados cuando  $k \neq r$ . Si aplicamos sobre y(t) el enfoque MV, la varianza resultaría ser  $\sigma_y^2 = \mathbf{w}^+ \cdot \mathbf{\Gamma}_{xx} \cdot \mathbf{w}$ , donde la matriz de covarianzas viene dada por  $\mathbf{\Gamma}_{xx} = \mathbf{E}[\mathbf{x}^T(t)\cdot\mathbf{x}^*(t)]$ . Minimizando la varianza con la restricción dada en Ec.3.3.3 encontraremos el estimador MV en el dominio de la frecuencia. Además, sustituimos  $\mathbf{\Gamma}_{xx}$  por una estimación mediante  $\mathbf{R}_{xx} = \mathbf{E}[\mathbf{X}(\omega_k)\cdot\mathbf{X}^+(\omega_k)]$ .

$$\sum_{m=1}^{M} w_m \cdot \exp\left[-j2\pi \cdot f\frac{d}{c}(m-1)\cdot \sin\theta\right] = 1 \qquad (Ec.3.3.3)$$

donde *c* es la velocidad de propagación, ahora la búsqueda no se hace en *f* sino en  $\theta$ . Esta restricción puede escribirse matricialmente como:  $\mathbf{A}^+(\omega_k, \theta) \cdot \mathbf{w} = 1$ , donde

$$\mathbf{A}^{+}(\omega_{k},\theta) = \left\{1 \quad \exp(j\omega_{k}\frac{d}{c}\operatorname{sen}\theta) \dots \exp\left[j\omega_{k}\cdot(M-1)\frac{d}{c}\operatorname{sen}\theta\right]\right\}.$$
 Minimizando  $\sigma_{y}^{2}$ ,

sujeta a esa restricción, *Ec.3.3.3*, obtenemos el vector w óptimo:

$$\mathbf{w}_{opt} = \frac{\mathbf{R}_{xx}^{-1} \cdot \mathbf{A}^{*}(\omega_{k}, \theta)}{\mathbf{A}^{T}(\omega_{k}, \theta) \cdot \mathbf{R}_{xx}^{-1} \cdot \mathbf{A}^{*}(\omega_{k}, \theta)}$$

Sustituyendo este resultado en la expresión de la varianza obtendríamos:

$$\sigma_{\min}^{2} = \frac{1}{\mathbf{A}^{T}(\boldsymbol{\omega}_{k},\boldsymbol{\theta}) \cdot \mathbf{R}_{xx}^{-1} \cdot \mathbf{A}^{*}(\boldsymbol{\omega}_{k},\boldsymbol{\theta})}$$

El resultado del enfoque MV sobre una agrupación, en este caso ULA, es un filtro espacial que pasa sin distorsionar la energía de frecuencia  $\omega_k$  con dirección de incidencia  $\theta$  genérica. La energía fuera de esa dirección o en distinta frecuencia se verá atenuada.

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



**Figura 3.3.4.** Ilustración de una hipotética distribución de niveles de los autovalores para un escenario con 3 fuentes inmersas en ruido y una agrupación de 8 sensores.

$$P_{xx}^{MV}(\theta) = \frac{1}{\mathbf{A}^{T}(\omega_{k},\theta) \cdot \mathbf{R}_{xx}^{-1} \cdot \mathbf{A}^{*}(\omega_{k},\theta)}$$

Esta expresión también es conocida como conformador de haz de Capon. Este estimador mejora la resolución espacial del conformador de haz clásico, capacidad que depende de número de sensores, M, que componen la agrupación [Krim 1996].

#### Método MUSIC

El método MUSIC (MUltiple SIgnal Characterization) está basado en la descomposición en valores singulares (SVD) [Rao 1992] de la matriz de covarianzas,  $\mathbf{R}_{yy}$  de y(t) Ec.3.3.4, obtenida a partir del modelo de la Ec.2.4.2. A los métodos que utilizan esta descomposición se les denomina métodos Basados en Subespacios. Originalmente esta descomposición se utilizo en métodos espectrales, aunque de manera implícita. De las primeras publicaciones donde de manera explícita se invoca esta descomposición destacamos, por ser la más afín con nuestra aplicación la de [Pisarenko 1973]. El punto de partida es la matriz de covarianza de la salida, que puede expresarse de la siguiente forma.

$$\mathbf{R}_{yy} \equiv \mathbf{E}\left\{\mathbf{y}(t) \cdot \mathbf{y}^{+}(t)\right\} = \mathbf{A}(\theta) \cdot \mathbf{E}\left\{\mathbf{s}(t) \cdot \mathbf{s}^{+}(t)\right\} \cdot \mathbf{A}^{+}(\theta) + \sigma^{2} \cdot \mathbf{I}$$
 (Ec.3.3.4)

donde  $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_M(t)]^T$ ,  $\mathbf{A}(\theta) = [\mathbf{g}(\theta_1), \dots, \mathbf{g}(\theta_L)]$  de rango  $(M \times L)$  es la matriz de dirección,  $\mathbf{g}(\theta_i) = \{\exp[-j\omega\tau_1(\theta_i)], \dots, \exp[-j\omega\tau_M(\theta_i)]\}^T$  es el vector de las respuestas de cada sensor en la dirección  $\theta_i$ ,  $\tau_m(\theta_i) = (m-1) \cdot d/c \cdot sen(\theta_i)$  el retardo sobre cada sensor tomando como referencia al primer sensor,  $\sigma^2 = E\{\mathbf{n}(t) \cdot \mathbf{n}^+(t)\}$  la varianza del ruido presente en la agrupación e I la matriz identidad.

La descomposición de una matriz genérica **R** de dimensión  $M \times N$ , consiste en representarla mediante  $\mathbf{R} = \mathbf{U} \cdot \mathbf{W} \cdot \mathbf{V}^{\mathrm{T}}$ , donde **U** es una matriz ortogonal de dimensión  $M \times M$  y **V** es otra matriz ortogonal de dimensión  $N \times N$ . La matriz **W** es de la misma dimensión que **R**, donde los elementos de la diagonal tienen valores numéricos no negativos en orden descendente, y todos los elementos fuera de la diagonal son ceros. A los valores de la diagonal de **W** se les denomina valores singulares de **R** y a las columnas de **U** y **V** vectores singulares. Los valores singulares de **R** son las raíces cuadradas de los autovalores o valores propios de  $\mathbf{R}^{\mathrm{T}} \cdot \mathbf{R}$ , **U** los autovectores propios de  $\mathbf{R}^{\mathrm{T}} \cdot \mathbf{R}$  y **V** los autovectores de  $\mathbf{R} \cdot \mathbf{R}^{\mathrm{T}}$ .

Previamente haremos un inciso sobre el problema que nos ocupa, esto es determinar las direcciones de L ondas planas incidiendo en una agrupación lineal e uniforme de M sensores. Además, hemos supuesto que el ruido está espacial y temporalmente incorrelado, que las ondas planas no son totalmente coherentes entre sí y que el número de muestras es mucho mayor que el número de sensores.

Sean  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$  los autovalores de  $\mathbf{R}_{yy}$  ordenados en forma descendente y el rango de  $\mathbf{A}(\theta) \cdot \mathbf{E} \{ \mathbf{s}(t) \cdot \mathbf{s}^+(t) \} \cdot \mathbf{A}^+(\theta) = L$ , entonces debe cumplirse:  $\lambda_i > \sigma^2$  para  $i = 1, \dots, L$  y  $\lambda_i = \sigma^2$ , para  $i = L+1, \dots, M$ , Figura 3.3.4. Suponiendo que los  $\{\lambda_i\}_{i=1}^L$  son distintos, y que sus autovectores son  $v_1, \dots, v_L$  y los correspondientes a  $\{\lambda_i\}_{i=L+1}^M$  son  $e_1, \dots, e_{ML}$ , así que podemos definir las matrices de los autovectores del modo siguiente:

$$\mathbf{V} = \left[\mathbf{v}_{1}, \dots, \mathbf{v}_{L}\right]_{(MxL)}$$
$$\mathbf{E} = \left[\mathbf{e}_{1}, \dots, \mathbf{e}_{M-L}\right]_{(Mx(M-L))}$$

Consecuentemente, al considerar que el espacio de ruido es ortogonal al de señal  $\mathbf{A}^+(\theta) \cdot \mathbf{E} \cdot \mathbf{E}^+ \cdot \mathbf{A}(\theta) = 0$ , para  $\theta = \theta_1, \theta_2, \dots, \theta_L$ , tendríamos:

$$\mathbf{R} \cdot \mathbf{E} = \mathbf{A}(\theta) \cdot \mathbf{E} \{ \mathbf{s}(t) \cdot \mathbf{s}^{+}(t) \} \cdot \mathbf{A}^{+}(\theta) \cdot \mathbf{E} + \sigma^{2} \cdot \mathbf{E} = \sigma^{2} \cdot \mathbf{E}$$
(*Ec.3.3.5*)

Como los autovectores son ortonormales, podemos escribir también la anterior expresión del modo siguiente:

$$\mathbf{A}^{+}(\boldsymbol{\theta}) \cdot \left[\mathbf{I} - \mathbf{V} \cdot \mathbf{V}^{+}\right] \cdot \mathbf{A}(\boldsymbol{\theta}) = 0, \text{ para } \boldsymbol{\theta}_{1}, \boldsymbol{\theta}_{2}, \dots, \boldsymbol{\theta}_{L} \qquad (Ec. 3.3.6)$$

Es posible comprobar algebraicamente que los parámetros  $\{\theta_1, \dots, \theta_L\}$  son las únicas soluciones de *Ec.3.3.6*, [Su 1983].

La idea básica del algoritmo MUSIC es explotar las propiedades Ec.3.3.5 y Ec.3.3.6, de la matriz de covarianzas. En la práctica  $R_{yy}$  es desconocida, pero puede estimarse de manera consistente a partir de los datos, es decir y(t). En base a lo expuesto hasta aquí la función a estudiar será:

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos

$$\mathbf{F}(\theta) = \mathbf{A}^{+}(\theta) \cdot \mathbf{E} \cdot \mathbf{E}^{+} \cdot \mathbf{A}(\theta) \qquad (Ec.3.3.7)$$

La estimación mediante MUSIC de los  $\{\theta_i\}$  se realiza seleccionando los L valores de  $\theta$  para los cuáles  $F(\theta)$  es mínima.

En el método MUSIC la varianza puede ser grande cuando alguno de los autovalores de  $\{\lambda_k\}^{q}_{k=1}$  se aproxima a  $\sigma^2$  [Haykin 1991], Figura 3.3.4. Ejemplo de esto serían aquellas situaciones con baja relación señal a ruido o señales altamente correladas entre sí. También es posible un incremento de la varianza cuando el escenario contiene un "mínimo plano", dicho de otro modo, la estimación alcanza un valle que impide la determinación de un único valor mínimo.

Con el fin de paliar en cierta medida la varianza en [Sharman 1986] se publica una sugestiva variante que en [Haykin 1991] han denominado estimador MUSIC "Mejorado". Para ello consideran el producto entre el vector de direcciones de fuente  $\mathbf{A}(\theta)$  y la estimación del autovector del espacio de ruido,  $\hat{\mathbf{e}}$ , *Ec.3.3.8.* Cuando los autovectores del espacio de ruido son perfectamente conocidos  $\varepsilon_i(\theta) = 0$ . La mejora del estimador se obtiene maximizando la verosimilitud del vector  $\mathbf{\varepsilon}$ :

$$\varepsilon_i(\theta) \equiv \mathbf{A}^+(\theta) \cdot \hat{\mathbf{e}}_i \text{ con } i = 1, \dots, M - L \qquad (Ec.3.3.8)$$

Se observa que el estimador dado en *Ec.3.3.7* minimiza:

$$\sum_{i=1}^{M-L} \left| \mathcal{E}_i \right|^2$$

En [Sharman 1986] encontramos que el estimador que maximiza la verosimilitud asintótica (para N >> 0) de *Ec.3.3.8* viene dado por la minimización de la función:

$$\boldsymbol{\alpha}(\theta) = \frac{\mathbf{F}(\theta)}{\mathbf{r}(\theta)} \tag{Ec.3.3.9}$$

donde  $\mathbf{F}(\theta)$  es la función MUSIC original y  $\mathbf{r}(\theta)$  es:

$$\mathbf{r}(\theta) = \mathbf{A}^{+}(\theta) \cdot \hat{\mathbf{U}} \cdot \mathbf{A}(\theta)$$

donde la matriz  $\hat{\mathbf{U}}$  de la expresión anterior se obtiene de la matriz  $\mathbf{U}$ , dada en la expresión siguiente:

$$\mathbf{U} = \boldsymbol{\sigma}^{2} \left[ \sum_{k=1}^{L} \frac{\lambda_{k}}{\left(\boldsymbol{\sigma}^{2} - \lambda_{k}\right)} \mathbf{v}_{k} \cdot \mathbf{v}_{k}^{H} \right]$$

Esta matriz se construye a partir de los autovalores y autovectores del espacio de señal, obtenidos a partir de la matriz de covarianzas estimada de las muestras, es decir  $\{\hat{\lambda}_k\}$  y  $\{\hat{\mathbf{v}}_k\}$  por descomposición de  $\hat{\mathbf{R}}_{yy}$ . Esta variante del MUSIC es más costosa, computacionalmente hablando, pero presenta mejores prestaciones especialmente cuando tenemos pocas muestras de la señal y cuando la varianza del ruido es alta. Un último apunte sobre esta mejora es que el numerador  $\mathbf{r}(\theta)$  está relacionado con la varianza del estimador MUSIC.

Siguiendo la misma propuesta anterior en [Stoica 1990b] nos muestran que el concepto exacto del estimador ML (Maximun Likelihood) no obtiene como resultado la minimización de *Ec.3.3.9*. Estos investigadores demuestran y proponen determinar las estimaciones de  $\{\theta_i\}$  minimizando la siguiente función:

$$\boldsymbol{\beta}(\boldsymbol{\theta}) = \frac{M - L}{N} \cdot Ln \left[ \hat{\boldsymbol{\sigma}} \mathbf{r}(\boldsymbol{\theta}) \right] + \frac{\mathbf{F}(\boldsymbol{\theta})}{\hat{\boldsymbol{\sigma}} \mathbf{r}(\boldsymbol{\theta})}$$

donde  $\hat{\sigma} = \frac{1}{M-L} \sum_{k=L+1}^{M} \hat{\lambda}_k$ .

En [Stoica 1990a] podemos encontrar un esmerado análisis de la raíz cuadrada de la media de los valores del error cuadrático (Root Mean Square Error, RMSE) y la media de los valores absolutos del error, para el MUSIC y el MUSIC mejorado. En la citada referencia se les denomina MUSIC-1 y MUSIC-2, respectivamente. Mediante la realización de simulaciones numéricas y análisis de los citados parámetros, los autores concluyen que ambos métodos presentan prácticamente la misma carga computacional. Sin embargo, lo más destacable es el comportamiento frente a fuentes correladas. El MUSIC es incapaz de realizar estimaciones en estas condiciones, mientras el MUSIC mejorado presenta estimaciones con una baja deriva, incluso en condiciones adversas de relación señal a ruido, aunque bien es verdad no realiza todas las estimaciones posibles.

## • Método de Mínima Varianza Guiada

Cuando las fuentes a localizar sean de banda ancha, será necesaria una operación o preprocesado tendente a reducir el problema a banda estrecha, para seguidamente tratarlo con los métodos clásicos de DOA. Para ello, por ejemplo, si aplicamos una FFT o un banco de filtros el problema de banda ancha se convierte en banda estrecha. Si aplicamos un banco de filtro tendríamos que intercalar filtros paso banda, tantos como fueran necesarios, para transformar el caso de banda ancha en un caso múltiple de banda estrecha.

El método de Mínima Varianza Guiada (STeered Minimum Variance, STMV) que vamos exponer, presentado en [Krolik 1989, Haykin 1991], tiene como

planteamiento general de principio la detección y localización de varias fuentes acústicas de banda ancha, dadas las salidas de una agrupación de sensores pasiva. Su detección y localización implica, además la discriminación de múltiples señales superpuestas a un ruido difuso que se supone de fondo.

Una posible solución a este problema sería dividir direccionalmente el campo acústico, lo que se conoce como filtrado espacial, asociando los máximos locales de potencia con la dirección de las fuentes en campo lejano.

La mayoría de los métodos de conformación de haz de alta resolución se han desarrollado para señales de banda estrecha. Estos métodos requieren la estimación de la matriz densidad de espectro cruzado de las salidas de la agrupación (Cross Spectral Density Matrix, CSDM). La extensión de estas técnicas a problemas de banda ancha se logra mediante la estimación de una matriz CSDM por cada frecuencia de la banda de trabajo. El siguiente paso será la combinación de las matrices CSDM con los resultados de estimaciones en banda estrecha para cada banda. Esto requiere la realización de observaciones largas, a fin de obtener medidas estadísticamente estables. Sin embargo, un tiempo de observación largo constituye una seria limitación. Por ejemplo, si las fuentes sonoras del escenario cambian de localización dinámicamente en el tiempo las propiedades del campo acústico no son estacionarias, lo que limita el tiempo de observación disponible.

El método STMV es capaz de tratar con señales de banda ancha, requiriendo un tiempo de observación significativamente reducido. El primer paso es preprocesar las salidas de los sensores de modo que cada fuente de banda ancha pueda representarse mediante un modelo de rango 1. El preprocesado consiste en crear la matriz de covarianzas de la salida de los sensores y seguidamente insertar retardos para formar un conformador de haz convencional. La estadística espaciotiempo resultante, denominada matriz de covarianzas dirigida (Steered Covariance Matrix, STCM), focaliza de manera efectiva a las ondas incidentes en su dirección de apuntamiento. En otras palabras, una fuente de banda ancha en la dirección de apuntamiento de la STCM contribuye con un componente de rango uno a la matriz, independientemente de su espectro temporal. De este modo usando una STCM diferente para cada dirección de interés, cada una de las fuentes presentes en el campo acústico podrían manipularse mediante modelos de rango uno.

Consideremos una agrupación lineal de banda ancha con M sensores midiendo un campo generado por L fuentes puntuales (y en campo lejano) de banda ancha en presencia de ruido ambiente difuso. Supongamos que las fuentes y el ruido de fondo son estadísticamente independientes. Sea  $y_m(t)$  la representación analítica de la salida continua en el tiempo para un sensor m con m=-K,...,K siendo M=2K+1 el número total de sensores, y K un número entero y par. Así las cosas el modelo supuesto sería:

$$y_m(t) = \sum_{i=1}^{L} s_i \left[ t - \tau_m(\theta_i) \right] + n_m(t)$$

donde  $s_i(t)$ , i=1,...,L son las señales recibidas de cada una de las fuentes, consideradas procesos aleatorios estacionarios de media nula. El término  $n_m(t)$ representa el ruido de fondo procesado en cada sensor, que consideramos espacial y temporalmente estacionario, y de media nula. Mediante  $\tau_m(\theta)$ representamos el retardo de propagación en el *m*-ésimo sensor relativo a la coordenada origen de la agrupación para una fuente localizada en  $\theta_i$ . Las localizaciones,  $\theta_i$  para i=1,...,L de las *L* fuentes, son los parámetros a estimar a partir de una observación finita, muestreo temporal en la salida de los sensores. Excepto para condiciones de propagación multitrayecto, supondremos que las fuentes están mutuamente incorreladas.

Para una mejor aproximación al problema del procesado de agrupaciones de banda ancha, será útil considerar una representación en el dominio de la frecuencia de la salida de los sensores. El vector en el dominio de tiempo de las salidas será:  $\mathbf{y}(t) = [y_{\cdot\mathrm{K}}(t),...,y_{\mathrm{K}}(t)]^T$  en el intervalo temporal -T/2 a T/2. El vector en el dominio de la frecuencia será  $\mathbf{Y}(\omega_k) = [Y_{\cdot\mathrm{K}}(\omega_k),...,Y_{\mathrm{K}}(\omega_k)]^T$ , donde los elementos  $Y_{\mathrm{K}}(\omega_k)$ , de  $\mathbf{Y}(\omega_k)$  corresponden a los coeficientes de las series de Fourier de  $y_{\mathrm{m}}(t)$  a la frecuencia  $\omega_k = 2\pi k/T$ . Para valores grandes de T los vectores  $\mathbf{Y}(\omega_k)$  y  $\mathbf{Y}(\omega_k)$  ( $k \neq r$ ) estarán incorrelados. Supongamos que las salidas de los sensores están limitadas en banda a  $\omega_l \leq \omega_k \leq \omega_h$ . La frecuencia  $\omega_l$  representa la más baja del ancho de banda útil de la señal y  $\omega_h$  la más alta. Las estadísticas de segundo orden del campo considerado quedarán especificadas mediante el conjunto de matrices de densidad de espectro cruzado para banda estrecha,  $\mathbf{R}_{yy}(\omega_k) = \mathbf{E}[\mathbf{Y}(\omega_k)$   $\mathbf{Y}(\omega_k)^+]$ , para k = l,...,h, donde recordamos que el superíndice ()+ implica conjugada y traspuesta. La matriz  $\mathbf{R}_{yy}(\omega_k)$  puede expresarse mediante:

$$\mathbf{R}_{yy}(\omega_k) = \mathbf{A}(\omega_k, \theta) \cdot \mathbf{P}_s(\omega_k) \cdot \mathbf{A}(\omega_k, \theta)^+ + \mathbf{R}_n(\omega_k)$$

donde  $\mathbf{A}(\omega_k, \theta) = [\mathbf{g}(\omega_k, \theta_l), \mathbf{g}(\omega_k, \theta_2), ..., \mathbf{g}(\omega_k, \theta_p)]$  es la matriz  $M \times L$  de dirección de las fuentes,  $\mathbf{g}(\omega_k, \theta_i) = \{\exp[-j\omega_k \tau_{-K}(\theta_i)], ..., \exp[-j\omega_k \tau_K(\theta_i)]\}^T$  es el vector de direcciones de la *i*-ésima fuente,  $\mathbf{P}_s(\omega_k)$  es la matriz  $L \times L$  de densidad espectral de las fuentes situadas en  $\theta = [\theta_1, ..., \theta_L]$ , y  $\mathbf{R}_n(\omega_k)$  es la matriz  $M \times M$  de covarianza de ruido.

Aunque el vector de situación de las fuentes ( $\theta$ ) es independiente de la frecuencia este vector de parámetros está incluido en las matrices de dirección de fuentes,  $\mathbf{A}(\omega_k, \theta)$ , con k = l,...,h, claramente dependiente de la frecuencia. Por lo tanto, la misma fuente contribuye con un componente de rango uno en  $\mathbf{R}_{yy}(\omega_k)$  distinto en cada frecuencia. Luego, sin preprocesar los vectores en el dominio de la frecuencia,  $\mathbf{Y}(\omega_k)$  para k = l,...,h, no podrán usarse para formar una matriz de covarianzas de banda ancha única, en la que cada fuente tenga una representación de rango uno.

La estimación espacial de espectros de banda ancha conlleva, por lo general, primero la formación de estimaciones espaciales de espectros de banda estrecha en cada frecuencia, y segundo la combinación de los resultados para alcanzar los métodos de banda ancha llamados incoherentes. El inconveniente principal es la Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos

necesidad de estimar matrices de espectro cruzado de banda estrecha para cada frecuencia de la banda de recepción.

La acción denominada focalización o centrado de banda ancha implica un proceso previo sobre  $\mathbf{Y}(\omega_k)$ . La transformación aplicada a los vectores de salida de los sensores tendrá así la misma descripción de rango uno en todas las frecuencias temporales. Ahora, las matrices de covarianza de banda estrecha de las salidas preprocesadas podrán sumarse en frecuencia para obtener una matriz de covarianza focalizada y de banda ancha. En esta matriz los componentes de interés podrán estimarse con una estabilidad estadística que es función del producto tiempo total de observación, T, por ancho de banda,  $\Delta \omega = \omega_{\rm h} \cdot \omega_{\rm l}$ .

Si consideramos  $\theta$  como la dirección de interés, la focalización puede alcanzarse formando  $\mathbf{T}_{s}(\theta, \omega_{k}) \cdot \mathbf{Y}(\omega_{k})$ , donde  $\mathbf{T}_{s}(\theta, \omega_{k})$  se define mediante:

$$\mathbf{T}_{s}(\theta,\omega_{k}) = \begin{cases} \exp[j\omega_{k}\tau_{-K}(\theta)] & 0 & \cdots & 0 \\ 0 & \exp[j\omega_{k}\tau_{-K+1}(\theta)] & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \exp[j\omega_{k}\tau_{K}(\theta)] \end{cases}$$

Esta matriz recibe el nombre de matriz de apuntamiento o matriz dirigida, su utilidad radica en su capacidad para construir un vector dirigido u orientado en la dirección  $\theta$ , a partir de las salidas de los sensores en el dominio del tiempo, es decir:

$$\mathbf{y}_{s}(t,\theta) = \sum_{k=l}^{h} \mathbf{T}_{s}(\theta,\omega_{k}) \mathbf{Y}(\omega_{k}) \cdot \exp(j\omega_{k}t)$$

Teniendo en cuenta la definición de  $\mathbf{T}_s$  e  $\mathbf{y}_s(t, \theta)$  quedaría:

$$\mathbf{y}_{s}(t,\theta) = \left\{ y_{-K} \left[ t + \tau_{-K}(\theta) \right], y_{-K+1} \left[ t + \tau_{-K}(\theta) \right], \dots, y_{K} \left[ t + \tau_{-K}(\theta) \right] \right\}^{T}$$

Se observa que los retardos de apuntamiento son precisamente los necesarios para implementar un conformador de haz del tipo retardo y suma en la dirección  $\theta$ , por ejemplo en [Krim 1996]. En general, la suma de matrices de covarianza de banda estrecha predirigidas resulta en una matriz de covarianzas de banda ancha focalizada o centrada dada por:

$$\mathbf{R}_{s}(\theta) = \sum_{k=l}^{h} \mathbf{T}_{s}(\omega_{k},\theta) \mathbf{R}_{ys}(\omega_{k}) \mathbf{T}_{s}(\omega_{k},\theta)^{+}$$
(Ec.3.3.9)

A  $\mathbf{R}_{s}(\theta)$  se le denomina matriz de covarianzas dirigidas (STeered Covariance Matrix, STCM) correspondiente a la dirección  $\theta$ . La estructura de esta matriz, sobre la base del modelo inicial, puede usarse para impulsar una variedad de métodos de estimación de espectros de banda ancha en el espacio. Por ejemplo, si consideramos una agrupación lineal de sensores igualmente espaciados una distancia, d, situados en  $x_m = m \ d = -K, ..., K$ . Sea  $\theta$  la dirección de la fuente relativa al broadside de la agrupación, entonces,  $\tau_m(\theta) = m \cdot \tau(\theta)$  es el retardo asociado con cada sensor, donde  $\tau(\theta) = d/c \ sen(\theta)$  y c la velocidad de propagación. De esta forma, el elemento jk-ésimo de  $\mathbf{R}_s(\theta)$  vendría dado por:

$$\left\{\mathbf{R}_{s}(\theta)\right\}_{jk} = \sum_{i=1}^{L} \rho_{i} \left\{m\left[\tau\left(\theta\right) - \tau\left(\theta_{i}\right)\right]\right\} + \eta_{m}\left[m \cdot \tau\left(\theta\right)\right]$$

donde  $\rho_i(\tau) = E\{s_i(t+\tau)s_i(t)^*\}$  es la función de autocorrelación de la *i*-ésima fuente y  $\eta_m(\tau) = E\{n_0(t+\tau)n_m(t)^*\}$  es la función de correlación cruzada entre el ruido recibido en el sensor que se encuentra en la coordenada origen de la agrupación y el *m*-ésimo sensor. La función es válida bajo la condición de que las fuentes estén incorreladas, o bien que los retardos por propagación multitrayecto estén muy por encima del tiempo de correlación de las señales de la fuente más el retardo de propagación a lo largo de la agrupación. Esta insensibilidad de la STCM a la correlación multitrayecto implica que las técnicas basadas en STCM pueden usarse, sin modificación, para resolver fuentes coherentes afectadas por multitrayecto. Además, cuando la dirección de apuntamiento, es igual a  $\theta_L$ , tenemos que  $\{\mathbf{R}_s(\theta_L)\}_{jk}$  es

$$\left\{\mathbf{R}_{s}(\theta_{L})\right\}_{jk} = \sum_{\substack{i=1\\i\neq L}}^{L} \rho_{i}\left\{m\left[\tau\left(\theta_{L}\right) - \tau\left(\theta_{i}\right)\right]\right\} + \sigma_{L}^{2} + \eta_{m}\left[m\cdot\tau\left(\theta_{s}\right)\right]$$

donde  $\sigma_L^2 = \rho_L(0)$  es la potencia de la *L*-ésima fuente. De este modo para una fuente alineada con la dirección de apuntamiento de la agrupación, la STCM contiene una constante, componente de rango uno igual a la potencia de la fuente e independiente de su firma espectral.

Una comparación interesante sería entre la focalización de banda ancha arriba presentada con el método de estimación espectral de mínima varianza (MV). Para una agrupación "sintonizada" a la frecuencia  $\omega_k$  la estimación del espectro espacial de mínima varianza en banda estrecha,  $\mathbf{Z}_k(\theta)$ , vendrá dada por:

$$\mathbf{Z}_{k}(\theta) = \left[\mathbf{g}(\omega_{k},\theta)^{+} \cdot \mathbf{R}(\omega_{k})^{-1} \cdot \mathbf{g}(\omega_{k},\theta)\right]^{-1}$$
(Ec.3.3.11)

Si tomamos una muestra finita de datos de la agrupación será posible una estimación,  $\hat{\mathbf{Z}}_{k}(\theta)$ , de  $\mathbf{Z}_{k}(\theta)$  sustituyendo la matriz de covarianzas por una estimación,  $\hat{\mathbf{R}}(\omega_{k})$ . Cuando se desea un registro completo de todo el campo de observación, tendremos que calcular  $\hat{\mathbf{Z}}_{\kappa}(\theta)$  para cada una de las direcciones de

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos

interés. Seguidamente, sumando las estimaciones de mínima varianza (banda estrecha), para cada una de las bandas de interés (de  $\omega_1 a \omega_n$ ); llegaremos a  $\hat{\mathbf{Z}}_{icmv}(\theta)$  que es el estimador de mínima varianza incoherente (ICMV) y de banda ancha, dado por:

$$\hat{\mathbf{Z}}_{icmv}(\theta) = \sum_{k=l}^{h} \left[ \mathbf{g} \left( \omega_k, \theta \right)^+ \cdot \hat{\mathbf{R}} \left( \omega_k \right)^{-1} \cdot \mathbf{g} \left( \omega_k, \theta \right) \right]^{-1}$$
(Ec.3.3.12)

Este estimador lo usaremos como base para comparar las prestaciones de otro resultante del método denominado Mínima Varianza Guiada (Steered Minimum Variance, STMV). El STMV consiste en la estimación de las componentes de cc (corriente continúa) de la STCM orientada en cada dirección  $\theta$ , mediante un planteamiento de mínima varianza. La estimación del espectro espacial en la dirección  $\theta$ , mediante este método, posee el efecto de minimizar la contribución energética de las fuentes en otras direcciones. Aplicando *Ec.3.3.11* para estimar la cc de  $\mathbf{R}_s(\omega)$ , obtendríamos el estimador de espectro espacial del método denominado STMV.

$$\mathbf{Z}_{stmv}(\boldsymbol{\theta}) = \left[\mathbf{1}^{+} \cdot \mathbf{R}_{s}(\boldsymbol{\theta})^{-1} \cdot \mathbf{1}\right]^{-1}$$

donde 1 es una matriz  $M \times 1$  de unos. Sustituyendo  $\mathbf{R}_{s}(\omega)$  mediante  $\hat{\mathbf{R}}_{s}(\omega)$  dada por *Ec.3.3.9* obtendremos, para una muestra finita, el estimador,  $\hat{\mathbf{Z}}_{stmv}(\theta)$ , de  $\mathbf{Z}_{stmv}(\theta)$ . Al igual que para *Ec.3.3.12*, podremos formar estimaciones de la potencia espacial del espectro en banda ancha calculando  $\hat{\mathbf{Z}}_{stmv}(\theta)$  para un conjunto de direcciones  $\{\theta\}$  que contiene las localizaciones de interés.

$$\hat{\mathbf{Z}}_{stmv}(\theta) = \frac{1}{\mathbf{1}^{+} \left[ \sum_{k=l}^{h} \mathbf{T}_{s}(\omega_{k}, \theta) \cdot \hat{\mathbf{R}}(\omega_{k}) \cdot \mathbf{T}_{s}(\omega_{k}, \theta)^{+} \right]^{-1}} \mathbf{1}$$
(Ec.3.3.13)

La expresión Ec.3.3.13 nos muestra claramente que en caso de banda estrecha (l=h), el STMV se reduce al método MV convencional. Sin embargo, para fuentes de banda ancha, comparando Ec.3.3.12 con Ec.3.3.13, aparecen diferencias sustanciales. Específicamente, en Ec.3.3.13, las matrices de covarianza se promedian previamente a su inversión. Sin embargo, en Ec.3.3.12, se aplica la inversión a cada matriz de covarianzas de banda estrecha antes del promediado. Por esta razón, el método STMV proporciona una inversión de matrices estadísticamente más estable, lo que facilita su uso con un número pequeño de muestras. Sin embargo, el método STMV, estrictamente hablando, es asintóticamente subóptimo. Es decir, su precisión, a diferencia de lo que ocurre con los métodos incoherentes, no mejora al incrementar el tiempo de observación (tamaño de la muestra). Al incrementar el tamaño del snapshot la varianza del



Figura 3.3.5. Expresión gráfica del concepto de centrado o focalización simultánea de todas las fuentes, hacia un espacio con la dirección original de cada fuente, aunque todas a una misma frecuencia central ω<sub>0</sub>.

método STMV disminuye, pero esta mejora va acompañada por un incremento en la deriva del valor de localización estimado cuando el tamaño de la muestra supera el umbral del tiempo de observación. En [Krolik 1989, Haykin 1991] podemos encontrar un estudio más exacto de la varianza del STMV en comparación con el ICMV (InCoherent Minimum Variance). Los resultados sugieren que el STMV es capaz de proporcionar estimaciones del espectro espacial para fuentes próximas con pocos datos, mientras que el método ICMV produce matrices  $\hat{\mathbf{R}}(\omega_k)$  singulares y por tanto estimaciones estadísticamente inestables.

## • Método del Remuestreo Espacial de Mínima Varianza

Una matriz STCM solamente focaliza incidencias de banda ancha en una única dirección de apuntamiento,  $\theta$ . Entonces habrá que calcular matrices STCM en todas las direcciones de interés. Obviamente, una transformación capaz de centrar con precisión incidencias de todas las direcciones simultáneamente sería, computacionalmente hablando, más eficiente. Idealmente, esta operación de enfoque transformaría cada matriz de covarianzas (de banda estrecha) de tal modo que cada fuente presente en el escenario aparecería con una caracterización de rango uno, Figura 3.3.5. Además, esta caracterización debería ser independiente de la frecuencia y de su posición. Como resultado tendríamos una única matriz de covarianzas guiada (banda ancha), para estimar el espectro espacial en todas las direcciones. El método conocido como Remuestreo Espacial de Mínima Varianza (Spatially Resampled Minimum Variance, SRMV) [Krolik 1990b, Haykin 1991] aplicado en agrupaciones lineales equiespaciadas, es capaz de alcanzar, aproximadamente, este objetivo. Y, además, sin la necesidad de estimaciones preliminares de las direcciones de las fuentes. Este método, conceptualmente, consiste en tratar las salidas de una agrupación de M sensores, como el resultado de un muestreo espacial realizado sobre una apertura lineal. En una agrupación lineal discreta con sensores espaciados una distancia d,

situados en  $x_m = m \cdot d$  (m = -K, ..., K), M = 2K+1 con  $K \in \mathbb{Z}$  pares, la salida en el dominio de la frecuencia del *m*-ésimo sensor puede expresarse mediante:

$$Y_m(\omega_k) = \sum_{i=1}^{L} S_i(\omega_k) \exp\left[j\omega_k m \frac{d}{c} \operatorname{sen}(\theta_i)\right] + N_m(\omega_k) \qquad (Ec.3.3.14)$$

donde  $S_i(\omega_k)$  representa a la componente frecuencial  $\omega_k$  de la *i*-ésima fuente y  $N_m(\omega_k)$  expresa el ruido a la salida del *m*-ésimo sensor a la frecuencia  $\omega_k$ . Las  $\theta_i$ , i=1,...,L, son las direcciones de las fuentes relativas al broadside de la agrupación. Si denominamos a  $Y_f(x, \omega_k)$  como el campo incidente a la frecuencia  $\omega_k$  sobre una apertura lineal dispuesta a lo largo del eje x, entonces,  $Y_m(\omega_k)$  puede verse como el resultado de muestrear espacialmente en posiciones x=m d, con m=-K,...,K y K=(M-1)/2, a la función  $Y_f(x, \omega_k)$  continua en x.

$$Y_f(x,\omega_k) = \sum_{i=1}^{L} S_i(\omega_k) \exp\left[j\omega_k \frac{x}{c} \operatorname{sen}(\theta_i)\right] + N(x,\omega_k)$$
 (Ec.3.3.15)

Suponiendo que la matriz de direcciones es constante para todas las frecuencias, dentro del ancho de banda común, y aplicando una transformación a las salidas  $Y_{\rm m}(\omega_{\rm k})$  de los sensores, sería posible centrar o focalizar simultáneamente a todas las fuentes [Krolik 1990a]. Sea  $Y(\omega_{\rm k})$  el vector centrado o enfocado de la salida de los sensores y  $A(\omega_{\rm k}, \theta)$  la matriz centrada o focalizada de las direcciones de cada una de las fuentes, y  $\omega_0$  la frecuencia central. El objetivo del centrado o focalización de banda ancha implica encontrar matrices de enfoque  $T_r(\omega_{\rm k})$  tal que:

$$\tilde{\mathbf{A}}(\omega_k, \theta) \equiv \mathbf{T}_r(\omega_k) \mathbf{A}(\omega_k, \theta) = \mathbf{A}(\omega_0, \theta)$$

Así, cada fuente de banda ancha presente en la matriz de covarianzas centrada, Ec.3.3.16, quedaría caracterizada mediante una submatriz de covarianzas de rango uno.

$$\tilde{\mathbf{R}}(\omega_0) = \sum_{k=l}^h \mathbf{T}_r(\omega_k) \mathbf{R}(\omega_k) \mathbf{T}_r(\omega_k)^T \qquad (Ec.3.3.16)$$

La obtención de  $\tilde{\mathbf{A}}(\omega_k, \theta) = \mathbf{A}(\omega_0, \theta)$ , para cualquier  $\omega_k$  dentro del ancho de banda común a la fuente, consiste en ajustar el intervalo espacial de muestreo, d, en función de la frecuencia,  $\omega_k$ . Si expresamos la dependencia con la frecuencia de dicho intervalo mediante  $d(\omega_k)$ , el resultado ideal para el muestreo del campo incidente en  $x = n \cdot d(\omega_k) = n \cdot d \cdot \omega_0 / \omega_k$  [Bienvenu 1989], lo encontraremos sustituyendo esto en la expresión *Ec.3.3.15*.

$$\tilde{Y}_n(\omega_k) = \sum_{i=1}^L S_i(\omega_k) \exp[j\omega_0 \cdot \alpha_i \cdot n \cdot d] + \tilde{N}_n(\omega_k), \qquad -\tilde{K} \le n \le \tilde{K}$$

donde  $\widetilde{M} = 2\widetilde{K} + 1$  es la longitud de la agrupación remuestreada,  $\alpha_i = \operatorname{sen}(\theta_i)/c$  y  $\widetilde{N}_n(\omega_k)$  representa a la componente de ruido en la salida remuestreada de los sensores. Para  $\widetilde{K} = K$  obtenemos  $\widetilde{A}(\omega_k, \theta) = A(\omega_0, \theta)$  para cualquier  $\omega_k$ . El solapamiento espacial se evita eligiendo,  $d(\omega_k)$ , tal que  $\omega_k/c \leq \pi/d(\omega_k)$ , lo que implica  $\omega_0 \leq \pi c/d$ , es decir,  $d \leq \lambda_0/2$ . Si el espacio físico entre sensores es de  $\lambda/2$ , a la frecuencia de fuente más alta  $(\omega_h)$ , entonces, la agrupación deberá centrarse o focalizarse a frecuencias  $\omega_0 \leq \omega_h$  ( $\lambda_h \leq \lambda_0$ ).

La transformación necesaria para alcanzar un remuestreo perfecto se obtiene examinando la operación en el dominio de la frecuencia. Pongamos que  $Y(e^{j\tilde{\psi}}, \omega_k)$ e  $\hat{Y}(e^{j\tilde{\psi}}, \omega_k)$  son las transformadas espaciales de Fourier de  $y_m(\omega_k)$  e  $y_n(\omega_k)$ respectivamente. Se demuestra en [Krolik 1990] que el remuestreo espacial perfecto corresponde a la traslación de frecuencia espacial definida por:

$$\tilde{Y}(e^{j\tilde{\psi}}, \omega_k) = \begin{cases} \frac{\omega_k}{\omega_0} Y(e^{j\tilde{\psi}}, \omega_k), & \text{para} \left| \tilde{\psi} \right| \leq \min\left(\pi, \pi \frac{\omega_0}{\omega_k}\right) \\ 0 & , & \text{para} \min\left(\pi, \pi \frac{\omega_0}{\omega_k}\right) < \left| \tilde{\psi} \right| \leq \pi \end{cases}$$

donde min(x,y) expresa el menor de x o y. La relación anterior indica que el remuestreo espacial ideal reescala el eje de frecuencia espacial,  $\psi$ , en cada frecuencia temporal,  $\omega_k$ , por el factor  $\omega_b/\omega_k$  de modo que una onda plana en $\psi_i = \omega_k \alpha_i \cdot d$  se traslada a  $\psi_i = \omega_k \alpha_i \cdot d \cdot \omega_0 / \omega_k = \omega_0 \cdot \alpha_i \cdot d$ . Esta operación de traslación de frecuencias es la clave de la focalización de banda ancha, de modo que asegura que la frecuencia espacial de una fuente de banda ancha es la misma sobre la totalidad de su ancho de banda temporal, permitiéndole ser modelada como una señal de rango uno. La transformación que puede realizar la focalización de longitud finita sería la siguiente matriz MxM:

$$\left\{\mathbf{T}_{r}^{++}\left(\boldsymbol{\omega}_{k}\right)\right\}_{pq} = \frac{1}{\pi} \cdot \frac{\operatorname{sen}\left\{\Psi_{k}\left[\frac{\boldsymbol{\omega}_{0}}{\boldsymbol{\omega}_{k}}\cdot\left(p-\tilde{K}-1\right)-\left(q-K-1\right)\right)\right]\right\}}{\left[\frac{\boldsymbol{\omega}_{0}}{\boldsymbol{\omega}_{k}}\cdot\left(p-\tilde{K}-1\right)-\left(q-K-1\right)\right)\right]}$$

donde el superíndice (·)<sup>++</sup> indica óptimo,  $\psi_k = \min(\pi, \pi \cdot \omega_k / \omega_0), p = 1,...,\tilde{M}, q = 1,...,M$ , y  $\tilde{M} = 2 \cdot \tilde{K} + 1$ . El error de remuestreo resultante sugiere que  $\tilde{K}$  debe satisfacer  $\tilde{K} = \left\lfloor K \cdot \frac{\omega_l}{\omega_0} \right\rfloor$ , donde  $\lfloor x \rfloor$  indica el mayor de los enteros que resulta menor

o igual a x. Luego, una elección de la longitud de la agrupación remuestreada;  $\widetilde{M} = 2 \cdot \widetilde{K} + 1$  sería consistente.

La matriz de covarianzas focalizada,  $\tilde{\mathbf{R}}(\omega_0)$ , estimada en tiempo finito de las N instantáneas (snapshots) de la agrupación, la obtenemos mediante la matriz de focalización y la estimación,  $\hat{\mathbf{R}}(\omega_k)$ , a partir de la siguiente expresión:

$$\tilde{\mathbf{R}}_{\mathbf{N}}(\omega_0) = \sum_{k=l}^{h} \mathbf{T}_{t}^{++}(\omega_k) \cdot \hat{\mathbf{R}}(\omega_k) \cdot \mathbf{T}_{t}^{++}(\omega_k)^{+} \qquad (Ec.3.3.17)$$

Usando *Ec.3.3.17* y realizando una estimación de mínima varianza, del espectro espacial a la frecuencia  $\omega_0$ , obtendremos el estimador de mínima varianza en banda ancha remuestreado espacialmente,  $\mathbf{Z}_{srmv}(\theta)$ , en la dirección  $\theta$ .

$$\hat{\mathbf{Z}}_{\text{srmv}}(\theta) = \frac{1}{\tilde{\mathbf{g}}(\omega_0, \theta)^+ \cdot \left[\sum_{k=l}^{h} \mathbf{T}_{l}^{++}(\omega_k) \cdot \hat{\mathbf{R}}(\omega_k) \cdot \mathbf{T}_{l}^{++}(\omega_k)^+\right]^{-1} \cdot \tilde{\mathbf{g}}(\omega_0, \theta)}$$

La estimación SRMV se parece a la STMV, ya que contempla el sumatorio de las matrices densidad de espectro cruzado a lo largo de la banda de recepción, previamente a la inversión de la matriz. Sin embargo, en el método SRMV la matriz en banda ancha de las covarianzas centradas,  $\tilde{\mathbf{R}}(\omega_0)$ , no depende de la dirección a la que apuntamos puesto que  $\tilde{\mathbf{R}}(\omega_0)$  fue diseñada para focalizar todas las incidencias simultáneamente. Como sólo formamos e invertimos una matriz de covarianzas centradas para todas las direcciones,  $\theta$ , éste método resultará considerablemente más eficiente desde el punto de vista computacional que el STMV. El análisis de la varianza de este estimador realizado en [Haykin 1991] alcanza la siguiente expresión:

$$Var\left\{\hat{Z}_{srmv}(\theta)\right\} = \frac{1}{BN - \tilde{M} + 1} \left\{ E\left[\hat{Z}_{srmv}(\theta)\right] \right\}^{2}$$

donde  $\mathbb{E}[z]$  expresa esperanza matemática de z. Observamos que la relación entre el producto tiempo de observación (N tamaño en muestras) ancho de banda ( $B \cdot N$ ) frente a  $\tilde{M}$ , longitud de la agrupación remuestreada, es un factor clave para explicar el incremento de estabilidad estadística de los métodos de banda ancha focalizados. Incluso cuando  $N < \tilde{M}$  y por tanto la matriz  $\hat{\mathbf{Z}}_{icmv}(\theta)$  no puede calcularse, todavía es posible aplicar el método SRMV, si  $B \cdot N \ge \tilde{M}$ . Para señales de banda ancha esto sugiere que  $B \ge \tilde{M}$ . El método SRMV puede producir estimaciones independientes de las localizaciones de las fuentes con una única muestra de la agrupación, es decir, con una única instantánea (snapshot). Posee mucha mayor estabilidad estadística que los métodos incoherentes de mínima varianza, a costa de una peor resolución. Este aspecto permite una reducción del tiempo mínimo de observación necesario. Para tiempos de observación largos, las prestaciones relativas entre el remuestreo espacial y los métodos incoherentes, en general, dependerán del escenario considerado.

## 3.3.3. Estimación DOA Paramétrica

En este apartado nos centraremos en dos métodos paramétricos. Estos métodos, como ya se ha dicho, explotan el modelo de señal de una agrupación de sensores, p.ej. el dado por la *Ec.2.4.2* para una ULA. También aprovechan la naturaleza estadística del modelo. Primeramente expondremos el método de Máxima Verosimilitud (Maximum Likelihood, ML), marco de donde derivan otros muchos métodos. A continuación se expondrá otro método que introduce como novedad el uso de parámetros relativos al proceso de generación de la señal, utilizando en la estimación un criterio de mínimos cuadrados (Minimum Least Square, MLS). Este método como se verá está inspirado también en ML.

## • Método de Máxima Verosimilitud

Este método parte de la selección de una función de coste, que será minimizada o maximizada según el caso. Supongamos que intentamos estimar un parámetro de naturaleza aleatoria,  $\Theta$ , como ocurre en el caso de la búsqueda de DOAs a partir de un conjunto de datos Y=y. En estas condiciones a la función densidad de probabilidad condicional  $p(\Theta | Y=y)$  se le conoce como la densidad a posteriori, ya que la estimación está condicionada a una observación previa [Peña-Sánchez 1988]. La obtención de  $p(\Theta | Y=y)$  se efectúa por el teorema de Bayes:

$$p(\Theta | Y) = p(Y | \Theta) \frac{p(\Theta)}{p(Y)}$$

Para resolver el problema, la primera etapa requiere la determinación de una densidad de probabilidad a priori,  $p(\Theta)$  Una posible solución del problema conlleva la búsqueda del valor más probable de  $p(\Theta | Y)$ , que es su máximo. La estimación del máximo a posteriori (Maximum A Posteriori, MAP) es el valor que produce el máximo valor de la densidad de probabilidad a posteriori.

$$\nabla_{\Theta} p(\Theta \mid Y)_{\Theta = \hat{\Theta}_{MAP}}$$
 (Ec.3.3.18)

Considerando el logaritmo de la función densidad de probabilidad condicional llegamos la siguiente expresión:

$$\ln p(\Theta \mid Y) = \ln p(Y \mid \Theta) + \ln p(\Theta) - \ln p(Y)$$

Como p(Y) no es una función de  $\Theta$ , si sustituimos esta última expresión en la ecuación *Ec.3.3.18*, la podemos escribir del modo siguiente:

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos

$$\nabla_{\Theta} \ln p(\Theta \mid Y) \mid_{\Theta = \hat{\Theta}_{MAP}} = \nabla_{\Theta} \left( \ln p(Y \mid \Theta) + \ln p(\Theta) \right) \mid_{\Theta = \hat{\Theta}_{MAP}} = 0 \quad (Ec.3.3.19)$$

Si no tenemos un conocimiento previo de  $p(\Theta)$  o bien modelamos  $\Theta$  como un parámetro no aleatorio, aproximadamente constante en el intervalo de valores relevantes del parámetro, obtenemos la estimación de ML como un caso especial de la estimación MAP. En estas condiciones la ecuación *Ec.3.3.19* quedaría:

$$\nabla_{\Theta} \ln p(\Theta \mid Y) \mid_{\Theta = \hat{\Theta}_{ML}} = \nabla_{\Theta} \left( \ln p(Y \mid \Theta) \right) \mid_{\Theta = \hat{\Theta}_{ML}} = 0$$

Con el objetivo de derivar el estimador ML de las localizaciones partiremos de la expresión siguiente para una ULA, que hemos considerado como modelo de señal.

$$\mathbf{y}(t) = \mathbf{A}(\theta) \cdot \mathbf{s}(t) + \mathbf{n}(t)$$

Una deducción algo más exhaustiva es posible encontrarla en [Kay 1988] desde el punto de vista de la estimación de la potencia espectral y en [Jaffer 1992] con un enfoque DOA frente a fuentes estocásticas.

Sobre el modelo de señal anterior vamos a realizar una serie de supuestos sobre la agrupación, las señales incidentes y el ruido [Ziskind 1988].

- A1. El número de fuentes es conocido, es menor que el número de sensores, L<M, aparecen simultáneamente en el escenario y ocupan la misma banda frecuencial.
- A2. Cada uno de los M vectores de dirección son linealmente independientes.
- A3. El ruido  $\{\mathbf{n}(t)\}$  es un proceso gaussiano de valores complejos estacionario y ergódico de media nula y matriz de varianza  $\sigma^{2}_{n} \cdot \mathbf{I}$ , con un escalar  $\sigma^{2}_{n}$  de valor desconocido y  $\mathbf{I}$  es la matriz identidad.
- A4. Las muestras de ruido  $\{\mathbf{n}(t_i)\}$  son estadísticamente independientes.

Con el fin de simplificar se ha supuesto que el número de fuentes presentes en el escenario es conocido. El caso donde el número de fuentes es desconocido se recoge adecuadamente en [Wax 1984 y 1989]. Los supuestos A1 y A2 son necesarios para garantizar la unicidad de la solución. Por su parte, los supuestos A3 y A4 son los convencionales para el ruido en agrupaciones de sensores, formulados para facilitar la aplicación de la metodología ML.

Atendiendo a los supuestos A3 y A4 la función densidad de probabilidad conjunta de los datos muestreados en la agrupación serían:

$$p(Y \mid \theta) = f(\mathbf{X}) = \prod_{i=1}^{N} \frac{1}{\pi \cdot \det[\sigma_n^2 \cdot \mathbf{I}]} \exp\left[-\frac{1}{\sigma_n^2} |\mathbf{y}(t_i) - \mathbf{A}(\theta) \cdot \mathbf{s}(t_i)|^2\right]$$
(Ec.3.3.20)

donde det[] expresa determinante, M es el número de muestras de los datos observados, la matriz  $A(\theta) = [g(\theta_l), \dots, g(\theta_L)]$  representa la respuesta de la agrupación en función de  $\theta$  con  $g(\theta_k) = [g_1(\theta_k), g_2(\theta_k), \dots, g_M(\theta_k)]^T$ , donde  $g_i(\theta) = \exp\{-j\omega_0(i-1)\cdot d/c \cdot \operatorname{sen} \theta\}$  y, por último, el vector s(t) que corresponde a la señal de las fuentes. Tomando logaritmos de la expresión Ec.3.3.20 y suponiendo que las fuentes de señal se pueden considerar deterministas en su forma de onda, tendríamos la función verosimilitud para el caso determinista, DML:

$$L_{DML}\left[\theta,\sigma_n^2,\mathbf{s}(t)\right] = -M \cdot \ln(\sigma_n^2) - \frac{1}{N\sigma_n^2} \sum_{i=1}^N \left|\mathbf{y}(t_i) - \mathbf{A}(\theta) \cdot \mathbf{s}(t_i)\right|^2$$

donde los parámetros desconocidos y a estimar serían la varianza del ruido,  $\sigma^{2}_{n}$ , las fuentes en si mismas,  $\mathbf{s}(t)$ , y las DOAs de cada una de ellas,  $\theta$ . Ignorando los términos constantes, normalizando por N y atendiendo al signo de la función  $L_{DML}$ , las estimaciones se obtienen resolviendo el problema siguiente:

$$\left[\hat{\theta}, \hat{\sigma}_n^2, s(t)\right] = \arg \min_{\theta, \sigma_n^2, s(t)} \left\{ M \cdot \ln(\sigma_n^2) + \frac{1}{N \cdot \sigma_n^2} \sum_{i=1}^N \left| \mathbf{y}(t_i) - \mathbf{A}(\theta) \cdot \mathbf{s}(t_i) \right|^2 \right\}$$
(Ec.3.3.21)

El problema se puede descomponer y así se ha hecho por ejemplo en [Böhme 1984, Wax 1992] donde la minimización explícita con respecto a  $\sigma^{2}_{n}$  y  $\mathbf{s}(t)$  da como resultado:

$$\hat{\sigma}_n^2 = \frac{1}{M} \operatorname{Tr} \left( \Pi_{\mathbf{A}}^{\perp} \cdot \hat{\mathbf{R}} \right) \quad \mathbf{y} \quad \hat{\mathbf{s}} = \mathbf{A}^{\dagger} \mathbf{x}(t)$$

donde Tr(z) indica traza de la matriz z,  $\hat{\mathbf{R}}$  es la matriz de covarianzas de las muestras,  $\mathbf{A}^{\dagger}$  es la seudoinversa de  $\mathbf{A}$ , y  $\Pi_{\mathbf{A}}^{\perp}$  es la proyección ortogonal sobre el espacio vacío de  $\mathbf{A}^{+}$ , y que explicitamos a continuación en *Ec.3.3.22*.

$$\hat{\mathbf{R}} = \frac{1}{N} \sum_{i=1}^{N} \mathbf{x}(t) \cdot \mathbf{x}(t)^{+}$$

$$\mathbf{A}^{\dagger} = (\mathbf{A}^{+} \cdot \mathbf{A})^{-1} \mathbf{A}^{+}$$

$$\Pi_{A} = \mathbf{A} \cdot \mathbf{A}^{\dagger} \Longrightarrow \Pi_{A}^{\perp} = \mathbf{I} - \Pi_{A}$$
(Ec.3.3.22)

Así las cosas y sustituyendo en Ec.3.3.21, la estimación de las DOAs se obtiene resolviendo el siguiente problema de minimización:

$$\hat{\theta}_{DML} = \arg \min_{\theta} \left\{ \operatorname{Tr} \left( \Pi_{\mathbf{A}}^{\perp} \cdot \hat{\mathbf{R}} \right) \right\}$$

La otra técnica ML se denomina SML ya que se modela a la forma de onda de la señal como un proceso aleatorio gaussiano. Por lo tanto, consideramos que la forma de onda de la señal es de media nula,  $E[\mathbf{s}(t) \cdot \mathbf{s}^{T}(t)]=0$ , y varianza  $\Gamma=E[\mathbf{s}(t) \cdot \mathbf{s}^{+}(t)]$ . Esto conlleva que el vector de los observables,  $\mathbf{y}(t)$ , sea de media nula, aleatorio y gaussiano con matriz de covarianzas:

$$\mathbf{R}_{vv} = \mathbf{A}(\theta) \cdot \mathbf{\Gamma} \cdot \mathbf{A}(\theta)^{+} + \sigma^{2} \mathbf{I}$$

A partir de aquí podemos considerar para SML dos casos [Rao 1994]:

- Caso 1: Γ y σ<sup>2</sup> son desconocidos.
- Caso 2:  $\Gamma$  y  $\sigma^2$  son conocidos.

<u>Caso 1</u>: En este caso la función densidad de probabilidad conjunta condicionada a  $\theta, \Gamma$  y  $\sigma^2$  sería:

$$f(\mathbf{0}, \mathbf{\Gamma}, \sigma^2) = \frac{1}{\pi^N \cdot (\det[\mathbf{R}_{yy}])^N} \exp\left[-N \cdot \operatorname{Tr}\left(\mathbf{R}_{yy}^{-1} \cdot \hat{\mathbf{R}}_{yy}\right)\right] \qquad (Ec.3.3.23)$$

donde  $\hat{\mathbf{R}}_{yy} = \mathbf{E} \left[ \mathbf{y}(t) \cdot \mathbf{y}(t)^{+} \right]$  es la estimación de la matriz de covarianza de los sensores obtenida mediante las observaciones. Así las cosas, la estimación de los parámetros puede obtenerse mediante la resolución del problema de minimización siguiente:

$$\left[\hat{\theta}, \hat{\Gamma}, \hat{\sigma}_n^2\right] = \arg \min_{\theta, \Gamma, \sigma_n^2} \left\{-\ln f(\theta, \Gamma, \sigma^2)\right\}$$

La resolución de este problema es extremadamente complicada, sin embargo puede simplificarse si  $\mathbf{R}_{yy}$  es definida positiva,  $\sigma^2 > 0$ , y no se impone condición alguna sobre  $\Gamma$ . En tal caso el siguiente teorema, proporciona una solución para la estimación de  $\theta$ ,  $\Gamma$  y  $\sigma^2$ .

*Teorema 1*: La estimación ML de  $\theta$  basada en la función densidad de probabilidad *Ec.3.3.23* puede obtenerse resolviendo el problema de minimización:

SML1: 
$$\hat{\theta} = \arg \min_{\theta} \left\{ (M - L) \cdot \ln \operatorname{Tr} \left( \mathbf{P}_{A}^{\perp} \cdot \hat{\mathbf{R}}_{yy} \right) + \ln |\mathbf{W}_{1}| - \ln |\mathbf{W}_{2}| \right\}$$

donde  $\mathbf{P}_{A}^{\perp} = \mathbf{I}_{M} - \mathbf{A}(\theta) \cdot \mathbf{W}_{2} \cdot \mathbf{A}(\theta)^{+}, \ \mathbf{W}_{1} = \mathbf{A}(\theta)^{+} \cdot \hat{\mathbf{R}}_{yy} \cdot \mathbf{A}(\theta) \ y \ \mathbf{W}_{2} = \mathbf{A}(\theta)^{+} \cdot \mathbf{A}(\theta).$ 

La estimación SML1 para  $\hat{\sigma}^2$  y  $\hat{\Gamma}$  se obtienen a partir de las siguientes expresiones:

$$\hat{\sigma}^{2} = \frac{1}{M-L} \operatorname{Tr} \left( \mathbf{P}_{A}^{\perp} \cdot \hat{\mathbf{R}}_{yy} \right)$$
$$\hat{\mathbf{\Gamma}} = \mathbf{W}_{2}^{-1} \mathbf{A}(\hat{\theta})^{+} \left[ \hat{\mathbf{R}}_{yy} - \hat{\sigma}^{2} \cdot \mathbf{I}_{M} \right] \mathbf{A}(\hat{\theta}) \mathbf{W}_{2}^{-1}$$

<u>Caso 2</u>: En este caso, como  $\Gamma$  y  $\sigma^2$  son conocidas, la función densidad de probabilidad conjunta condicionada a  $\theta$  sería:

$$f(\mathbf{\theta}) = \frac{1}{\pi^{N} \cdot (\det[\mathbf{R}_{yy}])^{N}} \exp\left[-N \cdot \operatorname{Tr}\left(\mathbf{R}_{yy}^{-1} \cdot \hat{\mathbf{R}}_{yy}\right)\right] \qquad (Ec.3.3.24)$$

*Teorema 2*: La estimación ML de  $\theta$ , que denominaremos ML2, basada en *Ec.3.3.24* se obtiene resolviendo el siguiente problema de minimización:

$$SML2: \quad \hat{\theta} = \arg \min_{\theta} \{ L_{SML2}(\theta) \}$$

donde

$$L_{SML2}(\boldsymbol{\theta}) = N \cdot \ln \left| \mathbf{R}_{yy} \right| + N \cdot \mathrm{Tr} \left[ \mathbf{R}_{yy}^{-1} \cdot \hat{\mathbf{R}}_{yy} \right]$$

En general los estimadores ML poseen algunas propiedades interesantes: consistencia, eficiencia asintótica, además de ser asintóticamente gaussiano [Bohme 1985]. Por otro lado, estas propiedades nos avanzan la necesidad de gran cantidad de datos para poder alcanzar estimaciones con cierta credibilidad.

#### • Estimación de Máxima Verosimilitud en la Localización de Fuentes Autorregresivas de Banda Estrecha.

En este mismo ámbito de los métodos paramétricos existe otro enfoque que no entra directamente dentro del conjunto de métodos ML sino que necesita un mayor elaboración. La metodología en cuestión usa parámetros de la fuente, concretamente sus coeficientes autorregresivos (AR) para reconstruir el modelo de señal a partir del que se realiza la estimación de la DOA o las DOAs mediante la aplicación de un criterio de Mínimos Cuadrados, LS. En principio un hándicap sería que aplicar esta metodología en un solo paso hace necesario tener un conocimiento previo de los modelos AR de las fuentes a localizar, salvo que a priori se tenga un conjunto de fuentes determinadas sobre las que se quiere trabajar.

Un enfoque desde este punto de vista lo podemos encontrar en [Satish 1994] donde se aborda simultáneamente la estimación DOA y de los parámetros AR de las fuentes. No obstante, un enfoque más completo en lo referente a cómo incluir Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos

en el modelo los parámetros de la fuente se propuso con anterioridad en [Ziskind 1992] y, por tanteo, lo tomaremos como referencia.

Como ya hemos establecido en apartados anteriores, y recordamos brevemente aquí, la envolvente compleja de las señales recibidas por una agrupación lineal de M sensores, sobre la que inciden las señales procedentes de L fuentes, viene dada por:

$$\mathbf{y}_0(t) = \sum_{k=1}^{L} \mathbf{g}(\theta_k) \cdot s_k(t) + \mathbf{n}_0(t)$$

donde el vector salida de la agrupación es  $\mathbf{y}_0(t) = [y_1(t), y_2(t), \dots, y_M(t)]^T$  y la respuesta de los sensores  $\mathbf{g}(\theta_k) = [g_1(\theta_k), g_2(\theta_k), \dots, g_M(\theta_k)]^T$ , con  $g_i(\theta_k) = c_i(\theta_k) \exp[-j\omega\tau_i(\theta_k)]$ . Si suponemos que todos los sensores presentan respuesta plana en amplitud, lineal en fase y directividad omnidireccional, entonces:  $g_i(\theta_k) = \exp[-j\omega\tau_i(\theta_k)]$ . Recordamos que  $\tau_i(\theta_k)$  es el retardo de propagación entre el sensor *i*-ésimo y el sensor tomado como referencia. En forma matricial esto mismo es posible representarlo del modo siguiente, donde nos encontramos nuevamente con nuestro modelo de partida (*Ec.2.4.2*) algo más desarrollado:

$$\mathbf{y}_0(t) = \mathbf{A}(\mathbf{\theta}) \cdot \mathbf{s}_0(t) + \mathbf{n}_0(t)$$

$$\operatorname{con} \boldsymbol{\theta} = \begin{bmatrix} \theta_1, \theta_2, \dots, \theta_L \end{bmatrix}, \mathbf{A}(\boldsymbol{\theta}) = \begin{bmatrix} \mathbf{g}(\theta_1), \mathbf{g}(\theta_2), \dots, \mathbf{g}(\theta_L) \end{bmatrix} \mathbf{y} \mathbf{s}_0(t) = \begin{bmatrix} s_1(t), s_2(t), \dots, s_L(t) \end{bmatrix}^T$$
$$\begin{pmatrix} y_1(t) \\ \cdot \\ \cdot \\ y_M(t) \end{pmatrix} = \begin{pmatrix} g_1(\theta_1) & g_1(\theta_2) & g_1(\theta_L) \\ g_2(\theta_1) & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ g_M(\theta_1) & \cdot & \cdot & g_M(\theta_L) \end{pmatrix} \begin{pmatrix} s_1(t) \\ \cdot \\ s_L(t) \end{pmatrix} + n_0(t)$$

Supongamos ahora que disponemos de información adicional. Las señales procedentes de cada una de las fuentes son procesos AR, es decir, son modelables mediante procesos autorregresivos distintos para cada fuente [Kay 1988]. Considerando  $d_i$  como el orden del proceso de la señal i y los  $a_{ik}$  como los coeficientes para la señal i, podríamos representar a cada señal del modo siguiente:

$$s_{i}(t) = \sum_{n=1}^{d_{i}} a_{in} \cdot s_{i}(t - nT_{s}) + \varepsilon_{i}(t)$$
 (Ec.3.3.25)

donde  $\varepsilon_i(t)$  representa un proceso estacionario blanco de media nula y  $T_s$  es un retardo relacionado con el ancho de banda de la señal (p.ej., a través de la frecuencia de muestreo F<sub>s</sub>). Si consideramos el muestreo en espacio y tiempo de la



Figura 3.3.6. Interpretación gráfica del término agrupación extendida.

señal recibida, cómo indica Ec.3.3.25, se origina lo que se denomina en [Ziskind 1992] agrupación extendida con intervalo de muestreo  $T_s$ .

En la Figura 3.6.6 se representa el resultado de tomar a la agrupación según la expresión Ec.3.3.25. El término agrupación extendida viene a indicar que la introducción de más información sobre la señal, coeficientes  $a_{in}$ , conlleva un incremento adicional de los datos disponibles al realizar una instantánea del campo proporcional a d (orden del proceso).

Si tomamos el número de elementos de retardo d, tal que  $d \ge max_i\{d_i\}$ , es posible reescribir la expresión Ec.3.3.25 del modo siguiente:

$$s_i(t) = \sum_{n=1}^d a_{in} \cdot s_i(t - nT_s) + \varepsilon_i(t)$$

Con ayuda de la Figura 3.3.6 es posible deducir la señal recibida en el m-ésimo elemento de la agrupación extendida. Dependiendo del valor de m podría ser de alguno de los dos modos siguientes:

$$y_m(t) = \sum_{i=1}^{L} g_m(\theta_i) \cdot s_i(t) + n_m(t) \qquad \text{para } 1 \le m \le M$$

$$y_m(t) = \sum_{i=1}^{L} g_m(\theta_i) \cdot s_i(t - lT_s) + n_m(t) \text{ para } M < m \le M(d+1) \text{ y } l = \left\lfloor \frac{m-1}{M} \right\rfloor$$

donde  $\lfloor r \rfloor$  indica el mayor de los enteros que es menor o igual a r. En el instante t en el sensor m-ésimo tenemos contribuciones de todas las fuentes. Como habíamos convenido en la posibilidad de representar a las señales mediante su modelo autorregresivo, añadamos los coeficientes:

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos

$$y_m(t) = \sum_{n=1}^d \sum_{i=1}^L g_m(\theta_i) \cdot a_{in} \cdot s_i(t - nT_s) + \sum_{i=1}^L g_m(\theta_i) \cdot \varepsilon_i(t) + n_m(t) \text{ para } 1 \le m \le M$$

Dada la complejidad de la expresión, ya que hemos de distinguir claramente entre unos y otros valores del índice m, optamos por separar la expresión en dos partes para una mayor claridad.

$$y_m(t) = \sum_{i=1}^{L} g_m(\theta_i) \cdot s_i(t - lT_s) + n_m(t)$$

Esta última expresión será válida para los valores siguientes de *m*:

$$M < m \le M(d+1)$$
 y  $l = \left\lfloor \frac{m-1}{M} \right\rfloor$ 

En forma matricial la señal recibida por la agrupación extendida será:

$$\mathbf{y}(t) = \mathbf{A}(a,\theta) \cdot \mathbf{s}_0(t) + \mathbf{B}(\theta) \cdot \mathbf{\varepsilon}(t) + \mathbf{n} (t)$$

con  $\mathbf{y}(t) = \begin{bmatrix} \mathbf{y}_0^T(t), \dots, \mathbf{y}_d^T(t) \end{bmatrix}^T$ ,  $\mathbf{y}_k(t) = \begin{bmatrix} y_{kM+1}(t), \dots, y_{kM+M}(t) \end{bmatrix}^T$ ,  $\mathbf{s}(t) = \begin{bmatrix} \mathbf{s}_1^T(t), \dots, \mathbf{s}_L^T(t)^T \end{bmatrix}^T$  y  $s_k(t) = \begin{bmatrix} s_1(t-kT_s), s_2(t-kT_s), \dots, s_L(t-kT_s) \end{bmatrix}^T$ . La matriz  $\mathbf{A}(a, \theta)$  es una matriz de dimensión  $M(d+1) \times Ld$  de concepción especial, al estar compuesta de  $(d+1) \times d$  bloques de matrices de dimensión  $M \times L$ , tal y como se refleja en la expressión siguiente:

$$\mathbf{A}(a,\theta) = \begin{bmatrix} \mathbf{A}_{1,1}(a,\theta) & \mathbf{A}_{1,2}(a,\theta) & \cdots & \mathbf{A}_{1,d}(a,\theta) \\ \mathbf{A}(\theta) & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{A}(\theta) & \cdots & \mathbf{0} \\ \vdots & & & \\ \vdots & & & \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{A}(\theta) \end{bmatrix}$$

con  $\mathbf{A}_{1,k}(a,\theta) = [a_{1k}\mathbf{g}(\theta_1), a_{2k}\mathbf{g}(\theta_2), \dots, a_{Lk}\mathbf{g}(\theta_L)]$  y  $\mathbf{A}(\theta)$  que en este contexto es una matriz  $M \times L$  dada por  $\mathbf{A}(\theta) = [\mathbf{g}(\theta_1), \mathbf{g}(\theta_2), \dots, \mathbf{g}(\theta_L)]$  y  $\mathbf{g}(\theta_k) = [g_1(\theta_k), \dots, g_M(\theta_k)]^T$ . La matriz  $\mathbf{B}(\theta)$  viene dada por  $\mathbf{B}(\theta) = [\mathbf{A}^T(\theta), \mathbf{0}^T, \dots, \mathbf{0}^T]^T$  donde las matrices  $\mathbf{A}(\theta)$  y las de ceros,  $\mathbf{0}$ , tienen dimensiones  $M \times L$ .
Por ejemplo, para una agrupación de 2 sensores (M = 2), escenario con dos fuentes (L = 2) y procesos autorregresivos de orden dos (d = 2):

$$\mathbf{A}(a,\theta) = \begin{bmatrix} g_1(\theta_1) \cdot a_{11} & g_1(\theta_2) \cdot a_{21} & g_1(\theta_1) \cdot a_{12} & g_1(\theta_2) \cdot a_{22} \\ g_2(\theta_1) \cdot a_{11} & g_2(\theta_2) \cdot a_{21} & g_2(\theta_1) \cdot a_{12} & g_2(\theta_2) \cdot a_{22} \\ g_1(\theta_1) & g_1(\theta_2) & 0 & 0 \\ g_2(\theta_1) & g_2(\theta_2) & 0 & 0 \\ 0 & 0 & g_1(\theta_1) & g_1(\theta_2) \\ 0 & 0 & g_2(\theta_1) & g_2(\theta_2) \end{bmatrix}$$

En general es posible referirse a las M(d+1) columnas de  $A(a, \theta)$  y de  $B(\theta)$  como vectores de apuntamiento de la agrupación extendida en la dirección  $\theta$ . En nuestro caso estos vectores dependen de los parámetros AR.

Recordemos que nuestro problema es la obtención de la DOA. Por tanto, tenemos que estimar las direcciones  $\theta_1, \theta_2, ..., \theta_L$  a partir del muestreo realizado por nuestra agrupación  $y(t_1), ..., y(t_n)$ , "snapshot".

En el planteamiento del problema se harán los siguientes supuestos:

- A1. Se conoce el número de fuentes y el orden de los procesos.
- A2. Los M(d+1) vectores de apuntamiento de cada conjunto son linealmente independientes.
- A3. El número de fuentes que es posible resolver de be satisfacer:  $L \leq M(d+1)/2$ .
- **A4.** Las muestras de ruido  $\{\mathbf{n}(t_1)\}$  son vectores complejos de media nula con varianza  $\sigma^2 \cdot \mathbf{I}$ .

El procedimiento de estimación una vez establecido el problema, ya sabemos, empieza con la obtención de una función de coste mediante algún criterio. En este caso en [Ziskind 1992] se utiliza un procedimiento derivado del criterio de mínimos cuadrados (MLS, Minimum Least Squares):

$$\min \left\| E\left\{ \left[ \mathbf{y}(t) - \mathbf{A}(a,\theta) \cdot \mathbf{s}(t) - \mathbf{B}(\theta) \cdot \mathbf{\epsilon}(t) \right] \left[ \mathbf{y}(t) - \mathbf{A}(a,\theta) \cdot \mathbf{s}(t) - \mathbf{B}(\theta) \cdot \mathbf{\epsilon}(t) \right]^{H} \right\} \right\|_{(Ec.3.3.26)}$$

donde  $\|\cdot\|_{F}$  indica norma de Frobenius, es decir:  $\|X\|_{F} = suma (traza(X^{H} \cdot X))$ .

Desarrollando la operación entre llaves y haciendo uso de los supuestos A1 hasta A4, la expresión Ec.3.3.26 se reduce a la siguiente:

$$\min \left\| \left\{ \mathbf{R}_{y} - \mathbf{A}(a,\theta) \cdot \mathbf{P}_{s} \cdot \mathbf{A}^{H}(a,\theta) - \mathbf{B}(\theta) \cdot \mathbf{P}_{s} \cdot \mathbf{B}^{H}(\theta) \right\} \right\|_{F}$$
(Ec.3.3.27)

donde  $\mathbf{P}_s = \mathbb{E}[\mathbf{s}(t) : \mathbf{s}^H(t)], \mathbf{P}_s = \mathbb{E}[\mathbf{s}(t) : \mathbf{s}^H(t)] \neq \mathbf{R}_y = \mathbb{E}[\mathbf{y}(t) : \mathbf{y}^H(t)].$ 

La ecuación Ec.3.3.27 implica que el criterio de estimación no es otra cosa que encontrar la máxima igualdad entre  $\mathbf{R}_{y}$ , matriz de covarianzas y la matriz de covarianzas del modelo, definida como:

$$\mathbf{R}_{\text{modelo}} = \mathbf{A}(a,\theta) \cdot \mathbf{P}_{s} \cdot \mathbf{A}^{H}(a,\theta) - \mathbf{B}(\theta) \cdot \mathbf{P}_{s} \cdot \mathbf{B}^{H}(\theta)$$

Como la matriz de covarianzas de las muestras,  $\mathbf{R}_{y}$ , no se conoce la aproximaremos mediante:

$$\hat{\mathbf{R}}_{y} = \frac{1}{N} \sum_{j=1}^{N} \mathbf{y}(t_{j}) \cdot \mathbf{y}^{H}(t_{j})$$

Así *Ec.3.3.27* quedaría:

$$\min \left\| \hat{\mathbf{R}}_{y} - \mathbf{R}_{\text{modelo}} \right\|_{F}$$
 (Ec. 3.3.28)

Los parámetros a priori desconocidos sobre los cuales minimizamos son: espaciales  $\theta$ , espectrales a, y las correlaciones de señal  $\mathbf{P}_s$  y ruido  $\mathbf{P}_s$ . Cuando, como en este caso, el número de parámetros a estimar es grande la capacidad de computación necesaria se hace prohibitiva y se debe recurrir a procedimientos subóptimos.

En este caso se propone abordar el problema mediante el uso de un procedimiento MLS en dos etapas. En una primera etapa estimamos los parámetros AR  $(a_{in})$ . La segunda etapa se inicia con la expresión de  $\mathbf{P}_s$  y  $\mathbf{P}_{\varepsilon}$  como función de los parámetros espectrales  $a_{in}$  estimados y los  $\theta$  desconocidos. Seguidamente buscamos los  $\theta$  que minimizan Ec.3.3.28. Al expresar  $\mathbf{P}_s$  y  $\mathbf{P}_{\varepsilon}$  como una función de  $\theta$  es posible realizar la búsqueda del mínimo únicamente sobre  $\theta$ . Aunando la definición de  $\mathbf{s}(t)$  y  $\mathbf{P}_s$ , y el supuesto A4, es posible observar que los elementos de  $\mathbf{P}_s$  forman un matriz simétrica ( $L d \ x \ L d$ ) que puede subdividirse en bloques diagonales  $d \times d$ . Por ejemplo, para L=2 y d=2, tendríamos:

$$\mathbf{P}_{s} = \mathbf{E} \left\{ \begin{bmatrix} s_{1}(T_{s}) \\ s_{2}(T_{s}) \\ s_{1}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \end{bmatrix}_{4 \times 1} \begin{bmatrix} s^{*}_{1}(T_{s}) & s^{*}_{2}(T_{s}) & s^{*}_{1}(2 \cdot T_{s}) & s^{*}_{2}(2 \cdot T_{s}) \end{bmatrix}_{1 \times 4} \right\} =$$

$$\mathsf{E} \left\{ \begin{bmatrix} s_{1}(T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{1}(T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{2}(T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{1}(2 \cdot T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{1}(2 \cdot T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) & s_{2}(2 \cdot T_{s}) \cdot s_{2}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{s}) \cdot s_{1}^{*}(2 \cdot T_{s}) \\ s_{2}(2 \cdot T_{$$

Con  $s_1(n \cdot Ts) = s_1(t \cdot n \cdot Ts)$ , siendo *n* un número entero, positivo y mayor o igual a cero. Así las cosas los elementos del *i*-ésimo bloque de la matriz pueden expresarse mediante:

$$p_{lk} \equiv p_i((|l-k|)T_s) \equiv \mathbb{E}\left[s_i(l\cdot Ts)s^*_i(k\cdot T_s)\right]$$
  

$$i = 1, \dots, L \ ; \ l, k = 1, \dots, d$$
(Ec.3.3.29)

Igualmente podemos expresar los elementos de la diagonal de la matriz  $\mathbf{P}_{\varepsilon}$ ,  $\sigma^2_{\varepsilon}$ , como:

$$\sigma_{\varepsilon i}^{2} = p_{i}(0) - \sum_{n=1}^{di} a_{in} \cdot p_{i}(k \cdot T_{s})$$
 (Ec.3.3.30)

Según las expresiones Ec.3.3.29 y Ec.3.3.30 se obtendrán unas matrices  $\mathbf{P}_s$  y  $\mathbf{P}_s$  con una considerable reducción en el número de parámetros sobre los que aplicar la minimización. Los únicos parámetros desconocidos son  $\theta_i$  y  $p_i(0)$  (para i = 1,..,L).

El siguiente paso de la minimización es encontrar el óptimo  $p_i(0)$ . Esto se hace minimizando  $p_i(0)$  sujeto a la restricción:

$$\sum_{i=1}^{L} p_i(0) \approx \frac{1}{M(d+1)} \sum_{m=1}^{M(d+1)} (\hat{\mathbf{R}}_y)_{mm}$$

Con  $(\mathbf{R}_{y})_{mm}$  expresamos el *m*-ésimo elemento de la diagonal de la matriz de covarianzas. En nuestro caso, al desconocerla, tendremos que utilizar la correspondiente a la muestra. La validez de esta aproximación depende de la relación señal a ruido. El conjunto de los  $\{p_i(0)\}$  óptimos derivados de esa forma son función de  $\theta$ . La etapa final del procedimiento de estimación consiste en buscar el mínimo de *Ec.3.3.28* para cualquier valor de  $\theta$ .

# 3.4 El Problema del Seguimiento de Móviles y Aproximación mediante Medidas de DOA

Una extensión natural y necesaria del problema de DOA descrito en el apartado 3.3 consiste en utilizar las medidas de 'localización' angular para hacer un seguimiento tomando estas posiciones como base. En primer lugar necesitamos un modelo de observación. Esto es lo que hacemos en el primer subapartado donde necesitamos considerar cómo esperamos que se mueva la fuente y el hecho particular de que la información base va a estar constituida por estimaciones de



Figura 3.4.1. Escenario con parámetros del seguimiento para la fuente k-ésima.

DOA. En el siguiente subapartado incorporamos, por conveniencia, de forma simultánea dos elementos. De un lado, un aparato matemático basado en el concepto de vector de estados mediante filtrado de Kalman. Y de otro, las medidas en forma de direcciones de llegada.

### 3.4.1. El Modelo de Observación

Visto de forma general, el problema del seguimiento de fuentes de señal en movimiento, mediante una agrupación pasiva de sensores concentrada y estática, plantea describir el movimiento de una fuente emisora y de esta descripción obtener una evolución de las localizaciones de la fuente, Figura 3.4.1. Para hacerlo con fidelidad es necesario conocer o al menos estimar el conjunto de parámetros  $\{r_k(t), \theta_k(t), \phi_k(t), v_k(t), \alpha_k(t)\}$ , donde  $r_k(t)$  es la distancia respecto de un origen de coordenadas,  $\theta_k(t)$  es la DOA,  $\phi_k(t)$  es el sentido del movimiento,  $v_k(t)$  es la velocidad y, por último,  $a_k(t)$  es la aceleración. Según la aplicación considerada puede ser necesario determinar la totalidad de los parámetros, p.ej. en aplicaciones tales como el seguimiento de cohetes en misiones espaciales. Sin embargo, en otras, p.ej. estudio del comportamiento y censo de cetáceos como los cachalotes bastaría con la DOA y la distancia, si bien esta última depende mucho de las condiciones de propagación pues puede haber una curvatura en el camino recorrido que haga diferir de forma apreciable la distancia en línea recta respecto de la trayectoria. Estimar la distancia real que separa a una sola agrupación de sensores concentrada y una fuente, sólo es factible si tenemos una idea precisa o certera del valor de la potencia con que emite la fuente, más un conocimiento cuasi exacto de la propagación de la señal desde la fuente a la agrupación. Existen aplicaciones, p.ej. seguimiento de cachalotes [Nielsen 2006, Nosal 2006], donde el conocimiento exacto de la distancia no es de vital importancia, en estos

casos una buena aproximación en base a conocer la potencia de emisión y el modelo de la propagación son más que suficientes para estimar la distancia. Por este motivo, nuestro trabajo sobre localización de cachalotes se centra en la estimación de DOA.

Este problema se puede plantear a varios niveles. Un primer nivel puede ser aquel donde se lleva a cabo la localización espacial, es decir, estimación de las coordenadas cartesianas o polares, de la fuente de señal, apoyados en el análisis de las muestras de datos para distintos instantes. Obtendríamos así una *trayectoria discreta*, al obtenerse la misma como resultado de un muestreo del campo creado por las fuentes en determinados instantes (p.ej., de forma periódica, según llegan señales). A través de los datos recopilados también sería posible una estimación de la velocidad e incluso de la aceleración.

El planteamiento hecho en el párrafo anterior lleva a una sucesión de posiciones sin conexión explícita entre sí y con la esperanza de que las estimas sean buenas (p.ej., cumplen unas especificaciones previamente fijadas). Si, como ocurre en muchas aplicaciones, dichas estimas no son suficientemente buenas hemos de ir más allá. Estamos hablando de incorporar un nivel superior de conocimiento en el que aportamos nuestro conocimiento acerca del modelo de movimiento de la fuente.

La determinación de los ángulos, acimut y o elevación, se puede llevar a cabo con cualquiera de los métodos de estimación DOA expuestos en el apartado 3.3. Sin embargo, a este respecto ya apuntábamos que hay una dificultad añadida cuando las estimaciones no son suficientemente buenas. Concretando más, si la fuente se desplaza con rapidez suficiente, la observación no podrá considerarse estacionaria en su conjunto, hecho que será fuente de error.

Esto trae consigo un empeoramiento en la resolución, debido a la dispersión del espectro espacial como consecuencia del movimiento de la fuente. En [Zhou 1999] se hace un estudio al respecto, donde aprecian tres cuestiones de interés. Una primera es que la resolución empeora cuando se incrementa el número de sensores, fenómeno totalmente en contra de lo que ocurre cuando las fuentes son estacionarias. La segunda es que se produce un ensanchamiento y un desplazamiento del lóbulo principal cuando crece el tamaño de la muestra. La tercera, y última, apreciación reviste gran importancia por su consecuencia directa, y es que el movimiento de las fuentes tiende a incrementar el rango de la matriz de covarianza de la agrupación. El resultado inmediato de este hecho es un cambio en la distribución de los autovalores, con tendencia a difuminar la frontera entre los autovalores del espacio de señal y del espacio de ruido. Esto trae consigo la detección errónea de un mayor número de fuentes.

Cuando en el escenario hay más de una fuente el problema que se presenta es decidir cómo asociar los ángulos de incidencia estimados, DOAs, con cada una de las fuentes presentes en el escenario. En este sentido aparece un problema añadido que ocurre cuando dos fuentes se cruzan y hay que decidir la trayectoria que sigue cada una.

Avancemos un poco más en la visión del modelo de observación. Uno de los modelos de señal para una agrupación de sensores aplicada al seguimiento de

fuentes más aceptado, es el de la ecuación Ec.3.4.1 que incluye en el mismo modelo la dinámica del movimiento [Zhou 1999].

$$\mathbf{y}(t) = \mathbf{A}[\mathbf{\theta}(t)] \cdot \mathbf{s}(t) + \mathbf{n}(t)$$
 (Ec.3.4.1)

Suponiendo un escenario de seguimiento compuesto por una agrupación de M sensores, que en principio podemos suponer una ULA, sobre la que inciden L fuentes, en la *Ec.3.4.1* tenemos que  $\mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_M(t)]^T$  es el vector de las salidas de cada uno de los sensores,  $\mathbf{n}(t) = [n_1(t), n_2(t), \dots, n_M(t)]^T$  es el vector de ruido aditivo presente en cada sensor,  $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_r(t)]^T$  el vector de señales,  $\boldsymbol{\theta}(t) = [\theta_1(t), \theta_2(t), \dots, \theta_T(t)]^T$  es el vector de las DOAs de las fuentes,  $\mathbf{A}[\boldsymbol{\theta}(t)]$ es la matriz de dirección de la agrupación, que viene determinada por la geometría de la agrupación y las DOAs de las fuentes, donde su columna k-ésima contiene el vector de apuntamiento asociado a la fuente k-ésima dado por  $\mathbf{g}[\mathbf{\theta}_{k}(t)] = \left\{1, \exp[j\omega_{0}\tau_{k2}(t)], \dots, \exp[j\omega_{0}\tau_{kM}(t)]\right\}^{T}, \text{ donde } \omega_{0} \text{ es la frecuencia de la señal}$ de la *k*-ésima fuente,  $x_m$ es la posición del *m*-ésimo sensor y  $\tau_{km}(t) = (1/c) \cdot x_m \cdot \operatorname{sen} \theta_k(t)$  representa el retardo relativo inducido por la k-ésima señal en el *m*-ésimo sensor con respecto al origen de coordenadas del sistema.

Los métodos empleados en las aproximaciones a la solución del problema del seguimiento de fuentes se pueden agrupar en métodos Bayesianos y No Bayesianos [Bar-Shalom 1978]. Otra forma de agruparlos según [Sword 1990] sería en base a que el método use vectores de estados, posiciones y velocidades de las fuentes, principalmente, o métodos que hacen seguimiento del ángulo de la fuente, de manera que emplean las señales recibidas de las fuentes para seguir sus ángulos con respecto a una referencia fija.

A la hora de diseñar los algoritmos, un enfoque típico es el de hacerlo mediante varios bloques como por ejemplo [Cevher 2007] usando beamforming para la estimación DOA y filtro de partículas para la ecuación de estados. En [Moran 1991] emplean tres subsistemas que trabajan en paralelo uno especializado en la detección, otro en el seguimiento la DOA y otro en el seguimiento de la distancia. La técnica de beamforming adaptativa se emplea en [Affes 1996] tanto para la estimación de DOA como para la de la velocidad, añadiendo también mecanismos para la identificación del canal y la detección de los cruces entre fuentes en movimiento.

Hay métodos que no necesitan a priori un conocimiento del número de fuentes presentes en el escenario, para ello utilizan una etapa inicial especializada en la estimación del número de fuentes y sus posiciones iniciales, para ello emplean, por ejemplo, MUSIC [Sword 1990, Sastry 1991, Satish 1995].

Las técnicas optimización clásicas tales como la de Newton en [Zhou 1999] o la de gradiente conjugado en [Sastry 1991] tienen aquí aplicación ya que en muchos casos el planteamiento realizado conduce a formulaciones no resolubles analíticamente.

## 3.4.2. Seguimiento basado en un Vector de Estados y Medidas Relacionadas con la DOA

Vamos a describir en esta sección un algoritmo de seguimiento compuesto de varias etapas [Rao 1994], para ello primeramente supondremos que el número de fuentes en movimiento presentes en el escenario, no cambia durante un periodo de seguimiento dado.

La aplicación del filtrado de Kalman, en base a un enfoque de vectores de estados, lo podemos encontrar en [Zhou 1999] y en [Riba 1996]. Hay enfoques donde a partir del modelo de señal se busca el incremento de la DOA, en lugar de directamente la DOA, en estos casos se explota la diferencia entre las matrices de covarianzas consecutivas [Sword 1990, Sastry 1991]. Es interesante destacar el empleo en estos casos de desarrollos en serie como el de Taylor en la búsqueda de los incrementos angulares [Satish 1995]. La opción de la descomposición de la matriz de covarianzas se explota en [Rao 1994] para determinar la DOA, introduciendo además reglas heurísticas que permitan asociar una trayectoria concreta con una DOA estimada. El empleo de la estimación ML la podemos encontrar en [Zhou 1999] asociado a una función de estados donde se incluyen ángulo, velocidad y aceleración. También en [Satish 1994] la estimación de la DOA mediante un enfoque que conjuga ML con la estimación de los parámetros AR de cada fuente detectada, de ese modo asocian cada DOA con su fuente. En el caso de sistemas emitiendo señales con ciertas propiedades se explota el concepto de cicloestacionariedad [Riba 1996].

Una observación importante, explotada en varios de las metodologías es la de considerar a la fuentes como cuasi estacionarias durante un intervalo de tiempo de integración limitado. Es, por ejemplo, el caso que nos ocupa en esta tesis para el seguimiento de cachalotes.

El problema de la asociación entre DOA y trayectoria se aborda en [Satish 1995, Zhou 1999], estos autores obtienen estimas implícitas de DOA y trayectoria. Sin embargo, el problema se puede abordar también de otras maneras. Por ejemplo, un primer enfoque podría partir del empleo de métodos de Asociación Probabilística. Estos estiman los estados sumando la totalidad de las hipótesis de asociación ponderadas mediante un conjunto de probabilidades derivadas de un enfoque de verosimilitud. En segundo ejemplo sería el empleo de supuestos de suavizado sobre los estados de la fuente en movimiento, lo que permite un ordenamiento natural de los datos. Un tercer ejemplo sería el de los métodos ML/EM que usan la función verosimilitud para buscar un máximo global. Y por último, están aquellos métodos heurísticos que emplean algoritmos del tipo vecino más próximo.

A continuación, vamos a describir someramente los elementos del escenario y la notación a emplear. Consideramos un escenario con una agrupación pasiva de M sensores omnidireccionales uniformemente espaciados una distancia d metros, como por ejemplo la ULA de la Figura 3.4.1. También consideramos la presencia de L fuentes móviles, tal que  $L \leq M$ -1. Estas fuentes se mueven en un plano con aceleraciones constantes sujetas a pequeñas perturbaciones. Suponemos que el

movimiento de la i-ésima fuente puede ser modelado mediante la ecuación Ec.3.4.2.

$$\mathbf{x}_{i}(k+1) = \mathbf{F} \cdot \mathbf{x}_{i}(k) + \mathbf{w}_{i}(k)$$
(Ec.3.4.2)

donde el vector  $\mathbf{x}_{i}(k)$  representa el estado de la *i*-ésima fuente móvil en el instante k dado por:

$$\mathbf{x}_{i}(k) = \begin{bmatrix} \theta_{i}(k) \\ \dot{\theta}_{i}(k) \\ \ddot{\theta}_{i}(k) \end{bmatrix}, \qquad i = 1, 2, \dots L$$

Se trata de un vector de estados en términos de las DOAs  $\theta_i(k)$ , las velocidades  $\dot{\theta}_i(k)$  y las aceleraciones  $\ddot{\theta}_i(k)$ . Siguiendo con la ecuación *Ec.3.4.2*, encontramos que la matriz **F** que se expresa del modo siguiente [Singer 1970]:

$$\mathbf{F} = \begin{bmatrix} 1 & T & \frac{T^2}{2} \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}$$
(Ec.3.4.3)

donde *T* indica intervalo de muestreo usado para determinar el estado en el instante *k*. Hemos de precisar que el modelo de Singer fue desarrollado para fuentes en movimiento que podemos describir en función de posición, velocidad y aceleración y que veremos con más detalle en 4.4.3. Aquí usaremos la versión simple expresada anteriormente en *Ec.3.4.3*. Además, en *Ec.3.4.2* tenemos el vector  $\mathbf{w}_i(k)=[w_{i1}(k) \ w_{i2}(k) \ w_{i3}(k)]^T$ , para i = 1, 2, ..., L, que representa las perturbaciones aleatorias sufridas por la aceleración en cada una de las trayectorias. Asumimos aceleración constante durante el intervalo de muestreo, pudiendo diferir de un intervalo a otro como consecuencia de las mencionadas perturbaciones. Para ello modelamos  $\mathbf{w}_i(k)$  como un proceso de ruido blanco gaussiano de media nula con covarianzas :  $\mathbf{E}[\mathbf{w}_i(k), \mathbf{w}_i(k)^T] = Q_i, i=1,2,...,L$ .

Denominamos a  $\hat{\theta}_i(k)$  como la estimación, pudiéndose aplicar cualquier algoritmo de estimación de DOA según vimos en el apartado 3.3.3 de esta tesis, de entre los métodos conocidos. También podríamos usar el algoritmo de estimación DOA desarrollado en esta tesis, apartado 3.6. Esta estimación está basada en los datos obtenidos en la agrupación de sensores, Ec.3.4.1, en el intervalo [kT, (k+1)T]. Esto nos conduce a la ecuación de medidas:

$$\hat{\theta}_i(k) = \theta_i(k) + \eta_i(k), \qquad i = 1, 2, \dots, L$$
 (Ec.3.4.3)

El escenario expuesto hasta el párrafo anterior es válido en muchos casos y requiere de un modelo matemático que nos permita trabajar. Esto puede venir de la mano del modelado (o filtrado) de Kalman [Welch 2001] que es el que asumimos. Veamos cómo se trata este tema. Basados en el modelo dinámico de Ec.3.4.2 y tratando las estimas  $\hat{\theta}(k)$  como medidas, tal y como aparece en Ec.3.4.3, construimos un filtro de Kalman para estimar los estados  $\mathbf{x}_i(k)$  de las fuentes móviles.

Introduzcamos primero un poco de nomenclatura. Mediante  $\hat{\mathbf{x}}_{i}(k|k-1)$  nos referimos al valor predicho de  $\mathbf{x}_i(k)$  basado en las medidas (estimaciones mediante algún algoritmo DOA) hasta el instante temporal (k-1). Tomamos  $\mathbf{P}_{i}(k \mid k-1)$  como la matriz de covarianzas del error de predicción  $\mathbf{x}_{i}(k) - \hat{\mathbf{x}}_{i}(k \mid k-1)$ . El valor estimado y filtrada de  $\mathbf{x}_{i}(k)$  basada en las medidas hasta el instante k se indicará mediante  $\hat{\mathbf{x}}_{i}(k|k)$ . La matriz de covarianzas del error de filtrado  $\hat{\boldsymbol{\theta}}(k)$ .  $\hat{\boldsymbol{\theta}}(k \mid k) \mathbf{v}$  $\mathbf{x}_{i}(k) - \hat{\mathbf{x}}_{i}(k|k)$ representa como  $\mathbf{P}_{i}(k \mid k).$ Mediante se  $\hat{\theta}(k \mid k-1)$  hacemos referencia a los vectores de longitud L siguientes:

$$\hat{\boldsymbol{\theta}}(k) = \left[\hat{\theta}_{1}(k), \hat{\theta}_{2}(k), \dots, \hat{\theta}_{L}(k)\right]^{T}$$
$$\hat{\boldsymbol{\theta}}(k \mid k) = \left[\hat{\theta}_{1}(k \mid k), \hat{\theta}_{2}(k \mid k), \dots, \hat{\theta}_{L}(k \mid k)\right]^{T}$$
$$\hat{\boldsymbol{\theta}}(k \mid k-1) = \left[\hat{\theta}_{1}(k \mid k-1), \hat{\theta}_{2}(k \mid k-1), \dots, \hat{\theta}_{L}(k \mid k-1)\right]^{T}$$

Suponemos también que respecto al modelo de señal, *Ec.3.4.1*, la matriz de covarianzas de las fuentes móviles  $\Gamma = E[\mathbf{s}_i(k), \mathbf{s}_i(k)^T]$  y la varianza del ruido  $\mathbf{n}(t)$ ,  $\sigma^2$ , permanecen inalteradas a lo largo del periodo de seguimiento.

Una vez presentada la nomenclatura a emplear y realizadas las consideraciones sobre los modelos de señal y de seguimiento, así como el escenario, vamos a continuación a exponer las distintas etapas del algoritmo de seguimiento. Primeramente, hemos de puntualizar que la implementación de las recursiones del filtrado de Kalman necesita una estimación inicial de  $\mathbf{x}_i(k)$  y las covarianzas de sus errores. Por ello, las tres primeras etapas del algoritmo se dedicaran a esta tarea.

<u>Etapa 1</u>: Sobre el primer intervalo [0,T) que se corresponde con k=0, obtenemos M capturas de señal, una por cada sensor de la agrupación. Sobre este conjunto de datos aplicamos un algoritmo de estimación de DOA que permita estimar en k=0:

$$\hat{\boldsymbol{\theta}}(0) = \left[\hat{\theta}_{1}(0), \hat{\theta}_{2}(0), \dots, \hat{\theta}_{L}(0)\right]^{T}, \hat{\boldsymbol{\Gamma}}(0), \hat{\sigma}^{2}(0) \qquad (Ec.3.4.3)$$

Una observación importante es que cualquier permutación de los componentes de  $\hat{\theta}(0)$  con la correspondiente permutación de filas y columnas de  $\hat{\Gamma}$  forman parte

de la estimación. Por eso será necesario fijar algún orden y designar la asociación entre fuentes móviles y DOAs, esto lo haremos mediante números 1,2,...,L, por ejemplo  $\hat{\theta}_i(0)$  será la DOA estimada para la fuente móvil *i*.

También en esta primera etapa obtenemos una aproximación a las varianzas del error  $p_i(0)$ .

<u>Etapa 2</u>: Sobre el intervalo [T, 2T), que se corresponde con k=1, y con los nuevos datos recopilados por los sensores más la consideración de  $\Gamma = \hat{\Gamma}(0)$  y  $\sigma^2 = \hat{\sigma}^2(0)$ , podemos aplicar de nuevo un algoritmo para obtener así las estimaciones  $\hat{\theta}_i(1)$  de  $\theta_i(1)$  y las varianzas  $p_i(1)$ . Suponiendo que los elementos de la diagonal de  $\Gamma$  (potencia de las fuentes móviles) son distintos, es decir, cada fuente emite con distinta potencia, el uso de  $\hat{\Gamma}(0)$  por  $\Gamma$  permite mantener la asociación entre los componentes  $\hat{\theta}(1)$  y  $\hat{\theta}(0)$  respecto a las fuentes móviles.

<u>*Etapa 3*</u>: A partir de  $\hat{\theta}(1)$  y  $\hat{\theta}(0)$  inicializamos el filtro de Kalman para cada fuente móvil mediante:

$$\hat{\mathbf{x}}_{i}(1|1) = \begin{bmatrix} \hat{\theta}_{i}(1|1) \\ \hat{\theta}_{i}(1|1) \\ \hat{\theta}_{i}(1|1) \end{bmatrix} = \begin{bmatrix} \hat{\theta}_{i}(1) \\ T^{-1} \begin{bmatrix} \hat{\theta}_{i}(1) - \hat{\theta}_{i}(0) \\ 0 \end{bmatrix}$$

con la matriz de covarianza  $\mathbf{P}_i(1 \mid 1)$  de  $\hat{\mathbf{x}}_i(1 \mid 1)$  dada por:

$$\mathbf{P}_{i}(1|1) = \begin{bmatrix} p_{i}(1) & T^{-1}p_{i}(1) & 0\\ T^{-1}p_{i}(1) & T^{-1}[p_{i}(1) + p_{i}(0)] & 0\\ 0 & 0 & 0 \end{bmatrix}$$

En las anteriores expresiones hemos tomado como cero el valor inicial de  $\hat{\theta}_i$ . Si fuera necesario, podrían considerarse los datos del intervalo [2T, 3T), correspondiente a k=2, estimando  $\theta(2)$  y las varianzas  $p_i(2)$  en el mismo modo que lo hicimos en la Etapa 2. Ahora el filtro de Kalman puede inicializarse de la siguiente forma:

$$\hat{\theta}_i(2 \mid 2) = \hat{\theta}_i(2)$$
$$\hat{\theta}_i(2 \mid 2) = T^{-1} \left[ \hat{\theta}_i(2) - \hat{\theta}_i(1) \right]$$
$$\hat{\theta}_i(2 \mid 2) = T^{-2} \left[ \hat{\theta}_i(2) - 2 \cdot \hat{\theta}_i(1) + \hat{\theta}_i(0) \right]$$

Desde este punto ya estamos en condiciones de arrancar el algoritmo recursivo de Kalman. Únicamente habrán de introducirse modificaciones que tomen en cuenta la posibilidad de que las trayectorias de distintas fuentes móviles puedan cruzarse, debido a que en esa circunstancia las DOAs tienden a ser las mismas, complicando consecuentemente las estimaciones.

<u>Etapa</u> 4: Supongamos que tenemos valores filtrados y matrices de covarianzas  $\hat{\mathbf{x}}_i(k|k)$  y  $\mathbf{P}_i(k|k)$  para  $k \ge 1$  ó 2. Usando la *Ec.3.4.2* para (*k*+1) obtendremos:

$$\hat{\mathbf{x}}_i(k+1 \mid k) = \mathbf{F} \cdot \hat{\mathbf{x}}_i(k \mid k), \quad k \ge 1$$

Examinemos las primeras componentes de  $\hat{\mathbf{x}}_i(k+1|k)$ , i=1,2,...,L, denominadas  $\hat{\theta}_1(k+1|k), \hat{\theta}_2(k+1|k), ..., \hat{\theta}_L(k+1|k)$ . Supongamos que estas estimaciones se encuentran bien separadas usando un criterio como el siguiente:

$$\min_{i \neq j} \left[ \hat{\theta}_i(k+1 \mid k) - \hat{\theta}_j(k+1 \mid k) \right] \ge u$$
 (Ec.3.4.4)

donde u es valor elegido para un umbral. Seguidamente podemos proceder como en las siguientes etapas dependiendo del resultado obtenido en *Ec.3.4.4*.

<u>Etapa 4a</u>: Combinamos  $\hat{\theta}(k+1)$  y  $\hat{\theta}(k+1|k)$  a través del filtrado de Kalman para así obtener  $\hat{\theta}(k+1|k+1)$  y su matriz de covarianzas, del modo siguiente:

$$\hat{\theta}_i(k) = \theta_i(k) + \eta_i(k), \quad i = 1, 2, \dots, L$$

ecuación esta última que podemos explicitar algo más:

$$\hat{\theta}_i(k) = \mathbf{h} \begin{bmatrix} \theta_i(k) \\ \dot{\theta}_i(k) \\ \ddot{\theta}_i(k) \end{bmatrix} + \eta_i(k), \quad i = 1, 2, \dots, L$$

donde  $h = [1 \ 0 \ 0].$ 

En base a la ecuación dinámica Ec.3.4.2 y la ecuación anterior el filtro de Kalman para la fuente móvil *i*-ésima (i = 1,...,L) sería:

$$\begin{bmatrix} \hat{\theta}_i(k \mid k) \\ \hat{\theta}_i(k \mid k) \\ \hat{\theta}_i(k \mid k) \end{bmatrix} = \begin{bmatrix} \hat{\theta}_i(k \mid k-1) \\ \hat{\theta}_i(k \mid k-1) \\ \hat{\theta}_i(k \mid k-1) \end{bmatrix} + L_i(k)[\hat{\theta}_i(k) - \hat{\theta}_i(k \mid k-1)]$$

donde  $\hat{\theta}_i(k | k+1)$ ,  $\hat{\theta}_i(k | k+1)$ ,  $\hat{\theta}_i(k | k+1)$  son las estimaciones predichas de  $\theta_i(k)$ ,  $\dot{\theta}_i(k)$ ,  $\ddot{\theta}_i(k)$  respectivamente, basadas en las medidas hasta el instante (k+1)T, mientras  $\hat{\theta}_i(k | k)$ ,  $\hat{\theta}_i(k | k)$ ,  $\hat{\theta}_i(k | k)$  son las estimas filtradas de  $\theta_i(k)$ ,  $\dot{\theta}_i(k)$ ,  $\ddot{\theta}_i(k)$ respectivamente, basadas en las medidas hasta el instante kT. La ganancia de Kalman  $\mathbf{L}_i(k)$  viene dada por:

$$\mathbf{L}_{i}(k) = \frac{\mathbf{P}_{i}(k \mid k-1)\mathbf{h}^{T}}{\mathbf{h} \cdot \mathbf{P}_{i}(k \mid k-1)\mathbf{h}^{T} + J_{ii}^{-1}}$$
(Ec.3.4.5)

con  $J_{ii} = N(\mathbf{V}_i)^T (\mathbf{I}_{M^2} + \mathbf{K})(\hat{\mathbf{R}}_{yy} \otimes \hat{\mathbf{R}}_{yy}) \mathbf{V}_i$  que es el elemento (i,i) de la matriz de información de Fisher, aquí N es el tamaño de la muestra de datos,  $\mathbf{I}_{M^2}$  es la matriz identidad de dimensión  $M^2$ ,  $\mathbf{K} = \sum_{i,j=1}^{M} \mathbf{H}_{ij} \otimes \mathbf{H}_{ij}^T$ , donde  $\mathbf{H}_{ij}$  indica una matriz  $M \times M$  cuyos elementos (i,j) son la unidad y el resto ceros y  $\otimes$  denota producto de Kronecker,  $\hat{\mathbf{R}}_{yy}$  es la estimación de la matriz de covarianzas de los datos recogidos en la agrupación de sensores y la matriz  $\mathbf{V}_i = vec(\hat{\mathbf{R}}_{yy}^{-1}\hat{\mathbf{R}}_{(yy)_i}\hat{\mathbf{R}}_{yy}^{-1})^T$  donde si  $\mathbf{Z} = [\mathbf{a}, \mathbf{b}, \mathbf{c}]$  entonces  $vec(\mathbf{Z}) = [\mathbf{a}^T, \mathbf{b}^T, \mathbf{c}^T]^T$ .

<u>Etapa 4b</u>: Si para alguno de los resultados de la Ec.3.4.4 encontramos separaciones entorno a un valor u, elegido como umbral, procedemos a formar agrupamientos de estimas.

A continuación vamos a dar una descripción de este algoritmo, para ello supongamos que en el instante kT, tenemos una predicción de la estimación  $\hat{\theta}(k | k-1)$  del vector de DOAs de las *L* fuentes móviles.

$$\hat{\theta}(k \mid k-1) = \left[\hat{\theta}_{1}(k \mid k-1), \hat{\theta}_{2}(k \mid k-1), \dots, \hat{\theta}_{L}(k \mid k-1)\right]^{T}$$

Si la distancia (valor absoluto de la diferencia) entre la DOA estimada de dos o más fuentes móviles es inferior a un umbral dado, u, entonces estas fuentes móviles forman un grupo. A los efectos de la estimación, un grupo se considera como una fuente móvil única. De este modo la distancia entre miembros de una clase particular es inferior a u, mientras que entre miembros de distintos grupos la diferencia será mayor. Por lo tanto, este método agrupa las estimas en distintos grupos, digamos m. Supongamos que los agrupamientos son:

$$\left(\hat{\theta}_{i_1},\ldots,\hat{\theta}_{i_{b_i}}\right), \quad i=1,2,\ldots,m \leq L$$

Para simplificar escribimos  $\hat{\theta}_{i_c}$  en lugar de  $\hat{\theta}_{i_c}(k+1|k)$ . Entonces, reemplazamos cada uno de los valores  $b_i$  en el grupo *i* por su valor medio.

$$\hat{\theta}_{(i)} = \frac{\hat{\theta}_{i_1} + \ldots + \hat{\theta}_{i_{b_i}}}{b_i}, \quad i = 1, 2, \ldots, m$$

Es decir los valores predichos para cada fuente móvil  $i_1,...,i_b$  se toman como  $\hat{\theta}_{(i)}$ .

Para ver cómo trabaja el resto del algoritmo supongamos un caso con L = 5 fuentes móviles. Definimos primeramente el siguiente parámetro:

$$d_{ij} = \left| \hat{\theta}_i(k \mid k-1) - \hat{\theta}_j(k \mid k-1) \right| , i, j \in \{1, 2, 3, 4, 5\}$$

valor que expresa las distancias entre la predicción de la estimación DOA. Con estos valores formamos la matriz de distancia  $D^0$  del modo siguiente:

$$1 \quad 2 \quad 3 \quad 4 \quad 5$$

$$1 \quad \begin{bmatrix} 0 & d_{12} & d_{13} & d_{14} & d_{15} \end{bmatrix}$$

$$2 \quad \begin{bmatrix} d_{12} & 0 & d_{23} & d_{24} & d_{25} \end{bmatrix}$$

$$D^{0} = 3 \quad \begin{bmatrix} d_{13} & d_{23} & 0 & d_{34} & d_{35} \end{bmatrix}$$

$$4 \quad \begin{bmatrix} d_{14} & d_{24} & d_{34} & 0 & d_{45} \end{bmatrix}$$

$$5 \quad \begin{bmatrix} d_{15} & d_{25} & d_{35} & d_{45} & 0 \end{bmatrix}$$

Si todos los  $d_{ij}$ ,  $i \neq j$  son mayores que u, entonces cada predicción de la estimación DOA forma un grupo. Supongamos que tenemos algún  $d_{ij}$ ,  $i \neq j$  que son menores que u. En ese caso de entre estos  $d_{ij}$ , elegimos el  $d_{ij}$  más pequeño. Por ejemplo, sea  $d_{35}$  el más pequeño, por lo tanto agrupamos  $\hat{\theta}_3(k \mid k-1)$  y  $\hat{\theta}_5(k \mid k-1)$ , y consideramos una matriz de distancias modificada  $D^1$  como la siguiente:

$$D^{1} = \begin{bmatrix} 35 & 1 & 2 & 4 \\ 35 & 0 & d_{(35)1} & d_{(35)2} & d_{(35)4} \\ d_{(35)1} & 0 & d_{12} & d_{14} \\ d_{(35)2} & d_{12} & 0 & d_{24} \\ d_{(35)4} & d_{14} & d_{24} & 0 \end{bmatrix}$$

donde  $d_{(ij)k} = \max\{ d_{ik}, d_{jk} \}$ .

Volvemos a comprobar si alguna de las entradas  $D^1$  son menores que u, elegimos el más pequeño. Por ejemplo, supongamos que el más pequeño sea  $d_{24}$ , así que definimos una matriz de distancias  $D^2$  como la que sigue:

$$D^{2} = \begin{bmatrix} 0 & d_{(35)(24)} & d_{(35)1} \\ d_{(35)(24)} & 0 & d_{(24)1} \\ d_{(35)1} & d_{(24)1} & 0 \end{bmatrix}$$

donde  $d_{(ij)(kl)} = \max\{ d_{(ij)k}, d_{(ij)l} \}.$ 

Si ninguna de las entradas de  $D^2$  son inferiores a u, tenemos tres grupos, llamados (35), (24) y 1, si fuera así continuaríamos con el proceso.

# 3.5 Algoritmo de Estimación Conjunta de DOA e Identificación de Fuentes

En este apartado usamos el concepto de DOA asociado al concepto de localización, particularmente, angular. Desde un punto de vista práctico, el problema de la estimación DOA abordado en el apartado 3.3 contempla la necesidad de disponer de una muestra de datos obtenida con cierta diversidad espacial. Esta diversidad espacial la conseguimos mediante una agrupación de sensores, en nuestro caso los sensores estarán espaciados regularmente de forma concentrada, es decir, la separación entre ellos será igual o inferior a media longitud de onda. Además, el número de sensores será reducido, lo que impone a priori una limitación en el número de fuentes estimables. Sin embargo, ciertas metodologías [Ziskind 1992] que incorporan información sobre la fuente permiten salvar este escollo. Ya vimos en 3.3.3 cómo incorporar esta información a la estimación de DOA en banda estrecha. En este apartado vamos a ir un paso más adelante.

Un algoritmo de estimación DOA puede aplicarse a una fuente de señal específica y de banda ancha, o más ampliamente a un conjunto de fuentes con señales de características comunes. Esto generalmente conlleva algún tipo de procesamiento bien previo o bien a posteriori sobre los datos observados, por ejemplo, mediante descomposición en múltiples problemas de banda estrecha dentro de una banda de interés. Sin embargo, esto no resulta ser un algoritmo enteramente específico para ese conjunto de fuentes. Para que eso sea así creemos que es necesario que el propio algoritmo de estimación incorpore algún modelo de la fuente de señal en su propia definición.

Los cachalotes emiten distintos tipos de sonidos [André 1997], pero los que con más frecuencia emiten son los denominados clics [Wahlberg 2002, Teloni 2003], señales que son susceptibles de ser modeladas mediante procesos AR y ARMA [Hernández 2002b, Hernández-Pérez 2003, Zimmer 2005]. Nuestra intención es aprovecharlo, incorporando este conocimiento de manera explícita en el algoritmo de estimación DOA, por ende la asociación entre la DOA estimada e individuo, fuente sonora, será directa.



**Figura 3.5.1.** Estructura simplificada de la cabeza de un cachalote (a), hipótesis del recorrido de la excitación sonora en la cabeza del cachalote (b) y modelo de tubos para explicar el espectro clásico de un clic (c) propuestos en [Hernández-Pérez 2003].

### 3.5.1. Modelado mediante Procesos AR y ARMA de Clics de Cachalotes

La primera pregunta que nos hemos de hacer cuando se trata de modelar las señales producidas por una fuente, sonora en nuestro caso, debe ser: ¿Cómo se generan estas señales? En el caso de los cachalotes, a día de hoy, no disponemos de un conocimiento del mecanismo que esté cien por cien corroborado por la comunidad científica. Sin embargo, disponer de al menos unas nociones sobre el mecanismo de producción más aceptado por la comunidad científica, nos orientará sobre las técnicas de modelado más adecuadas.

La más aceptada de las hipótesis sobre el sistema de producción de sonidos en los cachalotes, es la siguiente [Norris 1972, Madsen 2001, Møhl 2001 y Møhl 2002]: el proceso comienza con una excitación impulsional muy potente producida en un órgano denominado "Labios de Mono", Figura 3.5.1(a). Este impulso se propaga hacia atrás (3.5.1b, línea negra) a través del órgano "Espermaceti", hacia un saco de aire frontal, desde donde parte es reflejada hacia delante a través de un órgano conocido como "Junk" que se cree sirve para enfocar la energía hacia el exterior dotando a este sistema de una gran directividad [Møhl 2000, Zimmer 2005b]. De hecho la conjunción de: el tamaño de la cabeza, los sacos distal y frontal como reflectores, y la velocidad de propagación dentro del medio graso contenido en este órgano, permiten que se puedan generar varios clics secundarios (Figura 3.5.1(b), trazo rojo). A este respecto hemos de decir que existen estudios, que aprovechando la existencia de los clics secundarios, desarrollan técnicas para determinar la medida de la cabeza a partir del retardo relativo entre el pulso principal y los secundarios [Adler-Fenchel 1980, Whitehead 1990, Gordon 1991, Goold 1996, Rhinelander 2004].

Nuestros experimentos sobre registros de sonidos de cachalotes muestran que sus espectros reflejan la existencia de resonancias y mínimos de transmisión, Figura 3.5.2. La presencia de resonancias estaría debida a una estructura de tubos acústicos en el órgano Spermaceti 3.5.1c. Más difícil de justificar, aunque razonable, es asumir que los mínimos de transmisión se deben bien al grupo de lentes que en conjunto adoptan forma cónica para el Junk o bien a interacciones complejas dentro del Spermaceti. Un estudio acústico detallado de un sistema de tubos similar, aunque aplicado a la generación de voz, lo podemos encontrar en [O'Shaughnessy 1987], desde ese estudio es posible ver la similitud entre el modelo de tubos y el modelado AR. Esta idea ha sido ampliamente usada en procesado de voz desde entonces. Incluso se puede utilizar un modelo ARMA [Quintana-Morales 2003]. Tanto para modelos AR, MA y ARMA existen buenas técnicas que además no necesitan de un conocimiento exacto de la excitación [Kay 1988]. Esto viene muy bien pues en el caso de los cachalotes es muy difícil (casi imposible) tener acceso a la excitación que se genera en los *Labios de Mono*.

Con estas consideraciones parece viable proponer la aplicación de un modelado ARMA (AutoRegressive Moving Average) para el sistema de producción de sonidos de los cachalotes. En este modelado la parte AR permite recoger las resonancias y la parte MA los mínimos de transmisión. Estamos asumiendo, por tanto, que el sistema de producción de clics es lineal e invariante en el intervalo



Figura 3.5.2. Espectro de un clic de cachalote.

que dura (p.ej., entre 2 y 10 milisegundos) cualquiera de estos clics y sus posibles réplicas.

El hecho de que cada individuo tenga unas características diferentes en la cabeza confiere un 'sello' particular a las señales que genera. Cómo se extrae este sello es un problema que abordamos mediante el modelado ARMA antes mencionado. Así, entendemos, y nuestras medidas de campo así lo corroboran [Hernández-Pérez 2003], cada cachalote tiene unas características propias que podemos extraer convenientemente.

#### Modelo Autorregresivo de Medias Móviles

Desde un punto de vista práctico sabemos que podemos aproximar un proceso aleatorio tiempo discreto mediante un modelo basado en una función de transferencia racional. En este modelo hay una secuencia de entrada u[n] y una secuencia de salida s[n] relacionadas mediante la siguiente ecuación en diferencias:

$$s[n] = -\sum_{k=1}^{d} a[k]s[n-k] + \sum_{k=0}^{q} b[k]u[n-k]$$
(Ec.3.5.1)

donde los a[k] son los coeficientes autorregresivos (AR) de orden  $d \ge b[k]$  son los coeficientes de medias móviles (MA) de orden q. Este modelo es a veces mencionado como modelo de polos y ceros, y se denomina proceso ARMA(d,q). El interés en estos modelos radica en la relación de los filtros lineales con las funciones de transferencia racionales. En el dominio transformado Z, la función



**Figura 3.5.3.** Modelado espectral de un clic de cachalote empleando las metodologías MYWE TSLS (a) y reconstrucción de la señal mediante MYWE (b).

de transferencia del sistema, H(z), entre la entrada u[n] y la salida s[n] para un proceso ARMA es la siguiente función racional:

$$H(z) = \frac{B(z)}{A(Z)}$$

donde A(z) es la transformada Z de la rama AR dada por la siguiente expresión:

$$A(z) = 1 + \sum_{k=1}^{d} a[k] z^{-k}$$

y B(z) la transformada Z de la rama MA que se expresa del modo siguiente:

$$B(z) = \sum_{k=0}^{q} b[k] z^{-k}$$

Si A(z) tiene todos sus ceros dentro del círculo unidad del plano Z, se garantiza que H(z) es un filtro causal y estable. El significado físico está relacionado con las resonancias. Por otro lado, el significado de los ceros de B(z) está relacionado con los mínimos de transmisión.

Naturalmente cada cachalote presentará para sus clics un conjunto de coeficientes AR y MA específicos, para ello será necesaria una estimación previa de los mismos en base a las señales recogidas en campo.

Varias son las metodologías capaces de realizar esta tarea, aunque cuando hablamos de modelado ARMA esta se reducen considerablemente dada la dificultad que entraña. Nosotros hemos usado las Ecuaciones Modificadas de Yule-Walker (MYWE, Modified Yule-Walker Equations) [Friedlander 1984, Manolakis 2005] y Mínimos Cuadrados en tres Etapas (TSLS, Two-Stage Least Squares) [Mayne 1977, Konvalinka 1979, Kay 1988].

En cualquier caso, de una forma u otra, el problema de la estimación de los parámetros se plantea como una minimización del error de predicción, definido este como e[n]=s[n]-s'[n], donde s[n] sería la señal y s'[n] la señal reconstruida. Problema que encuentra solución por distintas vías según las metodologías arriba indicadas y de las cuáles pasamos a dar una pequeña reseña, al tiempo que damos un avance del comportamiento que cada una de ellas tiene a la hora de modelar clics de cachalotes. En la Figura 3.5.3 podemos ver los espectros normalizados y las señales reconstruidas para modelados ARMA(d,q). Podemos ver (Figura 3.5.3(a)), en principio, que ambas técnicas permiten caracterizar bien tanto las resonancias como los ceros de transmisión.

En el caso de las ecuaciones modificadas de Yule-Walker la estimación de los coeficientes para la parte AR surgen al resolver el siguiente sistema matricial:

$$\begin{bmatrix} r_{ss}(0) & r_{ss}(1) & \cdots & r_{ss}(d-1) \\ r_{ss}(1) & r_{ss}(0) & \cdots & r_{ss}(d-2) \\ \vdots & \vdots & \ddots & \vdots \\ r_{ss}(d-1) & r_{ss}(d-2) & \cdots & r_{ss}(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_d \end{bmatrix} = -\begin{bmatrix} r_{ss}(1) \\ r_{ss}(2) \\ \vdots \\ r_{ss}(d) \end{bmatrix}$$

donde las ecuaciones modificadas de Yule-Walker que definen  $r_{ss}$  para el caso ARMA son tal y como se indican más abajo, ecuaciones que presentan una relación no lineal entre  $r_{ss}[m]$  y los parámetros  $\{a_k\}$  y  $\{b_k\}$ . Para el caso AR se simplifican, como se muestra en las expresiones siguientes:

CASO ARMA  

$$r_{ss}(m) = \begin{cases} -\sum_{k=1}^{d} a_k \cdot r_{ss}(m-k) + \sum_{k=m}^{q} b_k \cdot r_{su}(m-k), & 0 \le m \le q \\ -\sum_{k=1}^{d} a_k \cdot r_{ss}(m-k), & m > q \end{cases}$$
CASO AP

$$r_{ss}(m) = \begin{cases} -\sum_{k=1}^{d} a_k \cdot r_{ss}(m-k) + \sigma_u^2, & m = 0\\ -\sum_{k=1}^{d} a_k \cdot r_{ss}(m-k), & m > 0 \end{cases}$$

En las ecuaciones anteriores  $r_{su}[m] = \sigma_u^2 h^*[-m]$  es la correlación cruzada entre la secuencia entrada u[n] y la observada s[n],  $\sigma_u^2$  es la varianza del ruido blanco, u(n), usada como secuencia de entrada al proceso, mientras que h(m) es la respuesta al impulso del filtro H(z), función de transferencia del sistema generador del proceso observado, s[n]. El algoritmo MYWE implementado realiza la estimación de los parámetros MA del sistema a partir de la secuencia de entrada al proceso, u[n].

El algoritmo TSLS es un estimador de los denominados subóptimo para procesos ARMA, su principal aportación reside en la estimación del proceso de excitación, la secuencia de entrada u(n). El desconocimiento de esta secuencia tiene como efecto que no se pueda disponer de la correlación cruzada entre la entrada y la salida,  $r_{su}[m]$ , lo que deviene en la no linealidad del problema. En este caso la Ec.3.5.1 se transforma en la siguiente

$$s[n] = -\sum_{k=1}^{d} a[k]s[n-k] + \sum_{k=1}^{q} b[k]\hat{u}[n-k] + \hat{u}[n]$$

donde  $\hat{u}[n]$ es un estimación de la secuencia de entrada u[n]. El apelativo de tres etapas, le sobreviene debido al uso de una primera etapa donde estimamos, mediante mínimos cuadrados, los coeficientes AR de un orden elevado, fijando la estimación de u[n],  $\hat{u}[n]$ , igual a la salida del filtro del error de predicción definido este del modo siguiente:

$$\hat{u}[n] = \sum_{k=1}^{L} a[k]s[n-k]$$

A continuación se estiman los coeficientes  $\{b_k\}$  de la rama MA del proceso, a partir de los cuáles se forman las siguientes secuencias:

$$y[n] = -\sum_{k=1}^{q} \hat{b}[k] y[n-k] + s[n]$$
$$n = -d, -d + 1, \dots, N - 1$$

$$z[n] = -\sum_{k=1}^{q} \hat{b}[k] z[n-k] + \hat{u}[n]$$
$$n = -q, -q + 1, \dots, N - 1$$

El paso final sería la estimación de los parámetros del proceso ARMA considerando la resolución mediante mínimos cuadrados del siguiente problema:

$$\hat{\boldsymbol{\Theta}} = (\mathbf{H}^{\dagger} \cdot \mathbf{H})^{-1} \mathbf{H}^{\dagger} (\mathbf{y} - \mathbf{z})$$

donde  $\hat{\Theta} = \left\{-\hat{a}[1], -\hat{a}[2], \dots - \hat{a}[d], \hat{b}[1], \hat{b}[2], \dots \hat{b}[q]\right\}^T$ ,  $\mathbf{y} = \{\mathbf{y}[0], \mathbf{y}[1], \dots \mathbf{y}[N-1]\}^T$ ,  $\mathbf{z} = \{\mathbf{z}[0], \mathbf{z}[1], \mathbf{z}[N-1]\}^T$  y

$$\mathbf{H} = \begin{bmatrix} y(-1) & y(-2) & \cdots & y(-d) & z(-1) & z(-2) & \cdots & z(-q) \\ y(0) & y(-1) & \cdots & y(-d+1) & z(0) & z(-1) & \cdots & z(-q+1) \\ \vdots & \vdots \\ y(N-2) & y(N-3) & \cdots & y(N-d-1) & z(N-2) & z(N-3) & \cdots & z(N-q-1) \end{bmatrix}$$

Una vez obtenidos los parámetros  $\hat{\Theta}$  podemos proceder a generar sintéticamente una señal de obteniendo así la señal reconstruida tal como aparece en la siguiente ecuación.

$$s'[n] = -\sum_{k=1}^{d} a[k]s'[n-k] + \sum_{k=1}^{q} b[k]\hat{u}[n-k] + \hat{u}[n]$$

El error cuadrático medio (en dB) de reconstrucción se puede estimar como:

$$E = \frac{1}{N} \sum_{n=0}^{N-1} (e[n])^2 = \frac{1}{N} \sum_{n=0}^{N-1} (s[n] - s'[n])^2$$

O en valor logarítmico  $E(dB) = 10 \cdot \log_{10}(E)$ . Observamos en la Figura 3.5.3(a) que el modelado espectral mediante TSLS es cualitativamente mejor que el MYWE al hacer el seguimiento del espectro de la señal, p.ej. en la ubicación de los polos y ceros. La mejor adecuación del TSLS para el modelado de clics de cachalotes se muestra igualmente en la reconstrucción de la señal, Figura 3.5.3(b). Allí

observamos un seguimiento ciertamente ajustado de la señal, cuantitativamente la diferencia entre los errores de reconstrucción del TSLS y el MYWE se encuentra por encima de los 10 dB a favor del TSLS, para el caso de un proceso modelado con un orden AR igual a 20 y un orden MA de 10. En el apartado 3.6.1 se presentan más experimentos de los que podremos extraer conclusiones más precisas.

## 3.5.2. Algoritmo de Estimación DOA Específico de Fuentes AR

Los algoritmos de estimación DOA clásicos (ver apartado 3.3) fueron establecidos inicialmente para trabajar con fuentes de banda estrecha, sin imponer un conocimiento específico de la fuente. En cualquier caso se busca hallar la estimación DOA, con la máxima precisión y el mínimo de carga computacional, como cuestiones más relevantes. En esta tesis el problema que nos planteamos es el desarrollo de un algoritmo que trate con unas fuentes específicas, cachalotes. Como primer dato hemos de decir que se trata de fuentes de banda ancha, cuestión que queda claramente reflejada en la Figura 3.5.3(a) y en el apartado 3.6.1, que además es coherente con lo reflejado en [Zatman 1998]. En este sentido varios son los métodos DOA propuestos hasta la fecha para banda ancha, p.ej. los presentados en el apartado 3.3.2 dentro de los métodos de MV, denominados STMV [Krolik 1989, Haykin 1991] y SRMV [Krolik 1990B, Haykin 1991]. Métodos que aunque resuelven adecuadamente el problema de la estimación DOA, el número de estas viene limitado por el de sensores, no pudiendo resolver un número de fuentes superior o igual al de sensores de la agrupación. Al no incorporar otra información relativa a la señal que la del ancho de banda de interés, no será posible asociar de manera específica la dirección DOA y una fuente determinada. Otro ejemplo de estimación DOA de banda ancha lo encontramos en [Ficker 1989], método mediante el que si es posible estimar las DOAs de un número de fuentes superior al número de sensores. Sin embargo, a pesar de ser un método que presenta buenas prestaciones en términos de SNR y deriva de las estimaciones, la carga computacional es alta.

Otro dato importante sobre las fuente de nuestro interés es que, tal y como hemos demostrado en el apartado 3.5.1, estas fuentes son modelables mediante procesos AR y ARMA. En ese contexto y en el ámbito de la estimación DOA en el dominio del tiempo conocemos la propuesta de [Ziskind 1992] (ver apartado 3.3.3). Los autores de la misma proponen un método basado en el supuesto de que las señales son de autorregresivas y de banda estrecha, con el añadido de que el número de fuentes puede ser mayor que el número de sensores. Sin embargo, se trata de un método no apto para banda ancha. Además, se hace necesaria la estimación de los coeficientes, así como de las matrices de correlación de señal y ruido.

En otro orden de cosas, es importante destacar que los algoritmos de estimación DOA clásicos no incluyen la capacidad de asociarla con una fuente específica, es decir la DOA no lleva identificación alguna sobre la fuente de procedencia. Esta capacidad en ciertas aplicaciones, donde p.ej. la estimación DOA fuese un paso previo o intermedio dentro de un sistema, puede resultar de gran utilidad ya que de lo contrario habría que hacerlo en etapas posteriores. En un principio podríamos pensar que esta capacidad puede dar lugar a algoritmos no extensibles a otras aplicaciones. Sin embargo, en este caso creemos que esto no es así, ya que el tipo de modelado que queremos aplicar a nuestras fuentes de banda ancha, AR y ARMA, puede extenderse a otras fuentes sonoras bastante cotidianas.

Así las cosas, la propuesta que vamos a desarrollar es un algoritmo de estimación DOA para fuentes de banda ancha mediante una agrupación de sensores pasivos, con un número reducido de sensores, posiblemente inferior al número de fuentes, para fuentes modeladas mediante procesos AR.

En primer lugar, vamos a suponer que el ancho de banda de nuestro interés se circunscribe al comprendido entre una frecuencia inferior  $\omega_l$  y una superior  $\omega_h$ . Además, comenzaremos definiendo en el dominio de la frecuencia el modelo de las señales incidentes. Sea la fuente *i*-ésima, de modelo autorregresivo (AR) conocido, dada por la expresión *Ec.3.5.2*:

$$S_i(\omega_k) = \sum_{n=1}^d a_{in} \cdot S_i(\omega_k) \cdot \exp(-j\omega_k nT_s) + \Sigma_i(\omega_k)$$
(Ec.3.5.2)

donde *d* es el orden del modelo AR, que sin pérdida de generalidad hemos supuesto igual para todas las fuentes,  $T_s$  es el periodo de muestreo,  $\{a_{in}\}$  son los coeficientes del modelo AR,  $\Sigma_i(\omega_k)$  es un proceso estacionario blanco de media nula (es el error de predicción) y  $\omega_k$  corresponde a una frecuencia comprendida entre  $\omega_l$  y  $\omega_h$  ( $\omega_l \le \omega_k \le \omega_h$ ).

Supongamos un escenario compuesto por una agrupación uniforme, ULA, de M sensores omnidireccionales de banda ancha situada en campo lejano de las fuentes, con sensores espaciados  $D = \lambda_{\min}/2$ , donde  $\lambda_{\min}$  es la longitud de onda más corta de la emitidas en la banda de interés por las L fuentes autorregresivas. Fuentes que inciden desde direcciones  $\{\theta_i\}^{L}_{i=1}$  desconocidas. Consideramos también que las fuentes y el ruido de fondo son procesos de banda ancha con idéntico ancho de banda,  $B=(\omega_h - \omega_l)/2 \pi$ , mutuamente incorrelados, ergódicos de segundo orden y estacionarios, y de media nula.

Admitimos que el tiempo de observación de las señales en los sensores es un valor finito,  $T_0$ , suficientemente largo en comparación a la inversa del ancho de banda de las señales ( $B \cdot T_0 \gg 1$ ). La frecuencia de muestreo cumple el criterio de Nyquist, particularmente,  $F_s = 2 \cdot B$ .

En función de todo lo avanzado en los párrafos anteriores la señal recibida en el *m*-ésimo sensor según *Ec.3.5.2*,  $Y_{\rm m}(\omega_k)$ , vendrá dada por las siguientes expresiones, designadas expresiones extendidas de las salidas de los sensores.

$$Y_{m}(\omega_{k}) = \sum_{i=1}^{L} g_{m}(\omega_{k}, \theta_{i}) \cdot \left[ \sum_{n=1}^{d} a_{in} \cdot S_{i}(\omega_{k}) \cdot \exp(-j\omega_{k}nT_{s}) \right] \text{ para } 1 \le m \le M$$
$$+ \sum_{i=1}^{L} g_{m}(\omega_{k}, \theta_{i}) \cdot \Sigma_{i}(\omega_{k}) + N_{m}(\omega_{k})$$
$$Y_{m}(\omega_{k}) = \sum_{i=1}^{L} g_{m}(\omega_{k}, \theta_{i}) \cdot S_{i}(\omega_{k}) \cdot \exp(-j\omega_{k}lT_{s}) + N_{m}(\omega_{k})$$

para 
$$M < m \le M(d+1)$$
 y  $l = \left\lfloor \frac{m-1}{M} \right\rfloor$ 

donde  $N_m(\omega_k)$ ,  $(m=0,1,\ldots,M-1)$ , es el ruido en el sensor m a la frecuencia  $\omega_k$ ,  $\tau_m(\theta_l)=m(D/c)sin(\theta_l)$  es el retardo entre el m-ésimo sensor y el sensor tomado como referencia en la agrupación y c la velocidad de propagación de las ondas en el medio considerado. Si suponemos que el retardo de propagación sobre la totalidad de la agrupación es mucho menor que  $T_0/2$ , entonces el retardo de propagación en el dominio del tiempo corresponde aproximadamente a un desplazamiento de fase en los coeficientes de Fourier. Luego,  $Y_m(\omega_k)$  puede admitirse de media nula, asintóticamente gaussiana e incorrelada frecuencia a frecuencia en  $2\pi B/F_s$ . Por último, indicar que con  $\lfloor (m-1)/M \rfloor$  hacemos referencia al entero menor o igual al cociente mostrado.

En forma matricial obtenemos el vector de señal extendido  $\mathbf{Y}_{\mathbf{E}}(\omega_k) = \mathbf{A}(\omega_k, \alpha, \theta) \mathbf{S}(\omega_k) + \mathbf{A}'(\omega_k, \theta) \mathbf{\Sigma}(\omega_k) + \mathbf{N}(\omega_k)$ , donde  $\mathbf{\Sigma}(\omega_k) = [\Sigma_1(\omega_k), \dots, \Sigma_L(\omega_k)]^T$  es el vector del error de predicción (el superíndice (·)<sup>T</sup> indica traspuesta),  $\mathbf{A}'(\omega_k, \theta)$  es la matriz de enfoque a la frecuencia  $\omega_k$  dada por:  $\mathbf{A}'(\omega_k, \theta) = [\mathbf{g}(\omega_k, \theta_1), \dots, \mathbf{g}(\omega_k, \theta_L)]$ con

 $\mathbf{g}(\omega_k, \theta_i) = \left[\exp\left[-j\omega_k \tau_0(\theta_i)\right], ..., \exp\left[-j\omega_k \tau_{M-1}(\theta_i)\right]\right]^T$  como el vector de dirección de la fuente i-ésima,  $\mathbf{S}(\omega_k) = [S_1(\omega_k), ..., S_L(\omega_k)]^T$  es el espectro de las fuentes a la frecuencia  $\omega_k$ , y por último,

$$\mathbf{A}(\omega_k, a, \theta) = \left[ \mathbf{g}(\omega_k, \theta_1) \sum_{n=1}^d a_{1n} \exp\left(-jnT_s \omega_k\right), \dots, \mathbf{g}(\omega_k, \theta_L) \sum_{n=1}^d a_{Ln} \exp\left(-jnT_s \omega_k\right) \right] \text{es la matriz}$$

 $M \times L$  de dirección de fuentes. Es lo que denominamos versión AR extendida (ARExt). A modo de ejemplo, veamos cómo quedarían las matrices para un escenario compuesto por una agrupación de dos sensores, M=2, sobre la que inciden dos fuentes, L=2, que hemos modelado con dos coeficientes autorregresivos, fuente de orden d=2.

$\left(Y_1(\omega_k)\right)$		$(a_{11}\cdot g_1(\theta_1,\omega_k))$	$a_{21} \cdot g_1(\theta_2, \omega_k)$	$a_{12} \cdot g_1(\theta_1, \omega_k)$	$a_{22} \cdot g_1(\theta_2, \omega_k)$
$Y_2(\omega_k)$		$a_{11} \cdot g_2(\theta_1, \omega_k)$	$a_{21} \cdot g_2(\theta_2, \omega_k)$	$a_{12} \cdot g_2(\theta_1, \omega_k)$	$a_{22} \cdot g_2(\theta_2, \omega_k)$
$Y_3(\omega_k)$	_	$g_1( heta_1, \omega_k)$	$g_1( heta_2,\omega_k)$	0	0
$Y_4(\omega_k)$	_	$g_2( heta_1,\omega_k)$	$g_2(\theta_2,\omega_k)$	0	0
$Y_5(\omega_k)$		0	0	$g_1( heta_1,\omega_k)$	$g_1( heta_2,\omega_k)$
$\left(Y_{6}(\omega_{k})\right)$		0	0	$g_2(\theta_1,\omega_k)$	$g_2(\theta_2,\omega_k)$

(Ec. 3. 5. 3)

	$(g_1(\theta_1,\omega_k))$	$g_1(\theta_2,\omega_k)$		$(N_1(\omega_k))$
$\left(S_1^1(\omega_k)\right)$	$g_2(\theta_1,\omega_k)$	$g_2(\theta_2,\omega_k)$		$N_2(\omega_k)$
$S_2^1(\omega_k)$	0	0	$\left(\Sigma_1(\omega_k)\right)$	$N_1(\omega_k)$
$\left S_1^2(\omega_k)\right ^{\top}$	0	0	$\left(\Sigma_2(\omega_k)\right)^{\top}$	$N_2(\omega_k)$
$\left(S_2^2(\omega_k)\right)$	0	0		$N_1(\omega_k)$
	0	0 )		$\left(N_2(\omega_k)\right)$

donde  $S^{n}_{i}(\omega_{k}) = S_{i}(\omega_{k}) \exp(-j\omega_{k} \cdot n \cdot T_{s}).$ 

Si en la ecuación *Ec.3.5.3* excluimos el vector columna correspondiente al ruido en los sensores,  $\mathbf{N}(\omega_k)$ , el lado derecho es lo que denominamos vector de señal sintética de fuente. La matriz de covarianzas correspondiente a la parte derecha de la *Ec.3.5.3* sería un matriz de covarianzas sintética  $\mathbf{R}_s(\omega_k, \theta) =$  $\mathbf{E}\{[\mathbf{A}(\omega_k, \alpha, \theta)\mathbf{S}(\omega_k) + \mathbf{A}^*(\omega_k, \theta)\mathbf{\Sigma}(\omega_k)] [\mathbf{A}(\omega_k, \alpha, \theta)\mathbf{S}(\omega_k) + \mathbf{A}^*(\omega_k, \theta)\mathbf{\Sigma}(\omega_k)]^+\}.$ 

Una observación importante es que sólo cuando miramos en la dirección correcta se cumple la ecuación *Ec.3.5.3* para la fuente considerada. En otras palabras, únicamente una búsqueda por la totalidad del conjunto de direcciones de fuentes posibles permitiría estimar la DOA. Claramente, operar directamente sobre *Ec.3.5.3* conlleva una búsqueda multidimensional, lo que requiere una tarea computacional intensa a la vez que compleja. Observamos que para cada una de las direcciones del conjunto  $\boldsymbol{\theta} = [\theta_1, \dots, \theta_L]^T$  debemos construir una nueva matriz  $\mathbf{A}(\omega_k, a, \theta)$ . Esta dificultad puede superarse aislando las direcciones las direcciones en  $\mathbf{A}(\omega_k, a, \theta)$  y  $\mathbf{A}'(\omega_k, \theta)$ , de manera que *Ec.3.5.3* se transforma en la ecuación *Ec.3.5.4*.

$(Y_1(\omega_k))$	$Y_1(\omega_k)$		$\left(a_{11}\cdot S_1^1(\omega_k)+\Sigma_1(\omega_k)\right)$	$a_{21}$ · $S_2^1(\omega_k)$ + $\Sigma_2(\omega_k)$	
$Y_2(\omega_k)$	$Y_2(\omega_k)$		=	$a_{11} \cdot S_1^1(\omega_k) + \Sigma_1(\omega_k)$	$a_{21} \cdot S_2^1(\omega_k) + \Sigma_2(\omega_k)$
$Y_3(\omega_k)$	$Y_3(\omega_k)$			$S_1^1(\omega_k)$	$S_2^1(\omega_k)$
$Y_4(\omega_k)$	$Y_4(\omega_k)$			$S_1^1(\omega_k)$	$S_2^1(\omega_k)$
$Y_5(\omega_k)$	$Y_5(\omega_k)$		0	0	
$Y_6(\omega_k)$	$Y_6(\omega_k)$		0	0	

$$\begin{array}{cccc} a_{12} \cdot S_{1}^{2}(\omega_{k}) & a_{22} \cdot S_{2}^{2}(\omega_{k}) \\ a_{12} \cdot S_{1}^{2}(\omega_{k}) & a_{22} \cdot S_{2}^{2}(\omega_{k}) \\ 0 & 0 \\ 0 & 0 \\ S_{1}^{2}(\omega_{k}) & S_{2}^{2}(\omega_{k}) \\ S_{1}^{2}(\omega_{k}) & S_{2}^{2}(\omega_{k}) \end{array} \right) \begin{pmatrix} 1 & \exp[-j\omega_{k}\tau_{1}(\theta_{1})] \\ 1 & \exp[-j\omega_{k}\tau_{1}(\theta_{1})] \\ 1 & \exp[-j\omega_{k}\tau_{1}(\theta_{2})] \end{pmatrix}$$
(Ec.3.5.4)

que en forma compacta sería:

$$\mathbf{Y}_{E}(\omega_{k}) = \mathbf{A}(a, \mathbf{S}, \boldsymbol{\Sigma}, \omega_{k}) \cdot \Theta(\omega_{k})$$

Donde, a diferencia de Ec.3.5.3,  $\mathbf{Y}_{E}(\omega_{k})$  representa ahora la matriz extendida de las salidas de los sensores,  $\mathbf{A}(a, \mathbf{S}, \boldsymbol{\Sigma}, \omega_{k})$  es la matriz de señal, excitación y coeficientes, y  $\Theta(\omega_{k})$  es la matriz de direcciones. Analizando la Ec.3.5.4 resulta evidente que  $\mathbf{A}(a, \mathbf{S}, \boldsymbol{\Sigma}, \omega_{k})$  puede construirse antes de buscar sobre el conjunto de direcciones de modo que obtenemos una sustancial reducción de la carga computacional. Es lo que denominamos versión AR extendida rápida (ARExtFast). La matriz de covarianzas correspondiente a la parte derecha de la Ec.3.5.4 sería  $\mathbf{R}_{s}(\omega_{k}, \theta) = \mathbf{E}\{[\mathbf{A}(a, \mathbf{S}, \boldsymbol{\Sigma}, \omega_{k}) \ \Theta(\omega_{k})] [\mathbf{A}(a, \mathbf{S}, \boldsymbol{\Sigma}, \omega_{k}) \ \Theta(\omega_{k})]^{+}\}$ . A efectos prácticos esta parte derecha es lo que llamamos, al igual que en *Ec.3.5.3*, señal sintética y  $\mathbf{R}_{s}(\omega_{k},\theta)$  matriz de covarianzas sintética.

A continuación vamos a definir la función de búsqueda, que está basada en el muestreo de la matriz de covarianzas,  $\mathbf{R}_{YE}(\omega_k) = \mathbb{E}[\mathbf{Y}_{\mathrm{E}}(\omega_k), \mathbf{Y}_{\mathrm{E}}(\omega_k)^+]$  en conjunto con la matriz de covarianzas de la señal sintética de fuente  $\mathbf{R}_s(\omega_k, \theta)$ . Luego, el método de la Agrupación Extendida Autorregresiva (AEA) para estimación DOA sería:

$$\min_{[\theta_1,\dots,\theta_L]} \sum_{\omega_l}^{\omega_h} \left\| \mathbf{R}_{Y_E}(\omega_k) - \mathbf{R}_S(\omega_k,\theta) \right\|_F^2, \text{ para } \omega_k \in 2\pi B/F_s \qquad (Ec.3.5.5)$$

donde F es la norma de Frobenius. El proceso de estimación consistirá en determinar el conjunto de direcciones  $\theta$  para las cuáles *Ec.3.5.5* es mínima. Al tratarse de una función convexa siempre tendrá una solución única. Resumiendo, el proceso de estimación quedaría recogido en los siguientes pasos:

- 1. El número de fuentes es conocido a priori y también sus coeficientes  $\{a_{in}\}$ , que han sido estimados en realizaciones previas mediante alguno de los métodos estudiados en 3.5.1 para fuentes AR (p.ej., ARMA(d,0)).
- 2. A partir de los polinomios de predicción  $A_i(z) = \Sigma a_{in} z^{-n}$  determinamos las sub-bandas de frecuencias en la cuales cada fuente presenta máximos. Como resultado el análisis se restringirá a una nueva banda formada por la participación de todas las sub-bandas.
- 3. Formamos las matrices  $\mathbf{R}_{YE}(\omega_k)$  a partir de *Ec.3.5.3* o *Ec.3.5.4* según la formulación que elijamos y  $\mathbf{A}(a, \mathbf{S}, \boldsymbol{\Sigma}, \omega_k)$ . Es importante reseñar que en este método no es necesario un conocimiento exacto de las formas de onda de la fuente  $S_i(\omega_k)$  o del ruido generador,  $\Sigma_i(\omega_k)$ , en el receptor. Los experimentos realizados muestran que es suficiente con una estimación aproximada para señal y ruido mediante el filtrado de una señal aleatoria de ruido blanco.
- 4. Estimación de las DOAs a partir de Ec.3.5.5 donde la matriz de covarianzas sintética,  $\mathbf{R}_{s}(\omega_{k}, \theta)$ , se puede obtener a partir de Ec.3.5.3 o Ec.3.5.4 según la formulación que hayamos elegido.

### 3.5.3. Algoritmos de Estimación DOA Específico de Fuentes ARMA

En este apartado vamos a extender el algoritmo de estimación de DOA para fuentes AR al caso de fuentes ARMA. Partiendo de lo desarrollado dicha extensión es casi inmediata y natural. Esto trae consigo la posibilidad de desarrollar el mismo algoritmo del apartado anterior, pero considerando un modelado ARMA. En una primera instancia esto aportará más información acerca de la fuente, ya vimos en el apartado 3.5.1 cómo el modelado ARMA mediante el algoritmo TSLS permite una reconstrucción muy precisa de la señal. Además, no es descabellado pensar que también aportará una mejor discriminación entre las fuentes presentes en el escenario. Sin embargo, la extensión del algoritmo anterior desde un modelado AR a un modelado ARMA, no es la única forma que hemos encontrado de incorporar el modelado ARMA a la estimación DOA. En este mismo apartado presentaremos otro algoritmo que incorpora modelado ARMA a través de los polos para extraer información sobre los retardos relativos entre sensores para cada fuente. Además, se aplican técnicas de subespacio para la estimación DOA.

Pasamos a continuación a presentar cada uno de los algoritmos que tienen en común el uso del modelado ARMA de las fuentes consideradas, algoritmos que como veremos difieren en el tratamiento que se le da al conocimiento específico que sobre las fuentes tenemos.

#### • Algoritmo basado en Modelado ARMA y sus Coeficientes

Supongamos que la fuente i-ésima, de modelo autorregresivo (AR) de medias móviles (MA) conocidos, viene dada en el dominio de la frecuencia por:

$$S_i(\omega_k) = \sum_{n=1}^d a_{in} \cdot S_i(\omega_k) \cdot \exp\left(-j\omega_k nT_s\right) + \sum_{n=1}^q b_{in} \cdot U_i(\omega_k) \cdot \exp\left(-j\omega_k nT_s\right) + b_{i0} \cdot U_i(\omega_k)$$

donde d es el orden del modelo AR y q es el orden del modelo MA,  $T_s$  es el periodo de muestreo,  $\{a_{in}\}$  son los coeficientes de la parte AR,  $\{b_{in}\}$  son los coeficientes de la parte MA,  $U_i(\omega_k)$  es un proceso estacionario blanco de media nula que hace de excitación y  $\omega_k$  corresponde a una frecuencia comprendida entre  $\omega_l$  y  $\omega_h$  ( $\omega_l \leq \omega_k \leq \omega_h$ ). El término  $b_{i0}U_i(\omega_k)$  representa el error de modelización o, si se quiere, de predicción. Ahora, teniendo en cuenta esa expresión la señal recibida en el mésimo sensor,  $Y_m(\omega_k)$ , vendrá dada por:

$$Y_{m}(\omega_{k}) = \sum_{i=1}^{L} g_{m}(\omega_{k},\theta_{i}) \sum_{n=1}^{d} a_{in} S_{i}(\omega_{k}) \exp\left(-j\omega_{k} nT_{s}\right) \exp\left[-j\omega_{k} \tau_{m}(\theta_{i})\right] + \sum_{i=1}^{L} g_{m}(\omega_{k},\theta_{i}) \sum_{n=1}^{q} b_{in} U_{i}(\omega_{k}) \exp\left(-j\omega_{k} nT_{s}\right) \exp\left[-j\omega_{k} \tau_{m}(\theta_{i})\right] + N_{m}(\omega_{k})$$

para 
$$1 \le m \le M$$

$$Y_{m}(\omega_{k}) = \sum_{i=1}^{L} g_{m}(\omega_{k}, \theta_{i}) S_{i}(\omega_{k}) \exp\left(-j\omega_{k}nT_{s}\right) \exp\left[-j\omega_{k}\tau_{m}(\theta_{i})\right]$$
$$+ N_{m}(\omega_{k})$$
$$\text{para } M < m \le M(d+1) \text{ y } l = \left|\frac{m-1}{M}\right|$$

donde  $l = \lfloor (m-1)/M \rfloor$  significa el mayor entero menor o igual a (m-1)/M. Puesta en forma matricial la expresión anterior quedaría de la siguiente forma:

$$\mathbf{Y}_{E}(\omega_{k}) = \mathbf{A}(a,\theta,\omega_{k}) \cdot \mathbf{S}(\omega_{k}) + \mathbf{B}(b,\theta,\omega_{k}) \cdot \mathbf{U}(\omega_{k}) + \mathbf{N}(\omega_{k})$$

donde  $\mathbf{Y}_{E}(\omega_{k}) = \begin{bmatrix} \mathbf{Y}_{0}^{T}(\omega_{k}), \mathbf{Y}_{1}^{T}(\omega_{k}), \dots, \mathbf{Y}_{d}^{T}(\omega_{k}) \end{bmatrix}^{\mathrm{T}}$  es el vector extendido de dimensiones  $M(d+1) \times 1$ , con  $\mathbf{Y}_{n}(\omega_{k}) = \begin{bmatrix} Y_{nM+1}(\omega_{k}), Y_{nM+2}(\omega_{k}), \dots, Y_{nM+M}(\omega_{k}) \end{bmatrix}^{\mathrm{T}}$ ,  $\mathbf{S}(\omega_{k}) = \begin{bmatrix} \mathbf{S}^{1T}(\omega_{k}), \mathbf{S}^{2T}(\omega_{k}), \dots, \mathbf{S}^{dT}(\omega_{k}) \end{bmatrix}^{\mathrm{T}}$  de dimensión  $L \cdot d \times 1$ , donde  $\mathbf{S}^{n}(\omega_{k}) = \begin{bmatrix} S_{1}(\omega_{k}) \exp(-j\omega_{k}nT_{s}), \dots, S_{L}(\omega_{k}) \exp(-j\omega_{k}nT_{s}) \end{bmatrix}^{\mathrm{T}}$ . La matriz **A** viene dada por:

$$\mathbf{A}(a,\theta,\omega_k) = \begin{pmatrix} \mathbf{A}_{1,1}(a,\theta,\omega_k) & \mathbf{A}_{1,2}(a,\theta,\omega_k) & \cdots & \mathbf{A}_{1,p}(a,\theta,\omega_k) \\ \mathbf{A}(\theta,\omega_k) & 0 & \cdots & 0 \\ 0 & \mathbf{A}(\theta,\omega_k) & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ 0 & 0 & \cdots & \mathbf{A}(\theta,\omega_k) \end{pmatrix}$$

 $\operatorname{con} \mathbf{A}_{1,n}(a,\theta,\omega_k) = \begin{bmatrix} a_{1n}g(\theta_1,\omega_k), \dots, a_{Ln}g(\theta_L,\omega_k) \end{bmatrix} \quad \text{y} \quad g(\theta_i,\omega_k) = \begin{bmatrix} g_1(\theta_i,\omega_k), \dots, g_M(\theta_i,\omega_k) \end{bmatrix}^T$ donde  $g_m(\theta_i,\omega_k) = c_m(\theta_i,\omega_k) \cdot \exp\left[-j\omega_k\tau_m(\theta_i)\right] \quad \text{con} \quad \mathbf{A}(\theta,\omega_k) = \begin{bmatrix} g(\theta_1,\omega_k), \dots, g(\theta_L,\omega_k) \end{bmatrix}.$  La matriz  $\mathbf{B}(b,\theta,\omega_k)$ :

$$B(b,\theta,\omega_k) = \begin{pmatrix} B_{1,1}(b,\theta,\omega_k) & B_{1,2}(b,\theta,\omega_k) & \cdots & B_{1,q}(b,\theta,\omega_k) \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ 0 & 0 & \cdots & 0 \end{pmatrix}$$

donde  $B_{1,n}(b,\theta,\omega_k) = [b_{1n}g(\theta_1,\omega_k), b_{2n}g(\theta_2,\omega_k),...,b_{Ln}g(\theta_L,\omega_k)]$ . Por último, tenemos el vector correspondiente a las excitaciones, vector cuya dimensión es  $L \cdot q \times 1$  y que se expresa mediante:  $\mathbf{U}(\omega_k) = [\mathbf{U}^{1\,T}(\omega_k), \mathbf{U}^{2\,T}(\omega_k), ..., \mathbf{U}^{q\,T}(\omega_k)]^T$  donde desarrollando cada elemento tenemos:  $U^n(\omega_k) = [U_1(\omega_k) \cdot \exp(-j\omega_k nT_s), ..., U_L(\omega_k) \cdot \exp(-j\omega_k nT_s)]^T$ 

Así las cosas, podemos establecer que  $\mathbf{Y}_{\mathbf{E}}(\omega_k)$  es el vector extendido de la salida de los sensores,  $\mathbf{S}(\omega_k)$  es el vector extendido de señal,  $\mathbf{A}(a,\theta,\omega_k)$  de dimensión  $M(d+1) \times L d$  es la matriz de enfoque y de coeficientes AR. La matriz  $\mathbf{B}(b,\theta,\omega_k)$  de dimensión  $M(d+1) \times L q$  es la matriz de coeficientes MA,  $\mathbf{U}(\omega_k)$  es el vector de excitación y  $\mathbf{N}(\omega_k)$  de dimensión  $M(d+1) \times 1$  es el vector extendido de ruido.

Al igual que hicimos en el apartado anterior vamos a exponer las expresiones anteriores a partir de un ejemplo. Supongamos para ello un escenario compuesto por una agrupación de 2 sensores (M=2), con dos fuentes (L=2) y procesos autorregresivos ARMA(3,2), es decir d=3 y q=2. La expresión en forma matricial de la señal recibida por la agrupación será:

$$\begin{pmatrix} S_{1}(\omega_{k}) \exp(-j\omega_{k}T_{s}) \\ S_{2}(\omega_{k}) \exp(-j\omega_{k}T_{s}) \\ S_{1}(\omega_{k}) \exp(-j\omega_{k}2 \cdot T_{s}) \\ S_{2}(\omega_{k}) \exp(-j\omega_{k}2 \cdot T_{s}) \\ S_{1}(\omega_{k}) \exp(-j\omega_{k}3 \cdot T_{s}) \\ S_{2}(\omega_{k}) \exp(-j\omega_{k}3 \cdot T_{s}) \\ S_{2}(\omega_{k}) \exp(-j\omega_{k}3 \cdot T_{s}) \end{pmatrix} + \begin{pmatrix} b_{11} \exp[-j\omega_{k}\tau_{2}(\theta_{1})] & b_{21} \exp[-j\omega_{k}\tau_{2}(\theta_{2})] \\ 0 & 0 \\ 0$$

$$\begin{array}{cccc} b_{12} & b_{22} \\ b_{12} \cdot \exp[-j\omega_k \tau_2(\theta_1)] & b_{22} \cdot \exp[-j\omega_k \tau_2(\theta_2)] \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{array} \right) \begin{pmatrix} U_1(\omega_k) \cdot \exp(-j\omega_k T_s) \\ U_2(\omega_k) \cdot \exp(-j\omega_k T_s) \\ U_1(\omega_k) \cdot \exp(-j\omega_k 2T_s) \\ U_2(\omega_k) \cdot \exp(-j\omega_k 2T_s) \\ U_2(\omega_k) \cdot \exp(-j\omega_k 2T_s) \end{pmatrix}$$
(Ec.3.5.6)

Por simplicidad se ha excluido el vector de ruido de los sensores  $N(\omega)$  y se ha supuesto que la respuesta en amplitud de cada sensor con respecto a cada fuente vale la unidad. Es lo que denominamos versión ARMA extendida (ARMAExt). La

matriz de covarianzas correspondiente a la parte derecha de la Ec.3.5.6 sería  $\mathbf{R}_{s}(\omega_{k},\theta) = \mathbb{E} \left[ \mathbf{A}(\alpha,\theta,\omega_{k}) \mathbf{S}(\omega_{k}) + \mathbf{B}(b,\theta,\omega_{k}) \mathbf{U}(\omega_{k}) \right] (\mathbf{A}(\alpha,\theta,\omega_{k}) \mathbf{S}(\omega_{k}) + \mathbf{B}(b,\theta,\omega_{k}) \mathbf{U}(\omega_{k}) \right].$  A efectos prácticos esta parte derecha es lo que llamamos, al igual que en Ec.3.5.3 o Ec.3.5.4, señal sintética y  $\mathbf{R}_{s}(\omega_{k},\theta)$  matriz de covarianzas sintética.

Operar directamente en la expresión matricial anterior implica realizar búsquedas multidimensionales, que requieren a su vez de intensas y complejas computaciones numéricas, ya que para cada juego de direcciones DOA a estimar,  $\boldsymbol{\theta} = [\theta_1, \dots, \theta_L]^T$ , tenemos que construir una nueva matriz  $\mathbf{A}(a, \theta, \omega)$  y  $\mathbf{B}(b, \theta, \omega)$ . Al igual que hacíamos con el método basado en el modelado autorregresivo, podemos reducir la carga computacional aislando las direcciones en  $\mathbf{A}(a, \theta, \omega)$  y  $\mathbf{B}(b, \theta, \omega)$ . Luego, la expresión anterior se transforma en:

$Y_1(\omega)$	$Y_1(\omega_k)$ $Y_1(\omega_k)$	$\left(a_{11}S_1(\omega_k)\cdot\exp(-j\omega_kT_s)\right)$	$a_{21}S_2(\omega_k) \cdot \exp(-j\omega_k T_s)$
$Y_2(\omega$	$Y_2(\omega_k)$ $Y_2(\omega_k)$	$a_{11}S_1(\omega_k)\cdot\exp(-j\omega_kT_s)$	$a_{21}S_2(\omega_k)\cdot\exp(-j\omega_kT_s)$
$Y_{3}(\omega$	$Y_3(\omega_k)$ $Y_3(\omega_k)$	$S_1(\omega_k) \cdot \exp(-j\omega_k T_s)$	$S_2(\omega_k) \cdot \exp(-j\omega_k T_s)$
$Y_4(\omega$	$Y_4(\omega_k)$	$S_1(\omega_k) \cdot \exp(-j\omega_k T_s)$	$S_2(\omega_k) \cdot \exp(-j\omega_k T_s)$
$Y_5(\omega)$	$Y_5(\omega_k)$ $Y_5(\omega_k)$	0	0
$Y_6(\omega$	$Y_6(\omega_k)$	0	0
$Y_7(\omega$	$Y_7(\omega_k)$	0	0
$Y_8(\omega)$	$Y_{k}(\omega_{k})$ $Y_{8}(\omega_{k})$	( 0	0

\_ \_

\_

$b_{12}U_1(\omega_k) \cdot \exp(-j\omega_k 2T_s)$ $b_{12}U_1(\omega_k) \cdot \exp(-j\omega_k 2T_s)$ 0 0 0 0 0 0 0 0 0	$b_{22}U_{2}(\omega_{k}) \cdot \exp(-j\omega_{k} 2T_{s})$ $b_{22}U_{2}(\omega_{k}) \cdot \exp(-j\omega_{k} 2T_{s})$ $0$ $0$ $0$ $0$ $0$ $0$	0 0 0 0 0	0 0 0 0 0 0 0 0	$\exp[-j\omega_{k}\tau_{2}(\theta_{1})]$ $\exp[-j\omega_{k}\tau_{2}(\theta_{2})]$ $\exp[-j\omega_{k}\tau_{2}(\theta_{1})]$ $\exp[-j\omega_{k}\tau_{2}(\theta_{2})]$ $\exp[-j\omega_{k}\tau_{2}(\theta_{1})]$ $\exp[-j\omega_{k}\tau_{2}(\theta_{2})]$
0 0 0	0 0 0	0 0 0	0 0 0)	$\exp[-j\omega_k \tau_2(\theta_1)]$ $\exp[-j\omega_k \tau_2(\theta_2)]$

(Ec. 3. 5. 7)

forma La esta última ecuación compacta que presenta  $\mathbf{es}$  $\mathbf{Y}_{E}(\omega_{k}) = [\mathbf{A}(a, \mathbf{S}, \omega_{k}) + \mathbf{B}(b, \mathbf{U}, \omega_{k})] \Theta(\omega_{k})$  donde  $\mathbf{Y}_{E}(\omega_{k})$  es la matriz extendida de la salida de los sensores,  $A(a, S, \omega_k)$  es la matriz de señal y coeficientes,  $B(b, U, \omega_k)$  es la matriz de excitación y coeficientes, y  $\Theta(\omega_k)$  es la matriz de direcciones. A partir de la expresión Ec.3.5.7 resulta evidente que  $A(a, S, \omega_k)$  y  $B(b, U, \omega_k)$  pueden ser formadas antes de buscar sobre el juego de direcciones, reduciendo así la carga computacional. Nuevamente, tenemos separada la contribución de la señal de las fuentes respecto de sus direcciones. Es lo que denominamos versión ARMA extendida rápida (ARMAExtFast). La matriz de covarianzas correspondiente a la parte derecha de la Ec.3.5.7 sería  $\mathbf{R}_s(\omega_k, \theta) = \mathbf{E}[((\mathbf{A}(\alpha, \mathbf{S}, \boldsymbol{\Sigma}, \omega_k) + \mathbf{B}(b, \mathbf{U}, \omega_k)) \Theta(\omega_k))]$  $((\mathbf{A}(\alpha, \mathbf{S}, \boldsymbol{\Sigma}, \omega_k) + \mathbf{B}(b, \mathbf{U}, \omega_k)) \Theta(\omega_k))^+]$ . A effect os prácticos esta parte derecha es lo que llamamos, al igual que en *Ec.3.5.3* o *Ec.3.5.4*, señal sintética y  $\mathbf{R}_{s}(\omega_{k},\theta)$  matriz de covarianzas sintética.

Ahora podemos definir la función de búsqueda. Está basada en la matriz de covarianzas de las muestras  $\mathbf{R}_{YE}(\omega_k) = \mathbf{E}[\mathbf{Y}_{\mathrm{E}}(\omega_k), \mathbf{Y}_{\mathrm{E}}(\omega_k)^+]$  y la matriz de covarianza de la señal de fuente  $\mathbf{R}_{S}(\omega_k)$ . Luego, el método autorregresivo y de medias móviles de la agrupación extendida para la estimación DOA es:

$$\min_{\left[\theta_{1},\ldots,\theta_{L}\right]}\sum_{\omega_{k}\in 2\pi B/F_{S}}\left\|\mathbf{R}_{YE}(\omega_{k})-\mathbf{R}_{S}(\omega_{k},\theta)\right\|_{F}$$
(Ec.3.5.8)

donde F es la norma de Frobenius. Así que el proceso de estimación consiste en determinar el conjunto de **\theta** para las cuales *Ec.3.5.8* es mínima.

#### • Algoritmo basado en el modelado ARMA y la descomposición de polos

La base de partida de este método es poder realizar estimaciones DOA de alta resolución en situaciones donde se desconoce la covarianza espacial de ruido, así como las ganancias de la agrupación de sensores. La metodología propuesta conlleva el modelado de las fuentes como procesos autorregresivos de medias móviles. Seguidamente se forma una matriz virtual de datos, que es independiente de la ganancia de los sensores y de la covarianza del ruido. La factorización de esta matriz virtual de datos muestra que las técnicas basadas en el subespacio pueden aplicarse directamente para estimar la DOA de cada fuente. Esta técnica tiene la ventaja de no requerir ni el conocimiento sobre la covarianza del ruido del sensor ni de una calibración de la ganancia de los sensores.

La mayoría de los métodos DOA confían en la suposición de que el ruido aditivo de los sensores tiene una matriz de covarianza conocida y que el patrón de ganancia de los sensores también es conocido. Con frecuencia, en las aplicaciones prácticas, estas suposiciones no se cumplen. Por ejemplo, el ruido en los sensores puede ser provocado por ruido ambiente del medio altamente direccional y usualmente correlado a lo largo de la agrupación. El tráfico de barcos lejanos y las turbulencias oceánicas, son dos ejemplos claros de ruido con esas características. Además, por lo general, no suele disponerse del patrón de ganancia de los sensores en función de las perturbaciones físicas a que pueden verse sometidos. Estas imprecisiones pueden degradar severamente el rendimiento de estos algoritmos de estimación DOA. Por lo tanto, este es el contexto donde se debe enmarcar el método que vamos a describir [Zhou 1995].

Las señales de fuente  $\{s_i(t); i = 1, 2, ..., L\}$  se asumen estacionarias, de media nula y de banda ancha que pueden ser modelados como procesos ARMA de orden finito. Si las señales de fuente muestreadas pueden ser representadas por modelos ARMA, éstas satisfacen la recursión estocástica ya expresada en *Ec.3.5.1* y que retomamos:

$$s_{i}[n] = -\sum_{k=1}^{d_{i}} a_{ik} s_{i}[n-k] + \sum_{k=0}^{q_{i}} b_{ik} u_{i}[n-k]$$

donde  $s_i[n]$  denota los datos muestreados de  $s_i(t)$  en  $n \cdot T_s$ , n denota el índice temporal y  $T_s$  es el intervalo de muestreo.  $u_i[n]$  representa el proceso de ruido blanco y varianza unidad incorrelado con  $s_i(n)$ . La transformada Z para cada fuente puede escribirse como sigue:

$$S_i(z) = \frac{B_i(z)}{A_i(z)} \cdot U_i(z)$$

donde  $A_i(z)$  y  $B_i(z)$  son polinomios en  $z^{-1}$  estables de grado  $d_i$  y  $q_i$ , respectivamente, de esta manera el sistema será causal y estable. También asumimos que la función de transferencia  $B_i(z)/A_i(z)$  es apropiada, ej:  $q_i \leq d_i$ . Si la salida del sensor *m*-ésimo es  $y_m(n)$ , obtenida por muestreo de  $y_m(t)$  en  $n \cdot T_s$ , su transformada Z puede escribirse como:

$$Y_{m}(z) = \sum_{i=1}^{L} C_{m} \exp\{-j\omega_{k}\tau_{m}(\theta_{i})\}\frac{B_{i}(z)}{A_{i}(z)}U_{i}(z) + N_{m}(z)$$

Donde, L es el número de fuentes y  $C_m$  es la ganancia del sensor que, como veremos más adelante, no tendrá influencia. Por otro lado,  $\exp\{-j\omega_k \tau_m(\theta_i)\}$  es debido al retardo relativo de la fuente hasta llegar al sensor. Hemos supuesto que los sensores son omnidireccionales. Mediante  $N_m(z)$  representamos la transformada Z de  $n_m(n)$ , ruido del escenario captado por el m-ésimo sensor.

Definimos la secuencia de la covarianza cruzada entre las señales de las fuentes i-ésima y l-ésima como:

$$s_{il}(q) = E \left[ s_i(n) s_l^*(n-q) \right]$$

El espectro cruzado (o la transformada Z de la secuencia de covarianza cruzada sil(q)) entre las fuentes *i*-ésima y *l*-ésima viene dada por:

$$S_{il}(z) = \alpha_{il} \frac{B_i(z)B_l^*(1/z^*)}{A_i(z)A_l^*(1/z^*)}$$

donde  $\alpha_{il}$  es la covarianza entre  $s_i(n)$  y  $s_l(n)$  definida por:  $\alpha_{il} = E\left[u_i(n)u_l^*(n)\right]$ .

La secuencia de covarianza cruzada entre las salidas recibidas en los sensores *m*ésimo y *n*-ésimo puede ser escrita como:  $R_{mn}(q) = E\{y_m(i)y_n^*(i-q)\}$  y el espectro cruzado (en el dominio transformado Z) entre  $y_m(n)$  e  $y_n(n)$  está dado por:

$$R_{mn}(z) = \sum_{i=1}^{L} \sum_{l=1}^{L} \alpha_{il} C_m C_n \exp\left\{-j\omega_k(\tau_m(\theta_i) - \tau_n(\theta_l))\right\}$$

$$\times \frac{B_i(z)B_l^*(1/z^*)}{A_i(z)A_l^*(1/z^*)} + N_{mn}(z)$$
(Ec.3.5.9)

donde  $N_{mn}(z)$  es el espectro cruzado entre la salida de ruido de los sensores *m*ésimo y *n*-ésimo. Con las relaciones anteriores estamos listos para establecer el lema que viene a continuación:

*Lema*: Fijemos  $\lambda_{pq}$  como el polo q-ésimo de la señal de fuente p-ésima. Si las funciones de transferencia de las fuentes tienen diferentes polos y no tienen polos comunes con la misma multiplicidad se pueden establecer los siguientes límites

$$\lim_{z \to \lambda_{pq}} \frac{R_{mk}(z)}{R_{nk}(z)} \lim_{z \to \lambda_{pq}} \frac{R_{mk}^{*}(z)}{R_{nk}^{*}(z)} = \exp\left\{j2\omega_{k}(\tau_{m}(\theta_{p}) - \tau_{n}(\theta_{p}))\right\}$$
(Ec.3.5.10)

A continuación vamos a demostrar el lema anterior. Por simplicidad, consideramos el caso donde las funciones de transferencia de las fuentes no

tienen polos comunes y todos los polos son de orden uno. Las funciones de transferencia de las fuentes pueden ser expandidas como:

$$\frac{B_i(z)}{A_i(z)} = \sum_{r=1}^{p_i} \frac{V_{ir}}{1 - \lambda_{ir} z^{-1}}$$
(Ec.3.5.11)

donde  $V_{ir}$  es el residuo de  $B_i(z)/A_i(z)$  en  $\lambda_{ir}$ . Sustituyendo la ecuación Ec.3.5.11 en la ecuación Ec.3.5.9 obtenemos:

$$R_{mk}(z) = \sum_{i=1}^{L} \sum_{l=1}^{L} \alpha_{il} C_m C_k \exp\left\{j\omega_k(\tau_m(\theta_i) - \tau_k(\theta_l))\right\} \times$$

$$\sum_{r=1}^{p_i} \sum_{s=1}^{p_l} \frac{V_{ir}}{1 - \lambda_{ir} z^{-1}} \frac{V_{ls}^*}{1 - \lambda_{ls}^* z^{-1}} + N_{mk}(z)$$
(Ec.3.5.12)

Multiplicando tanto numerador como denominador en  $R_{mk}(z)/R_{nk}(z)$  por  $(1-\lambda_{pq}z^{-1})$  y tomando el límite, obtenemos:

$$\lim_{z \to \lambda_{pq}} \frac{R_{mk}(z)}{R_{nk}(z)} = \frac{V_{pq}C_{m} \exp(j\omega_{k}\tau_{m}(\theta_{p}))\sum_{l=1}^{S} \alpha_{pl}C_{k} \exp(-j\omega_{k}\tau_{k}(\theta_{l}))\sum_{s=1}^{p_{l}} \frac{V_{ls}^{*}}{1-\lambda_{ls}^{*}\lambda_{pq}}}{V_{pq}C_{n} \exp(j\omega_{k}\tau_{n}(\theta_{p}))\sum_{l=1}^{S} \alpha_{pl}C_{k} \exp(-j\omega_{k}\tau_{k}(\theta_{l}))\sum_{s=1}^{p_{l}} \frac{V_{ls}^{*}}{1-\lambda_{ls}^{*}\lambda_{pq}}} = \frac{C_{m}}{C_{n}} \exp\{j\omega_{k}(\tau_{m}(\theta_{p}) - \tau_{n}(\theta_{p}))\}$$
(Ec.3.5.13)

y, del mismo modo

$$\lim_{z \to \lambda_{pq}} \frac{R_{mk}^*(z)}{R_{mk}^*(z)} = \frac{C_n(\omega_k)}{C_m(\omega_k)} \exp\left\{j\omega_k(\tau_m(\theta_p) - \tau_n(\theta_p))\right\}$$
(Ec.3.5.14)

Estas ecuaciones Ec.3.5.13 y Ec.3.5.14 se combinan para dar lugar a la ecuación Ec.3.5.15. En ambas, hemos usado el hecho que:

$$\alpha_{il} = E\{u_i(n)u_l^*(n)\} = \left[E\{u_i(n)u_l^*(n)\}\right]^* = \alpha_{li}^*$$
(Ec.3.5.15)

Ahora consideraremos una situación más general donde varias de las funciones de transferencia de las fuentes comparten un polo común, pero con diferentes multiplicidades. Denotamos el polo común como  $\lambda_0$  con multiplicidad  $m_i$  para la función de transferencia de la fuente *i*-ésima. La expansión de Laurent de la función de transferencia de la fuente *i*-ésima sobre  $\lambda_0$  puede ser escrita como:

$$\frac{B_i(z)}{A_i(z)} = \sum_{l=0}^{\infty} \frac{\psi_i^{(l)}(\lambda_0)}{(z - \lambda_0)^{1 - m_i}}$$
(Ec.3.5.16)

donde

$$\psi_i(z) = (z - \lambda_0)^{m_i} \frac{B_i(z)}{A_i(z)}$$

Asumimos que la fuente *i*-ésima tiene la mayor multiplicidad  $m_i$  para  $\lambda_0$ . Para llegar a la ecuación Ec.3.5.10 se sustituye la ecuación Ec.3.5.16 en la ecuación Ec.3.5.12 y se multiplica numerador y denominador por $(z - \lambda_0)^{m_i}$ . Si un polo es común a varias fuentes con la misma multiplicidad este lema ya no es aplicable.

Usando el lema, estamos ahora listos para describir el algoritmo para la estimación de las DOA de cada fuente. El algoritmo desarrollado es un procedimiento de dos pasos. En el primer paso, se forma una matriz virtual de datos a partir de la agrupación de datos y de la estimación de los polos de fuente usando un modelo ARMA. En el segundo paso, se aplican técnicas basadas en el subespacio a la matriz virtual de datos para obtener las direcciones de llegada.

Para poder formar la matriz virtual de datos es necesario estimar los polos de fuente mediante alguno de los métodos propuestos en el apartado 3.5.1. A estos polos se les denota por  $\{\hat{\lambda}_{ir} \ i = 1, 2, ..., L \text{ and } r = 1, 2, ..., p_i\}$  donde  $p_i$  es el número de polos de la señal de fuente *i*-ésima. La matriz virtual de datos se define como la matriz Y de tamaño  $M \ge M$ , cuyos mn-ésimos elementos vienen dados por:

$$y_{mn} = \frac{1}{M} \sum_{i=1}^{L} \frac{1}{p_i} \sum_{r=1}^{p_i} \sum_{k=1}^{M} \lim_{z \to \hat{\lambda}_{ir}} \frac{R_{mk}(z)}{R_{nk}(z)} \frac{R_{nk}^*(z)}{R_{mk}^*(z)}$$

de acuerdo con la ecuación Ec.3.5.10, tenemos que:

$$y_{mn} = \sum_{i=1}^{L} \exp\left\{j2\omega_k(\tau_m(\theta_i) - \tau_n(\theta_i))\right\}$$

y se puede demostrar que la matriz *Y* puede ser factorizada como:

$$\mathbf{Y} = \mathbf{A} \cdot \mathbf{A}^{+} = \begin{bmatrix} \exp(j2\omega_{k}\tau_{1}(\theta_{1})) & \exp(j2\omega_{k}\tau_{1}(\theta_{2})) & \cdots & \exp(j2\omega_{k}\tau_{1}(\theta_{L})) \\ \exp(j2\omega_{k}\tau_{2}(\theta_{1})) & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ \exp(j2\omega_{k}\tau_{M}(\theta_{1})) & \cdots & \cdots & \exp(j2\omega_{k}\tau_{M}(\theta_{L})) \end{bmatrix} \times$$

$$\begin{bmatrix} \exp(-j2\omega_k\tau_1(\theta_1)) & \exp(-j2\omega_k\tau_2(\theta_1)) & \cdots & \exp(-j2\omega_k\tau_M(\theta_1)) \\ \exp(-j2\omega_k\tau_1(\theta_2)) & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \exp(-j2\omega_k\tau_1(\theta_L)) & \cdots & \cdots & \exp(-j2\omega_k\tau_M(\theta_L)) \end{bmatrix}$$

Se puede observar que la matriz A es similar en forma a la matriz de apuntamiento de la agrupación. La columna *i*-ésima de A está asociada con la fuente *i*-ésima y se expresa esto como:

$$a(\Theta_k) = \left[\exp(j2\omega_k\tau_1(\theta_i)), \exp(j2\omega_k\tau_2(\theta_i)), \dots, \exp(j2\omega_k\tau_M(\theta_i))\right]^{T}$$

donde  $\Theta = [\alpha, \beta]^T$  es el vector de parámetros DOA de fuente. Definimos el espacio columna de **A** como el subespacio de señal y su complemento ortogonal como el subespacio de ruido. También asumimos que la matriz **A** está llena.

El espectro cruzado de la agrupación de datos puede ser estimado mediante algún método clásico. A la hora de calcular la matriz virtual hemos optado por hacer la FFT de las covarianzas cruzadas y promediar para varias frecuencias entorno a la caracterizada en cada polo de cada fuente.

Después de que la matriz virtual de datos haya sido calculada, las técnicas basadas en el subespacio (p.ej., método MUSIC) pueden ser directamente aplicadas para obtener los parámetros de fuente DOA. El algoritmo de estimación quedaría como sigue:

- 1. Formamos la matriz virtual de datos  $\hat{\mathbf{Y}}$  y realizamos la descomposición en autovectores.  $\hat{\mathbf{E}}_N = [\hat{e}_{L+1}, \dots, \hat{e}_M]$  representa la estimación de los autovectores asociados al ruido como los *M*-*L* autovalores más pequeños de  $\hat{\mathbf{Y}}$ .  $\hat{P}_N = \hat{\mathbf{E}}_N \hat{\mathbf{E}}_N^+$  representa al operador de proyección ortogonal en el subespacio de ruido estimado. El número de fuentes se asume que es conocido.
- 2. Determinación de la DOA mediante la localización de los picos del espectro espacial expresado como

$$P(\Theta) = \left[a(\Theta)^{H} \hat{P}_{N} a(\Theta)\right]^{-1}$$

que justo es el inverso de la norma euclídea para la proyección de un continúo de vectores dirigidos sobre el rango de interés en el subespacio de ruido.

#### 3.5.4. Algoritmo de Identificación de Cachalotes

La identificación de uno o varios individuos dentro de una manada de cachalotes y su seguimiento individualizado, tiene aplicación en el estudio de sus hábitos,
hábitat en el que se mueven y comportamiento, principalmente cuando se encuentran sumergidos. Esta utilidad también sería de aplicable a la realización de censos de estos animales.

En general los métodos y algoritmos de identificación aplicados a los cetáceos se pueden entender más como métodos de clasificación, p.ej. en [Ghosh 1992, Fargues 1993, Gaetz 1993, Weisburn 1993, Fargues 1995, Huynh 1998 | podemos encontrar metodologías basadas en Modelos Ocultos de Markov (Hidden Markov Model, HMM) y en Redes Neuronales Artificiales (Artificial Neural Network, ANN). En cualquiera de ellos los algoritmos están ideados para identificar y separar los sonidos de distintas especies, con cierto grado de éxito, pero no lo están implícitamente para separar individuos de una misma especie. El algoritmo que proponemos en este apartado, recogido en [Hernández-Pérez 2004], está dirigido específicamente a la identificación de individuos de una misma especie, con el único requisito de que los sonidos puedan caracterizarse mediante procesos autorregresivos y de medias móviles. En este sentido respecto al cachalote en apartados anteriores hemos comprobado que los distintos sonidos emitidos por estos cetáceos son modelables tanto mediante procesos AR como ARMA. Sin embargo, existen otros cetáceos como p.ej. Ballenas Piloto, Delfines y Orcas, entre otros, que también emiten sonidos que presentan características susceptibles de caracterizarse mediante estos procesos. Por tanto, al menos para esas especies sería factible extender la aplicación de nuestro algoritmo de identificación.

El método que proponemos se basa en una filosofía algo diferente de lo que podemos encontrar en la bibliografía al uso, una particularidad de nuestro enfoque es que incluso los sonidos de varios individuos pueden llegar simultáneamente y no necesariamente aislados. Como ya anunciamos en el párrafo anterior asumimos que el proceso de producción es autorregresivo y de medias móviles, aunque para el propósito que nos ocupa, identificación, veremos que puede ser suficiente con contemplar sólo la producción autorregresiva, parte AR del modelo. Si pensamos en una agrupación de sensores como sistema de recepción submarina de los sonidos, el supuesto anterior conduce a una formulación matricial dependiente de la frecuencia para las señales en cada sensor. Para alcanzar nuestro objetivo aislamos la contribución de la señal de cada fuente de interés, sus coeficientes AR, el ruido generador de la esa señal y las direcciones de incidencia. Esto nos permite definir lo que denominamos una señal sintética de fuente que atiende a reproducir la contribución de cada fuente en un sensor determinado. Esto es así, ya que nuestro método realiza una búsqueda del conjunto de fuentes que minimizan la norma de la diferencia entre la señal sintética de fuente y la señal presente en el sensor.

## • Formulación del Modelo

Supongamos una ULA de M sensores de banda ancha igualmente espaciados  $D=\lambda_{\min}/2$ , donde  $\lambda_{\min}$  es la longitud de onda de la señal de frecuencia más alta dentro de la banda de interés. El escenario considerado cuenta con L fuentes incidiendo desde las direcciones  $\{\theta_i\}_{i=1}^L$ . Tanto las fuentes como el ruido de fondo se consideran procesos mutuamente incorrelados, ergódicos de segundo orden y

estacionarios, de media nula, de banda ancha con anchos de banda, B, idénticos. También vamos a suponer que el ruido es gaussiano.

Las señales en los sensores son el producto de la observación durante un intervalo finito de  $T_0$  segundos, suficientemente largo en comparación con la inversa del ancho de banda de las señales  $(B \cdot T_0 \gg 1)$ , muestreadas con un intervalo acorde con el criterio de Nyquist,  $F_s \ge 2 \cdot B$ , donde  $F_s$  es la frecuencia de muestreo. Así las cosas la salida del *m*-ésimo sensor vendrá dada por:

$$Y_m(\omega_k) = \sum_{i=1}^{L} c_m(\omega_k, \theta_i) \cdot S_i(\omega_k) \cdot \exp\left[-j\omega_k \cdot \tau_m(\theta_i)\right] + N_m(\omega_k)$$
(Ec.3.5.17)

donde m=0,...,M-1 siendo el sensor m=0 el de referencia,  $\omega_k \in 2\pi B/F_s$ ,  $c_m(\omega_k, \theta_l)$  es la respuesta direccional (que vamos a considerar omnidireccional) y en frecuencia del *m*-ésimo sensor,  $S_i(\omega_k)$  es la componente espectral a la frecuencia  $\omega_k$  de la fuente *i*-ésima,  $\tau_m(\theta_l)=m(D/c)\sin(\theta_l)=m\tau$ , así  $\tau$  será el retardo de propagación entre sensores, *c* es la velocidad de propagación y  $N_m(\omega_k)$  el ruido en el *m*-ésimo sensor. Si suponemos que el retardo de propagación sobre la agrupación al completo es menor que  $T_0/2$ , entonces ese retardo en el dominio temporal corresponde aproximadamente a un desplazamiento de fase en los coeficientes de Fourier. Por lo tanto,  $Y_m(\omega_k)$  puede asumirse como de media nula, asintóticamente gaussiana e incorrelada frecuencia a frecuencia en el rango  $2\pi B/F_s$ .

Otros detalles del contexto en que nos movemos en el desarrollo de este algoritmo nos lo proporcionan nuestros experimentos. Los citados resultados muestran la existencia de resonancias y antiresonancias en el espectro de los clics de cachalotes. Este hecho se refleja en la caracterización mediante parámetros AR y MA de dichas resonancias y antiresonancias, respectivamente, según podemos ver en los apartados 3.5.1 y 3.6.1, apoyados en [Hernández-Pérez 2003].Así que con el objeto de simplificar la formulación de nuestro método desarrollaremos únicamente el modelado autorregresivo (AR), en esta aplicación. Así las cosas, recordamos que la ecuación en diferencias en el dominio de la frecuencia que gobierna el proceso AR de las señales,  $S_i(\omega)$  es:

$$S_i(\omega_k) = \sum_{n=1}^d a_{in} \cdot S_i(\omega_k) \cdot \exp(-j\omega_k nT_s) + E_i(\omega_k)$$

donde  $a_{in}$  es el conocido coeficiente *n*-ésimo de la fuente *i*-ésima, *d* es el orden del modelo,  $T_s$  es el periodo de muestreo y  $E_i(\omega_k)$  es el ruido generador. Sin pérdida de generalidad el orden del modelo puede considerarse igual para todas las fuentes. Llegados a este punto procede incorporar este modelo en *Ec.3.5.17* y definir así la *Agrupación Extendida* en frecuencia. La expresión para las salidas extendidas de los sensores es:



**Figura 3.5.4.** Esquema de Bloques de un Sistema de Detección, Localización, Identificación y Seguimiento de Señales.

$$Y_{m}(\omega_{k}) = \sum_{i=1}^{L} c_{m}(\omega_{k}, \theta_{i}) \sum_{n=1}^{d} a_{in} \cdot S_{i}(\omega_{k}) \cdot \exp\left[-j\omega_{k} \cdot \tau_{m}(\theta_{i})\right] \cdot \exp\left(-j\omega_{k} nT_{s}\right)$$
$$+ \sum_{i=1}^{L} c_{m}(\omega_{k}, \theta_{i}) \cdot E_{i}(\omega_{k}) \cdot \exp\left[-j\omega_{k} \cdot \tau_{m}(\theta_{i})\right] + N_{m}(\omega_{k}); \qquad 1 \le m \le K$$

$$Y_m(\omega_k) = \sum_{i=1}^{L} c_m(\omega_k, \theta_i) \cdot S_i(\omega_k) \cdot \exp\left[-j\omega_k \cdot \tau_m(\theta_i)\right] \cdot \exp\left(-j\omega_k lT_s\right) + N_m(\omega_k)$$
$$K < m \le K(d+1) \qquad l = |(m-1)/K|$$

donde  $\lfloor (m-1)/K \rfloor$  expresa el mayor de los enteros menor o igual a (m-1)/K. En forma matricial la expresión anterior sería:

$$\mathbf{Y}(\omega) = \mathbf{A}(a,\theta,\omega)\mathbf{S}(\omega) + \mathbf{A}'(\theta,\omega)\mathbf{E}(\omega) + \mathbf{N}(\omega)$$
 (Ec.3.5.18)

donde  $\mathbf{Y}(\omega)$  de rango  $K(d+1)\times 1$  es el vector extendido de las salidas del sensor, la matriz de los coeficientes y apuntamiento es  $\mathbf{A}(a, \theta, \omega)$  de dimensión  $K(d+1)\times(L\cdot d)$ ,  $\mathbf{S}(\omega)$  de rango  $L\cdot d\times 1$  es el vector extendido de señal,  $\mathbf{A}^{*}(\theta, \omega)$  es la matriz de apuntamiento de dimensión  $K(d+1)\times L$ ,  $\mathbf{E}(\omega)$  de rango  $L\times 1$  es el vector excitación, y  $\mathbf{N}(\omega)$  de rango  $K(d+1)\times 1$  es el vector extendido de ruido.

Una vez establecido el contexto y definido nuestro marco analítico pasamos a exponer nuestro enfoque para la identificación, donde explotamos toda la información expuesta para cumplir con nuestro propósito. Es importante recordar que nuestro trabajo debe ser visto en un contexto más general de modelado de señal, detección, localización, identificación y seguimiento, Figura 3.5.4. Aunque en este apartado dejamos a un lado la detección y la localización ya tratadas en otros apartados, y el seguimiento que trataremos más adelante. Por lo tanto, pondremos atención únicamente en la identificación suponiendo que las otras tareas están ya realizadas adecuadamente. En nuestro desarrollo para afrontar el problema de la identificación hemos de hacer las siguientes suposiciones sobre la agrupación de sensores y las fuentes.

- 1. El número de señales y sus correspondientes direcciones de incidencia son conocidas. El número de sensores no está restringido a ser mayor que el número de fuentes. Esto es una consecuencia de la naturaleza de banda ancha de las señales, así como de la incorporación de los coeficientes  $a_{in}$ . Tanto el orden AR como los coeficientes son también conocidos.
- 2. Las L fuentes podrían ser estadísticamente dependientes. Esto se debe a que para un individuo podríamos tener varias realizaciones que lo caractericen.
- 3. El conjunto de los L(d+1) vectores de apuntamiento son linealmente independientes .
- 4. El ruido es gaussiano, ergódico de segundo orden y estacionario, de media nula, además es un proceso con matriz de covarianzas **C**. Condición que consideramos valida durante cada observación de  $T_0$  segundos.

En base a la suposición 4 y operando sobre *Ec.3.5.18* el vector de la función densidad de ruido  $N(\omega)$  sería:

$$\mathbf{N}(\omega) = \mathbf{Y}(\omega) - \mathbf{Y}'(\omega)$$

donde  $\mathbf{Y}'(\omega) = \mathbf{A}(a, \theta, \omega)\mathbf{S}(\omega) + \mathbf{A}'(\theta, \omega)\mathbf{E}(\omega)$ . Dado el supuesto 4 podemos definir la siguiente función de densidad de probabilidad para el ruido.

$$f(N) = \frac{1}{\pi^{L} |\mathbf{C}|} \exp[-\mathbf{N}(\omega)^{+} \mathbf{C}^{-1} \mathbf{N}(\omega)]$$

En la expresión anterior obviando los términos constantes y después de realizar algunas simplificaciones, si aplicamos logaritmos obtendríamos el identificador de máxima verosimilitud (ML).

$$\mathbf{L}(a,\theta) = -\sum_{\omega \in 2\pi B/F_s} \log |\mathbf{C}| + \sum_{\omega \in 2\pi B/F_s} [-\mathbf{N}(\omega)^+ \mathbf{C}^{-1} \mathbf{N}(\omega)]$$

que se resuelve mediante el siguiente problema de optimización.

$$a_{opt} = \arg\min_{a} \sum_{\omega \in 2\pi B/F_s} \left\{ \log(|\mathbf{C}|) + \mathbf{N}(\omega)^H \mathbf{C}^{-1} \mathbf{N}(\omega) \right\}$$
(Ec.3.5.19)

Esta minimización se aplica sobre todas las posibles combinaciones de las L fuentes. Esto es, para un conjunto de direcciones conocidas  $\{\theta_i\}^{L_{i=1}}$  buscamos todas las combinaciones de coeficientes de fuente para incorporarlas en **Y**'( $\omega$ ). La combinación o combinaciones de  $a_{opt}$  para los cuales la *Ec.3.5.19* es mínima determinan las fuentes presentes en el escenario. La matriz **C** debe estimarse previamente a la identificación durante los periodos en los cuáles no se detecta señal.

## 3.5.5. Algoritmo Conjunto de Localización, Identificación y Seguimiento

En los apartados anteriores de este mismo capítulo hemos ido desgranando los bloques fundamentales de un algoritmo capaz de ejecutar la tarea de localización, identificación y seguimiento como un todo. Así, en el apartado 3.3.1 expusimos un algoritmo de detección, en los apartados 3.3.2 y 3.3.3 estudiamos distintas técnicas para hacer localización angular mediante estimación de la dirección de incidencia (DOA). En los apartados 3.5.1, 3.5.2 y 3.5.3 ampliamos este último aspecto, introduciendo en la detección de la DOA modelado AR y ARMA. Además, en el apartado 3.5.4 presentamos nuestro algoritmo de identificación. Sólo nos falta aplicar metodologías de seguimiento, como las vistas en el apartado 3.4. Por tanto, disponemos ya de nuestras propias herramientas para amalgamar el que hemos denominado *algoritmo conjunto de localización, identificación y seguimiento*.

El algoritmo *conjunto de localización, identificación y seguimiento* puede trabajar de uno de los dos modos siguientes: un primer modo (Modo1), Figura 3.5.5, donde una vez detectada, localizada e identificada una determinada fuente se realiza su seguimiento, a partir de ese momento sólo trabaja con esa fuente. En este modo si en la base de datos no existe esa fuente se procede a incorporarla. Y un segundo modo (Modo 2), Figura 3.5.6, que busca a una fuente, previamente elegida, y cuando la encuentra realiza su seguimiento, rechazando cualquier otra fuente presente en el escenario.

La primera etapa, tal y como podemos ver en el diagrama de flujo de las Figuras 3.5.5 y 3.5.6 es la detección. Mediante este proceso discernimos las señales presentes frente al ruido de fondo en la entrada de la agrupación. Una vez extraídas las señales de interés, en nuestro caso clics de cachalotes, aplicamos el algoritmo de DOA. Según los resultados que veremos en el apartado 3.6, se pone de manifiesto que el algoritmo que mejores prestaciones nos ofrece es el ARMAExtFast, *Ec.3.5.8*. Dada la forma en que trabaja este algoritmo (ver apartado 3.5.3) es necesario estimar el modelo ARMA de la señal detectada, previamente a la estimación de la DOA. Como las mejores prestaciones de este algoritmo se consiguen con un orden AR = 10 y MA = 9 (ver Figura 3.6.15), lo utilizaremos así con modelado ARMA(10,9).



Figura 3.5.5. Diagrama de Flujo del Algoritmo conjunto de localización, identificación y seguimiento en Modo 1.



Figura 3.5.6. Diagrama de Flujo del Algoritmo conjunto de localización, identificación y seguimiento en Modo 2.

La etapa siguiente es la identificación. Dado que en la etapa anterior se calcula el modelo, aquí lo utilizamos para conocer si en nuestra base de datos se encuentra esa fuente, aplicamos para ello el algoritmo dado en *Ec.3.5.19*. Una vez hecha la identificación continuaremos con la siguiente etapa, si no fuera una fuente conocida ésta podría ser incorporada a la base de datos. Dependiendo del modo en que trabaja este algoritmo la siguiente etapa cambia. Así, si estamos en el Modo 1, Figura 3.5.5, pasamos directamente a la etapa de seguimiento, en esta etapa se asocian las fuentes con sus trayectorias, al tiempo que mediante filtrado de Kalman y en función de su historia pasada se suavizan estas. En cambio si se trata del Modo 2, Figura 3.5.6, sólo pasaremos a la etapa de seguimiento cuando la fuente detectada y localizada coincida con la fuente que se está buscando.

El algoritmo de seguimiento que contiene el proceso planteado en esta etapa se fundamenta en un vector de estado o movimiento y uno de medidas de la DOA. Como ya avanzamos en 3.4, con este enfoque parece adecuado un filtrado de Kalman. Luego, con estas premisas para la etapa indicada como "Seguimiento" en los diagramas de las Figuras 3.5.5 y 3.5.6, se desarrolla el algoritmo indicado en Figura 3.5.7. Como podemos ver el primer proceso incluye el algoritmo de DOA, que en nuestro caso es el mismo que junto con la detección inicializan el algoritmo, tanto en Modo 1 como en Modo 2. Aunque en este caso constituye el proceso de medida necesario en el algoritmo de seguimiento.

La inicialización del algoritmo de seguimiento necesita al menos dos medidas consecutivas de DOA, de ahí que el proceso completo no se inicia hasta tener k=1. Esto es así ya que vamos a suponer que las fuentes de interés presentan una aceleración nula o despreciable. Con las dos estimas (medidas) de DOA construimos el vector de estados que alimenta la ecuación de movimiento, eso será para k = 1, por la razón ya expuesta. Así las cosas el vector de estado resultante de la ecuación de movimiento será:

$$\hat{\mathbf{x}}_{i}(1|1) = \begin{bmatrix} \hat{\theta}_{i}(1|1) \\ \hat{\theta}_{i}(1|1) \end{bmatrix} = \begin{bmatrix} \hat{\theta}_{i}(1) \\ T^{-1} \begin{bmatrix} \hat{\theta}_{i}(1) - \hat{\theta}_{i}(0) \end{bmatrix}$$

donde T es el intervalo de muestreo. Seguidamente la ecuación de medidas en esta primera pasada quedaría de la forma siguiente:

$$\hat{z}_i(1) = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} \hat{\theta}_i(1 \mid 1) \\ \hat{\theta}_i(1 \mid 1) \end{bmatrix}$$

En el último paso de este algoritmo aplicaremos directamente la ecuación de Kalman, ecuación donde la ganancia de Kalman, L, viene dada por la Ec.3.4.5. Expresión donde entre otros términos tenemos la matriz de covarianzas del error  $\mathbf{P}_{i}$ , en nuestro caso dicha matriz se obtiene mediante:



Figura 3.5.7. Diagrama de Flujo detallado de la etapa de Seguimiento.

$$\mathbf{P}_i = \mathbf{F} \cdot \mathbf{V} \cdot \mathbf{F}^T + \mathbf{Q}$$

donde **V** es la matriz de covarianzas a priori, **Q** es la matriz de covarianza del sistema y **F** es una matriz cuya expresión viene dada por *Ec.3.4.3*, aunque en nuestro caso al no considerar la aceleración se reduce a la siguiente:

$$\mathbf{F} = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}$$

Estas matrices de covarianzas se van actualizando a lo largo del proceso, conforme van evolucionando las medidas y las estimas del vector de estados.

# 3.6 Experimentos y Resultados

En el segundo apartado de este capítulo hemos presentado los fundamentos de una herramienta de simulación que nos servirá de base para realizar una serie de experimentos con los que obtener resultados y poder llegar a conclusiones. La primera parte de los experimentos los dedicamos al estudio de los clics de cachalotes con vistas a conocer la bondad del modelado AR y ARMA. A tal efecto, estudiamos desde varios aspectos (p.ej., tipo de clic) el error de reconstrucción de señal con el objeto de conseguir una minimización del mismo. Nos preguntamos, también, por la calidad de los modelos vistos en términos de la función de transferencia o, concretamente, cómo se sitúan en frecuencia las resonancias y los mínimos de transmisión en términos de lo esperable a partir de un análisis tiempo-frecuencia.

Una vez aceptada la validez del modelado ARMA para las señales de nuestro interés pasamos a comprobar cómo se consiguen estimaciones de DOA específico de fuentes, esto es, conocida la fuente a través de su modelos abordamos su localización espacial. La batería de experimentos se ha diseñado de forma incremental añadiendo nuevos aspectos a estudiar conforme avanzamos en los mismos. Experimentamos con conceptos como dirección de incidencia desde el broadside al endfire, orden de los modelos, comportamiento con la SNR, tiempo de cómputo, prestaciones en función del número de sensores, comportamiento con una o dos fuentes simultáneas con diferentes niveles relativos de potencia.

Una vez evaluados los métodos de DOA pasamos al problema de identificación de fuente a nivel de individuo. Dicha evaluación se realiza para una serie de individuos en diversas condiciones de incidencia, SNR y trayectorias seguidas.

Finalmente, abordamos el problema de localización, identificación y posterior seguimiento de individuos. Para ello diseñamos experimentos en los que se sigue una trayectoria para la que se determinan la localización espacial y se aplica un filtrado de Kalman específico.

# 3.6.1. Resultados del Modelado de Clics de Cachalotes Mediante Procesos AR y ARMA

Los resultados se evaluarán desde tres puntos de vista. En primer lugar, el número de parámetros necesarios con cada método de estimación. En segundo lugar, la calidad de la función de transferencia a la hora de caracterizar en que frecuencias están las resonancias y los ceros de transmisión, así como la importancia relativa dentro del espectro. Y en tercer lugar, la calidad del error de reconstrucción y su valor cuadrático medio.

Por otro lado, hemos de tener en cuenta que disponemos de clics generados por distintos individuos. Luego, para validar que una determinada metodología sea la idónea habrá que comprobar que su comportamiento presenta las mismas bondades para un gran número de ellos.



Figura 3.6.1. Error cuadrático medio de reconstrucción, MSE, para los métodos MYWE, basado en las ecuaciones modificadas de Yule Walker, y TSLS.

#### • Error de Reconstrucción: MYWE vs. TSLS

En este primer apartado vamos a mostrar los resultados obtenidos al evaluar ambas metodologías. El parámetro que hemos elegido para esta comparación es el Error Cuadrático Medio (MSE, Mean Squared Error) de reconstrucción evaluado en dB tal como se presento en el apartado 3.5.1. Hemos tomado un conjunto (60 en este caso) suficientemente representativo de la variedad de clics de cachalotes de nuestra base de datos, *Voces Cetus* [Hernández 2002], y los hemos modelado con procesos ARMA(p,q) mediante cada uno de los dos métodos, MYWE y TSLS. Para ello hemos escogido valores de orden AR, p, desde 1 a 30, e igualmente para el orden MA, q. Así, evaluamos el MSE en dB con cada pareja de órdenes [p,q]. Obtenemos así un valor MSE para clic y conjunto de órdenes procediendo entonces a un promediado del MSE, para la totalidad de los clics considerados y un conjunto de órdenes determinado. Con la totalidad de los valores MSE promediados se confeccionaron las gráficas presentadas en la Figura 3.6.1.

Una primera observación gruesa que podemos hacer es que mientras MYWE presenta valores MSE entorno a los -30 dB, en el método TSLS están fundamentalmente alrededor de los -40 dB. En general, a igualdad de orden del modelo la diferencia del error es de unos 10 dB. Una observación algo más detenida nos lleva a decir que en el método MYWE, el incremento del orden AR o MA presenta una disminución del MSE, aunque no muy significativa y para órdenes mayores que 20. Mientras, en el TSLS la mejora es continua conforme se



**Figura 3.6.2.** Influencia de los órdenes AR y MA sobre el error cuadrático medio de reconstrucción para TSLS.



**Figura 3.6.3.** Órdenes AR y MA para el valor mínimo entre -30 y -35 dB de mse para un conjunto de clics modelados con el método MYWE.

incrementan los órdenes del proceso ARMA. En la Figura 3.6.2 podemos ver, con algo más de detalle, la influencia que tienen la rama MA y la AR del proceso en los valores de MSE para TSLS. El incremento en el orden AR conlleva una disminución del MSE en más de 10 dB. Sin embargo, la pendiente de reducción de MSE no es tan acusada cuando incrementamos el orden MA, sobre todo cuando el orden AR usado ya es elevado.

Otro experimento que hemos realizado, dentro de este mismo apartado, es el relativo a los órdenes necesarios para un valor MSE recogido en un cierto margen. Así en la Figura 3.6.3 podemos ver para un conjunto de clics cuáles son las parejas de órdenes AR y MA que nos procuran un mínimo. Dado que en el caso del método MYWE, recogido en la Figura 3.6.3, se alcanzan valores MSE



**Figura 3.6.4.** Órdenes AR y MA para el valor mínimo entre -35 y -40 dB de mse para un conjunto de clics modelados con el método TSLS.



**Figura 3.6.5.** Representación de los tres primeros picos espectrales y los polos de las funciones de transferencia obtenidas mediante los métodos MYWE y TSLS para un conjunto de clics.



**Figura 3.6.6.** Representación de los tres primeros valles espectrales y los ceros de las funciones de transferencia obtenidas mediante los métodos MYWE y TSLS para un conjunto de clics.

menores que en el método TSLS, ver Figura 3.6.1, el umbral escogido va de -30 a -35 dB. Mientras que en la Figura 3.6.4 presentamos el mismo experimento pero para el método TSLS y un umbral comprendido entre -35 y -40 dB. En estas dos últimas figuras hemos dispuesto el orden MA y cada clic individual en los ejes horizontales y el orden AR en el vertical. Lo primero que destaca entre ambos es que en el caso del método MYWE las parejas de órdenes aparecen más dispersasy con un grupo apreciable de clics que necesitan hasta orden 15. De hecho se observa una destacable concentración entre 10 y 25. Sin embargo, en el método TSLS prácticamente todo está acotado entre órdenes 10 y 10 como máximo, pero aún es posible observar una gran concentración entre los órdenes 5 y 5. Esto muestra que con órdenes bajos podemos conseguir con TSLS iguales o mejores prestaciones que con MYWE. Hemos de puntualizar que esas parejas de órdenes así obtenidas para el caso TSLS, Figura 3.6.4, están dando valores de MSE bastante más bajos que el caso MYWE. Una última lectura sería la poca importancia que para el método MYWE representa la rama MA.

## • Calidad de la Función de Transferencia estimada

En este apartado vamos a evaluar cualitativamente los métodos empleados a la hora de ubicar los polos y ceros espectrales más relevantes de la señal. Para ello hemos cogido un conjunto de señales de cachalotes, concretamente clics y los hemos analizado espectralmente en primer lugar. Para cada uno de esos clics hemos obtenido sus modelos ARMA(10,10) mediante los métodos MYWE y TSLS, del total de polos y ceros de las funciones espectrales modeladas escogemos los tres primeros y los representamos junto con los picos espectrales. Obtenemos de este modo para el caso de los polos, resonancias, la Figura 3.6.5 y para los ceros, nulos de transmisión, la Figura 3.6.6.

Para el caso de los polos, Figura 3.6.5, observamos que ambos métodos se ajustan bien a los de frecuencias más bajas, aunque siempre con mayores desviaciones para el caso MYWE. Prácticamente todos los polos calculados mediante el TSLS se ajustan siempre a los picos del espectro, pocos son los casos donde vemos que estos queden lejanos a dichos picos espectrales. Sin embargo, para el caso MYWE las desviaciones son apreciables claramente, sobre todo para frecuencias por encima de los 8000 Hz.

En la Figura 3.6.6 podemos contemplar la precisión que tienen ambos métodos para "capturar" las caídas espectrales profundas, mediante los ceros de las funciones de transferencia. Aquí todavía son más destacadas las derivas de los ceros estimados mediante el método MYWE, siendo mucho menores y en muchos casos prácticamente nulas las derivas de los ceros colocados mediante el método TSLS.

## • Error de Reconstrucción para Clics, Creaks y Gunshots

Los sonidos producidos por los cachalotes fueron catalogados por parte de diferentes autores [Watkins 1977, André 1997], existiendo alguna pequeña base de datos [Hernández 2002] donde se recogen ejemplos de cada uno de ellos. Estos sonidos reciben las denominaciones de: clics, creaks, codas, clangs o gunshots, llegando algunos autores a reportar también como sonidos diferenciados a los conocidos como clics rápidos y clics lentos. Estos últimos son secuencias de clics de 20 por segundo y uno cada 6 segundo respectivamente, sin embargo su base fundamental son los clics del que podemos decir que es por excelencia la base de prácticamente todos, excepto creaks y clangs o gunshots que son muy diferentes. El caso de las codas es bastante particular ya que son clics emitidos com distintas



**Figura 3.6.7.** Diferencia entre la señal original y la sintética para un clic obtenida mediante el modelado por los métodos MYWE y TSLS.



**Figura 3.6.8.** Modelado de creaks mediante los métodos MYWE y TSLS. Presentación espectral y funciones de transferencia (a), reconstrucción temporal de la señal (b), ampliación de la reconstrucción de la señal (c) y error de reconstrucción muestra a muestra (d).

diferencias temporales entre ellos, secuencias que son repetidas varias veces, si las escuchamos tienen la apariencia de un acorde musical, se cree que tienen como finalidad algún tipo de comunicación entre los individuos de una manada.

Hemos visto en los apartados anteriores cómo ambos métodos bajo estudio se comportan desde varios puntos de vista, aquí vamos a observarlos desde la óptica de la reconstrucción de la señal. Justo el apartado anterior trataba de cómo modelan el espectro de la señal. Sabemos que mediante esos modelos obtenemos las funciones de transferencia de esos procesos, luego con la excitación adecuada se podrá reconstruir la señal, señal sintética en ese caso. La calidad de la reconstrucción la vamos a evaluar de manera cualitativa en este apartado para los tipos de señales nombrados en el titulo del apartado. Aunque este aspecto también ha sido evaluado en el apartado dedicado al estudio de la relación entre el orden del modelo y el valor MSE, aquí lo veremos desde otra óptica.

En la Figura 3.6.7 presentamos el error de reconstrucción obtenido mediante los métodos MYWE y TSLS, dado sobre un conjunto de clics, donde por conveniencia de la representación se ha sumado un 'off-set' de 4 a uno de los métodos. Igual que para la Figura 3.6.6 se ha usado un ARMA(10,10). La lectura es representativa de la dinámica de la diferencia, que es muy superior en el caso del método MYWE que en el TSLS dando lugar así a la idea de que a la hora de modelar clics el método TSLS es mejor.

Los sonidos denominados creaks tienen la apariencia de una secuencia de impulsos de muy corta duración, con una separación muy corta entre ellos, el número de impulsos por segundo es muy elevado y se piensa que su utilidad es la ecolocalización fina, ya que los cachalotes suelen emitir estos sonidos cuando están sumergidos a grandes profundidades en busca de sus presas. Por esta circunstancia estos sonidos se suelen captan con menor frecuencia. De cualquier forma, a continuación vamos a ver como los métodos bajo estudio modelan estos sonidos, para ello hemos recortado una señal de estas escogiendo sólo dos impulsos consecutivos.

Si observamos con detalle la Figura 3.6.8(a) vemos que aunque ambos métodos ubican las resonancias y nulos de transmisión más relevantes, es el método TSLS quién logra centrarlos mejor e incluso caracterizar alguna resonancia más que el método MYWE. Pero donde resulta más evidente la diferencia entre ambos es en la reconstrucción temporal de la señal, Figura 3.6.8(b) y (c). La ampliación practicada sobre la Figura 3.6.8(b), Figura 3.6.8(c) visualiza mejor esto, el seguimiento de la señal practicado mediante el modelado TSLS se ajusta muy bien a esta, no así el método MYWE que en general se dispersa mucho más. Por último, y para clarificar aún más la calidad de la reconstrucción de la señal mediante ambos métodos, en Figura 3.6.8(d) se representa el error de reconstrucción para cada muestra, un examen detenido revela que ambos métodos cometen más errores en los tramos de señal más intensa, siendo muy superior el nivel del error cometido con la reconstrucción practicada mediante el método MYWE.

Otro sonido característico pero que suele escucharse un menor número de veces que los clics e incluso que los creaks, es el denominado clang o gunshot. Su utilidad no parece ser una sola o al menos la comunidad científica al respecto no



Figura 3.6.9. Representación temporal del sonido denominado clang o gunshot.



**Figura 3.6.10.** Modelado de gunshot mediante los métodos MYWE y TSLS. Presentación espectral y funciones de transferencia (a), reconstrucción temporal de la señal (b), ampliación de la reconstrucción de la señal (c) y error de reconstrucción muestra a muestra (d).

tiene una sola respuesta. Unos autores creen que los cachalotes los utilizan para aturdir a sus presas y otros que los emiten como signo de madurez.

Dentro del conjunto de sonidos producidos por lo cachalotes, estos son los de mayor duración e intensidad y no suelen repetirse muy seguidos uno del otro, en la Figura 3.6.9 se representa una muestra de estos sonidos. Como se observa se trata de un sonido con duración algo por encima de los 150 ms, de gran intensidad y con la apariencia de un impulso amortiguado de ruido.

En la Figura 3.6.10 vemos distintas ilustraciones resultado de la caracterización del gunshot mediante los métodos MYWE y TSLS. En el modelado espectral no es posible apreciar cualitativamente quien realiza un mejor seguimiento de las resonancias y nulos de transmisión principales. Si miramos con algo más de detalle parece que MYWE realiza un mejor seguimiento. Sin embargo, en la reconstrucción de la señal sigue siendo menor el error de reconstrucción para el TSLS que para el MYWE aunque la diferencia no es tan alta como en los casos anteriores.

## • Error de Reconstrucción en Función del Clic

En apartados anteriores hemos evaluado de diversas formas el error de reconstrucción. Primeramente lo estudiamos de una manera objetiva, promediando este error para la totalidad del conjunto de clics, así como para todas las parejas de órdenes posibles desde [1,1] hasta [30,30]. Posteriormente lo hemos hecho de una manera más cualitativa, mostrando visualmente los resultados y permitiendo una comparación no directamente numérica.

Para finalizar, vamos a ver el MSE en dB de una manera individualizada, clic por clic, eso sí para un conjunto de órdenes cerrado.

La obtención de los resultados incluidos en este apartado lleva consigo la toma de 60 clics y el modelado de cada uno con parejas de órdenes AR y MA fijas. Así conseguimos modelos ARMA(2,2), ARMA(20,2), ARMA(10,10) y ARMA(20,20), cuyos resultados aparecen en la Figura 3.6.11. Resultados que pasamos a comentar. Una primera observación, sería que para todos los casos y clics, siempre obtenemos un valor MSE mas bajo con el método TSLS. Los clics utilizados tienen valores SNNR comprendidos entre 5 y 12 dB, justamente los de SNNR por encima de 10 dB dan lugar a modelos MYWE y TSLS de valores MSE por debajo de la media, llegándose en estos casos a diferencias pequeñas entre ambos métodos. La "ganancia" en términos de MSE del TSLS sobre el MYWE está en promedio sobre los 10 dB. Mientras el MYWE no parece muy sensible a los parámetros MA, el TSLS nos muestra que el incremento del orden MA hace disminuir el MSE de manera apreciable, Figura 3.6.11(d), Figura 3.6.11(c) y Figura 3.6.11(e). Sin embargo, MYWE parece más sensible al incremento en el orden AR.

# 3.6.2. Simulaciones con los Algoritmos de Estimación DOA Específico de Fuentes AR y ARMA. Una fuente

En el apartado anterior hemos comprobado las prestaciones de los modelos disponibles para la caracterización de los clics. El siguiente paso, congruente con



**Figura 3.6.11.** Estudio del error de reconstrucción para un conjunto de clics modelados con ARMA(p,q) para ambos métodos TSLS y MYWE. ARMA(20,2) (a), ARMA(20,20) (b), ARMA(10,10) (c), ARMA(2,2) (d) y ARMA(2,20) (e).

nuestros objetivos, será usar esos modelos adaptados a un algoritmo de DOA, algoritmo que por esa circunstancia será un algoritmo específico de fuente. Así que, a seguidamente vamos presentar los resultados obtenidos en las distintas simulaciones. Estas han sido llevadas a cabo con los algoritmos de banda ancha de nuestra cosecha, así como con aquellos otros que tomamos como referencia, es decir, en cierta manera aquellos con los que competimos.



**Figura 3.6.12.** Resultados para cada algoritmo en función de la DOA, AR(2) en (a) y ARMA(2,1) en (b).

Concretamente nuestros referentes serán los métodos STMV y SRMV, ya presentados en el apartado 3.3. Abreviadamente nuestros algoritmos son ARExt y ARExtFast derivados del Algoritmo de Estimación DOA Específico de Fuentes AR presentado en el apartado 3.5.2. Los restantes son los Algoritmos de Estimación DOA Específico de Fuentes ARMA que hemos denominado ARMAExt y ARMAExtFast, y presentado en 3.5.3. Por último, con la denominación ARMAPol proponemos una aplicación a clics de cachalotes del algoritmo presentado en 3.5.3 para modelado ARMA y descomposición de polos. Los experimentos se realizarán utilizando 116 clics recogidos de nuestra base de datos.



Figura 3.6.13. Comparativa de los mejores algoritmos en función de la DOA.

#### • Comparación en función de la dirección de incidencia

En este primer apartado vamos a probar cada uno de los algoritmos DOA, anteriormente mencionados, evaluando y comparando sus resultados con direcciones de llegada que van desde 0° hasta 90° en pasos de 5°. El escenario que simulamos en este primer bloque de experimentos se compone de dos sensores, espaciados media longitud de onda respecto de la frecuencia máxima de trabajo, y una única fuente incidente, fuente que modelamos mediante procesos de orden 2 para la parte AR y un orden menos para la parte MA, por tanto AR(2) y ARMA(2,1). Dado que vamos a utilizar un total de 116 clics distintos, realizaremos 116 estimaciones para cada una de las direcciones a probar. El objetivo es conseguir dos medidas estadísticas, suficientemente significativas, sobre los resultados obtenidos. Las medidas en que nos vamos a centrar como más significativas para nuestros propósitos son la *Exactitud* y la *Precisión*. Entendemos que cuanto más próxima sea la media de las estimaciones al valor real, menor será el error de la estimación y, por tanto, mayor la Exactitud del algoritmo.

Una medida de la Precisión del algoritmo la encontraremos observando la desviación entre estimaciones, cuanto más corta sea la dinámica de esas desviaciones mayor será la Precisión. La SNR para este primer conjunto de experimentos la vamos a establecer en 100 dB, esto es, señal limpia.

En primer lugar, en la Figura 3.6.12(a) comparamos los algoritmos de referencia STMV y SRMV, con los que sólo emplean modelado AR. Como podemos ver nuestros algoritmos presentan menor exactitud y precisión que el STMV que se mantiene incluso para incidencias más allá de los 80°. Con respecto al SRMV es posible indicar que ni su exactitud ni su precisión llegan a los niveles del STMV, pero si supera a todos los restantes en exactitud aunque no en precisión. La precisión de algoritmos tales como ARExt y ARExtFast a partir de ángulos por



Figura 3.6.14. Influencia del orden de los procesos AR y ARMA en la Exactitud y la Precisión. Dirección de incidencia fija en 10° (a), 60° (b) y 80° (c).

encima de los 60° aparece superior a la del SRMV. En segundo lugar, en la Figura 3.6.12(b) comparamos los algoritmos que incorporan modelado autorregresivo y de medias móviles. Al igual que con AR, se sigue observando menor exactitud y precisión de los algoritmos ARMAExt y ARMAExtFast con respecto al STMV. El método que hemos denominado ARMAPol, presenta mejor exactitud que los

anteriores, sin llegar a los niveles del STMV o del SRMV. Su precisión es inferior a la del STMV, pero superior a la del SRMV. Además, este algoritmo supera los resultados de exactitud y precisión del SRMV para DOAs por encima de los 75°. Es de destacar también que a partir de los 80° el ARMAExtFast iguala y posteriormente supera la exactitud del SRMV, también la precisión.

Para precisar algo más los resultados, en la Figura 3.6.13 hemos reunido a los algoritmos STMV, SRMV, ARMAPol, ARExtFast y ARMAExtFast. Queda patente que una clasificación, excluyendo a los algoritmos tomados como referencia, en base a los parámetros puestos en juego en estos primeros experimentos sería, Figura 3.6.12(a) y 3.6.12(b): primero ARMAPol, segundo ARMAExtFast y tercero ARExtFast.

## • Influencia del orden de los procesos ARMA y AR

Los resultados que presentamos en este apartado nos ayudaran a comprobar cuál es el orden de modelado que mejores prestaciones nos proporciona. Para ello el escenario de la simulación sigue siendo el de una agrupación de 2 sensores y una única fuente, caracterizada mediante procesos AR y ARMA de órdenes variables en este caso. La relación señal a ruido será de 100 dB y haremos simulaciones para fuentes emitiendo en tres direcciones fijas, 10°, 60° y 80°.

Si atendemos detenidamente al conjunto de la Figura 3.6.14 destaca que el algoritmo ARMAPol no presenta una tendencia hacia una mejora continua con el incremento del orden, sino que presenta un salto entre orden 6 y 7, con un cambio de pendiente hacia el empeoramiento progresivo con el incremento del orden. Su precisión también tiene un comportamiento algo errático con el orden del proceso, así mientras para órdenes bajos presenta buena precisión para órdenes superiores no, aunque no de una manera absoluta. El orden que proporciona la mejor exactitud para una DOA de 10° es 5 (Figura 3.6.14(a)), para DOA de 60° también es 5 (Figura 3.6.14(b)) y para la de 80° es un orden 9 (Figura 3.6.14(c)).

El resto de los algoritmos presentan mejoras en la exactitud con el incremento del orden, aunque excepto los algoritmos ARMAExt y ARMAExtFast, los restantes a partir del orden 4 no alcanzan mejoras destacables. Para los algoritmos ARMAExt y ARMAExtFast sí que se obtienen mejoras cuasi continuas en la exactitud y también en la precisión. De entre estos dos métodos destacamos el ARMAExtFast que para DOAs de 10° (Figura 3.6.14(a)) y 60° (Figura 3.6.14(b)) con un orden 10 alcanza una muy buena exactitud con buena precisión. Para DOA de 80° los algoritmos ARMAExt y ARMAExtFast hasta orden 5 presentan malos resultados y a partir de ahí conforme incrementamos el orden se consiguen mejoras en la exactitud y también en la precisión. Los algoritmos ARExt y ARExtFast, por el contrario, presentan un comportamiento oscilante, es decir con altibajos, Figura 3.6.14(c), por tanto las mejoras no son continúas con el incremento del orden. Se puede observar en la Figura 3.6.14(c) que para ARExt se alcanza la máxima exactitud con un orden 4, mientras que para ARExtFast la obtenemos con orden 8.



Figura 3.6.15. Comparativa en función de la DOA con órdenes "óptimos".

Respecto a la precisión en esa misma gráfica tampoco se pueden hacer comentarios categóricos, dado que de un orden a otro hay casos donde se suceden mejoras para empeorar un orden más arriba. Sin embargo, ambos algoritmos se comportan mejor para las DOAs de 10° y 60°, aunque con diferencias entre ellos. Así por ejemplo para ARExt y DOA de 10° vemos que el orden óptimo se encuentra en 7, mientras que para ARExtFast está en 5. Cuando la DOA alcanza el valor de 60° el orden óptimo para ARExt es y para ARExtFast es 5. Nuevamente se confirma una inestabilidad en estos algoritmos con respecto a ARMAExt y ARMAExtFast, que presentan más uniformidad en el valor óptimo en función de la DOA.

En base a estos resultados hemos realizado un nuevo experimento: comprobar la exactitud y la precisión en la determinación de la DOA cuando empleamos los órdenes, digamos óptimos, es decir aquellos que según los resultados presentados en el conjunto Figura 3.6.14, nos proporcionan la mejor exactitud para cada algoritmo. Para ello repetimos algunos de los experimentos llevados a cabo en la obtención de las figuras: Figura 3.6.12 y 3.6.13. Para simplificar, hemos tenido en cuenta algunos resultados que veremos más adelante, así que hemos elegido para este nuevo experimento sólo los algoritmos ARMAPol, ARExtFast y ARMAExtFast con ódenes 5, 5 y 10 respectivamente, es decir modelos ARMA(5,4), AR(5) y ARMA(10,9) respectivamente. Los resultados se muestran en la Figura 3.6.15. Como cuestión más destacada subrayar que el algoritmo ARMAExtFast prácticamente iguala en exactitud al algoritmo STMV superando al SRMV. Sin embargo, en precisión donde parece un poco peor que el STMV y prácticamente igual a la del SRMV, sobre todo para incidencias por encima de los  $60^{\circ}$ .

Los otros dos algoritmos, ARMAPol y ARExtFast, presentan muy buenos resultados, aunque pierden exactitud a partir de los 60°. Además, se aprecia que la precisión del algoritmo ARMAPol está ciertamente por debajo a la del resto.



**Figura 3.6.16.** Influencia de la SNR en la exactitud y la precisión de los algoritmos. Dirección de incidencia fija en 10°. Algoritmos AR y referentes (a) y algoritmos ARMA y referentes (b).

#### • Comparando métodos de banda ancha en función de la SNR

Otro aspecto de gran interés para nuestros propósitos es evaluar los métodos en función de la SNR, máxime cuando nuestros algoritmos se diseñan para su empleo en ambientes ruidosos. En nuestro caso, la localización de fuentes inmersas en un medio con ruido de fondo de intensidad variable. Por ejemplo, el ruido propio del buque donde vaya instalado el sistema puede ser elevado en momentos determinados (navegación rápida) o el ruido producto de las olas sobre el casco del buque. Luego, entendemos que es de gran interés realizar experimentos donde el parámetro variable sea la SNR. El escenario considerado será el mismo descrito anteriormente y los experimentos se realizarán para las direcciones DOA de 10°, con resultados en la Figura 3.6.16, 60° en la Figura 3.6.17 y 80° en la Figura 3.6.18. A las señales de nuestra base de datos y con objeto de alcanzar los valores SNR a simular, se le ha añadido ruido blanco gaussiano de media nula.

En la Figura 3.6.16 tanto en la (a) como en la (b) se observa que para SNR bajas, por debajo de los 5 dB, nuestros algoritmos superan a los utilizados como referencias en la exactitud, aunque no tanto en precisión. Comparando nuestros



**Figura 3.6.17.** Influencia de la SNR en la exactitud y la precisión de los algoritmos. Dirección de incidencia fija en 60°. Algoritmos AR y referentes (a) y algoritmos ARMA y referentes (b).

algoritmos entre si, se podría decir que los AR Figura 3.6.16(a) superan en precisión a los ARMA Figura 3.6.15(b).

La Figura 3.6.17 en (a) y (b) nos muestra prácticamente una repetición de los resultados que aparecen en la Figura 3.6.17, aunque con menor exactitud (recordamos Figuras 3.6.12 y 3.6.13). También la precisión para SNR por debajo de 5 dB es baja.

En la Figura 3.6.18(a) vemos nuevamente que los algoritmos que tienen un conocimiento específico de la fuente son más robustos para SNR bajas. Aunque la exactitud deja bastante que desear, sí que sigue siendo superior a la de los algoritmos usados como referentes. En la Figura 3.6.18(b) vemos que se sigue conservando la misma pauta, sólo que el algoritmo ARMAPol se descuelga presentando peores resultados, prácticamente iguales a los tomados como referencia para SNR bajas.

## • Tiempo de computación

Hasta aquí todos los experimentos cuyos resultados hemos mostrado estaban relacionados con la influencia en la exactitud y la precisión de los algoritmos para diversos parámetros. Sin embargo, también la velocidad de ejecución o tiempo de



**Figura 3.6.18**. Influencia de la SNR en la exactitud y la precisión de los algoritmos. Dirección de incidencia fija en 80°. Algoritmos AR y referentes (a) y algoritmos ARMA y referentes (b).



Figura 3.6.19. Comparativa del tiempo de computación promedio para un único clic.

computación es una prestación importante para cualquier algoritmo destinado a tareas de campo.



Figura 3.6.20. Comparativa del tiempo de computación promedio en función del orden del proceso respecto al algoritmo STMV.

Disponer de resultados en un tiempo prudencial puede ser de gran relevancia. Ese tiempo mínimo debe estar en consonancia con las necesidades de la aplicación, es decir cada cuanto tiempo necesito actualizar mis estimaciones para obtener así datos útiles.

A continuación presentaremos los resultados de dos experimentos. El primero ha consistido en el promediado de los tiempos necesarios para estimar la DOA por clic, para la totalidad de los algoritmos. El escenario considerado es el mismo utilizado en los experimentos anteriores. El ordenador donde se han realizado todos los experimentos es un PC con el sistema operativo Windows XP - Service Pack 3 con 3,24 GB de RAM y CPU de doble núcleo a 3 GHz. Para la realización del experimento se desconectó el ordenador de la red de datos. Además, se procedió a la eliminación de todos aquellos procesos no estrictamente necesarios para el funcionamiento mínimo de la maquina. La experiencia de repitió un número suficiente de veces que seguidamente fueron promediadas.

A la hora de representar la carga computacional, tiempo de computación, que emplea cada uno de los algoritmos hemos optado por una representación comparativa, Figura 3.6.19, es decir partiendo de aquel de menor tiempo de computación, los demás se comparan con él en número de veces el tiempo del menor. Así la escala en ordenadas resultante es comparativa y refiere el número de veces que ese algoritmo tarda en resolver la DOA de un único clic, respecto a una unidad que es el tiempo de computación del algoritmo más veloz.

Es importante reseñar que los modelos autorregresivos empleados fueron AR(2) y los autorregresivos de media móvil ARMA(2,1). El número de sensores fue de 2.

Se podría decir que en la Figura 3.6.19 tenemos un escalón bien marcado. El comentado escalón lo ocupan, ordenados del más rápido al más lento, ARMAPol, STMV, ARMAExtFast y ARExtFast, que resultan entre 16 y 22 veces más lentos.



Figura 3.6.21. Comparativa de algoritmos DOA en función del número de sensores.

El algoritmo SRMV resulta ser el más veloz, sobre los 5 ms por clic. Por encima del "escalón" tenemos al ARExt que es unas 37 veces más lento y el ARMAExt que emplea unas 46 veces el tiempo que emplea el SRMV por clic.

Nuestros algoritmos usan coeficientes AR y MA, según el caso. El número de coeficientes crece con el orden del modelo empleado y también la precisión en la reconstrucción de la señal. En experimentos anteriores vimos que para determinados algoritmos el incremento del orden del modelo conlleva mejores prestaciones de exactitud y precisión. Luego, se hace necesario cualificar este hecho en cuanto a coste computacional. Es por ello que seguidamente en la Figura 3.6.20 podemos ver los resultados de cómo influye el orden del modelo en el tiempo de computación por clic para cada algoritmo. Al igual que en la Figura 3.6.19, en Figura 3.6.20 representamos una comparativa, en este caso con respecto al tiempo de computo por clic en el STMV, que según los resultados que hemos desgranando hasta aquí se le puede considerar el objetivo a alcanzar.

Haciendo una lectura de los resultados mostrados en la Figura 3.6.20, podemos ver al menos tres subdivisiones claras. La primera formada por el algoritmo ARMAPol, la segunda formada por ARMAExtFast y ARExtFast y la tercera por los restantes, ARMAExt y ARExt. La primera subdivisión nos muestra que incrementar el orden por encima de orden 4 no supone un aumento significativo en el tiempo de computación. La siguiente subdivisión engloba a los algoritmos ARMAExtFast y ARExtFast hacen algo similar a partir de orden 4, llegando para un orden 10 a quintuplicar y sextuplicar el tiempo necesario en el algoritmo STMV, respectivamente. El algoritmo ARMAPol para ese mismo orden no llega a duplicar ese tiempo. La última subdivisión, integrada por ARMAExt y ARExt presenta una pendiente incremental del tiempo de computación hasta el orden 4, que es como un punto de inflexión, y a partir de ahí la pendiente cambia haciéndose más suave. Los algoritmos de esta última subdivisión están entre 10 y 20 veces por encima del STMV cuando alcanzan el orden 4, mientras para orden



**Figura 3.6.22.** Comportamiento en un escenario con 2 fuentes del algoritmo STMV (a) y ARExtFast (b).

10 encontramos incrementos que van des<br/>de las 25a las 40veces el tiempo necesario <br/> con el STMV.

#### • Comparando algoritmos en función del número de sensores

Una última pregunta que nos hacemos es si es posible mejorar las prestaciones de los algoritmos DOA específicos de fuente, basados en modelado ARMA y AR, a base de incrementar el número de sensores integrantes de la agrupación.

Para este experimento únicamente hemos considerado los algoritmos ARMAPol, ARExtFast y ARMAExtFast. El orden de los modelos ha sido 2 para la parte AR y 1 para la parte MA, por lo demás el escenario es el mismo que el utilizado en experimentos anteriores. La dirección de incidencia se ha considerado fija y de 60°. En la Figura 3.6.21 observamos que el empleo de un mayor número de sensores para la práctica totalidad de los algoritmos no supone mejoras apreciables.

# 3.6.3. Simulaciones con los Algoritmos de Estimación DOA Específico de Fuentes AR y ARMA. Dos fuentes

Los experimentos cuyos resultados hemos presentado en el apartado 3.6.2, nos han permitido estudiar y conocer mejor las capacidades de los algoritmos DOA desarrollados en esta tesis. En todos los casos el estudio se ha realizado bajo la consideración de una única fuente presente en el escenario. En este apartado vamos a considerar dos fuentes en el escenario manteniendo una agrupación de sólo dos sensores, excepto para el algoritmo de referencia, STMV, que por definición no puede usarse para un número de fuentes igual al número de sensores, por tanto para este algoritmo usaremos una agrupación de cuatro sensores.

En los experimentos que vamos a presentar aquí hemos buscado estudiar dos aspectos fundamentales: la capacidad de localización, trabajando con la presencia de dos fuentes en el escenario, modificando sucesivamente la DOA de cada fuente y de la SNR de ambas, también estudiamos la capacidad de resolución en base a la separación angular entre las dos fuentes. La influencia del orden del proceso en las prestaciones de los algoritmos en presencia de dos fuentes. Un último aspecto a evaluar es el comportamiento cuando las fuentes presentan distintas niveles de potencia. Tomando como base los resultados obtenidos con anterioridad, los experimentos que aquí presentamos se van a realizar tan sólo con los algoritmos ARMAPol, ARExtFast y ARMAExtFast, y como referencia tendremos al STMV.

# • Comparando algoritmos en función de la DOA en un escenario con dos fuentes

Para estos experimentos hemos supuesto la siguiente situación inicial: una fuente con una DOA de 90° y la otra con 0°, seguidamente las colocamos en 10° y 80° respectivamente y así seguimos de 10° en 10°, una hacia el End-fire y la otra hacia el Broad-side. En total tendremos 10 localizaciones. Las fuentes emiten la misma potencia y consideramos una SNR de 100 dB. Otros datos de interés son que los modelos usados son de orden 6 y las agrupaciones constan de 2 sensores, excepto para el algoritmo STMV donde empleamos 4 sensores.

Los resultados se mostrarán gráficamente, así para cada uno de los algoritmos usados presentaremos los dos resultados más significativos. Una gráfica a la izquierda mostrando la exactitud y la precisión de la estimación de la DOA para cada una de las dos fuentes. Otra gráfica a la derecha nos muestra las posiciones reales de ambas fuentes y las estimadas por el algoritmo en cuestión.



(b)

**Figura 3.6.23.** Comportamiento en un escenario con 2 fuentes del algoritmo ARMAExtFast (a) y ARMAPol (b).

En la Figura 3.6.22(a) tenemos los resultados para el algoritmo STMV con una agrupación de 4 sensores. El principal problema que presenta es que si las fuentes se cruzan, como ocurre en este experimento, se equivoca y trastoca las estimaciones. Eso se debe a que explícitamente no conoce a cada fuente por separado, ya que el algoritmo simplemente procesa una banda de señal donde aparecen dos picos en el espectro espacial. Por lo demás, mientras acierta en la asignación de las DOAs a cada fuente, este algoritmo nos muestra su gran exactitud y precisión. En la Figura 3.6.22(b) observamos los resultados para el ARExtFast, destacamos en primer lugar que no se yerra en la fuente cuando estas se cruzan, en exactitud vemos que tanto para una fuente como para la otra



**Figura 3.6.24.** Comportamiento en un escenario con 2 fuentes del algoritmo ARExtFast (a) y ARMAExtFast (b) para SNR de 10 dB.

presenta desviaciones de cierta importancia, hasta 9°, siendo la precisión buena. La exactitud decrece conforme la separación entre fuentes disminuye. Si lo comparamos con el STMV claramente los errores son mucho menores y su utilidad en un escenario con dos fuentes es superior.

En la Figura 3.6.23(a) están los resultados para el ARMAExtFast muy similares a los obtenidos para el ARExtFast, aunque ARMAExtFast presenta algo más de exactitud y similar precisión. Los resultados obtenidos para el ARMAPol que se pueden ver en la Figura 3.6.23(b) son muy malos no siendo capaz de distinguir entre fuentes, cometiendo errores inaceptables.



**Figura 3.6.25.** Comportamiento en un escenario con 2 fuentes del algoritmo ARExtFast (a) y ARMAExtFast (b) para SNR de 5 dB.

Los resultados se pueden ver en Figura 3.6.24 para una SNR de 10 dB, de manera que en Figura 3.6.24(a) tenemos el comportamiento del algoritmo ARExtFast y en Figura 3.6.24(b) el del algoritmo ARMAExtFast. La única observación destacable para ambos algoritmos es un levísimo empeoramiento de la exactitud. Para una SNR de 5 dB hemos obtenido los resultados de la Figura 3.6.25. Prácticamente entre las Figuras 3.6.24(a) y 3.6.25(a) no se distinguen



**Figura 3.6.26.** Comportamiento en un escenario con 2 fuentes del algoritmo ARExtFast (a) y ARMAExtFast (b) para SNR de 0 dB.

diferencias significativas, salvo leves reducciones de la exactitud y precisión. Para el caso del algoritmo ARMAExtFast mostrado en la Figura 3.6.25(b) los resultados sustancialmente son los mismos que los encontrados previamente en la Figura 3.6.24(b).

Por último, en la Figura 3.6.26 representamos los resultados para el caso de los 0 dB y tanto para el caso ARExtFast recogido en Figura 3.6.26(a) como para el ARMAExtFast presentado en Figura 3.6.26(b) no se observan diferencias dignas de interés.



**Figura 3.6.27.** Comparativa para dos fuentes con distinta separación. Medida de la Exactitud y la Precisión (a) y estimación de la dirección de incidencia (b).

# • Comparando algoritmos en función de la SNR en presencia de dos fuentes

Trataremos en este apartado de realizar experimentos para discernir las prestaciones que podemos esperar de los algoritmos en un escenario con fuentes y relación señal a ruido cambiante, concretamente vamos a contemplar valores SNR de 10, 5 y 0 dB. Además, sólo lo vamos a presentar para los algoritmos ARExtFast y ARMAExtFast.

#### • Comparando algoritmos en función de la separación entre dos fuentes

Ahora, en aras a estudiar con más detalle la capacidad de resolución de nuestros algoritmos, realizamos unos experimentos donde vamos a variar la separación angular entre las dos fuentes presentes en el escenario.



**Figura 3.6.28.** Comparativa para dos fuentes con distinta separación. Medida de la Exactitud y la Precisión (a) y de la dirección de incidencia (b).

Las condiciones de contorno usadas fueron una SNR de 100 dB para cada fuente, 4 sensores en el caso del algoritmo STMV y 2 sensores para los algoritmos ARExtFast, ARMAExtFast y ARMAPol, el orden empleado ha sido 6, las fuentes estaban ubicadas en campo lejano y en las parejas de direcciones siguientes:  $(2^{\circ}, -2^{\circ})$ ,  $(3, -3^{\circ}), (4, -4^{\circ})$  y  $(5, -5^{\circ})$  que en la siguiente gráfica son las posiciones 1 a 4.

Los resultados aparecen en la Figura 3.6.27, de manera que en la Figura 3.6.27(a) vemos la medida de la exactitud y de la precisión de los algoritmos antes citados. Antes de comentar estos y otros resultados es importante indicar cómo están organizadas estas gráficas, es decir, qué convenios hemos adoptado en la representación para distinguir cada cosa. Los trazos están realizados en sólo dos colores, rojo y azul, con el rojo identificamos a la fuente 1 que toma posiciones en
2°, 3°, 4° y 5° sucesivamente. Con el color azul a la fuente 2 que toma posiciones en -2°, -3°, -4° y -5° sucesivamente. Además, para cada algoritmo hemos elegido un mismo símbolo, así podemos identificar algoritmo y fuente a la que se refiere el trazo. Tal y como se ha descrito, vemos que los errores tienen signos contrarios para cada algoritmo según la fuente de la que se trate. Para los algoritmos ARExtFast y ARMAExtFast observamos una no muy buena exactitud, desviaciones entorno a los 8º para ARMAExtFast y por encima de los 9º ARExtFast, con una tendencia al "aumento" de la exactitud conforme aumenta la separación entre fuentes para el algoritmo ARMAExtFast. La precisión de ambos algoritmos la podemos calificar de aceptable. Sin embargo, para el algoritmo STMV encontramos que la exactitud va disminuyendo conforme se incrementa la separación, cuestión carente de toda lógica, salvo que si nos damos cuenta el color del trazo delata que parece estar ubicando mal a las fuentes. Esta cuestión se confirma en la Figura 3.6.27(b) donde claramente vemos como con una exactitud cuasi ideal, pero los colores de los trazos debidos al STMV están equivocados. Respecto a la precisión del algoritmo STMV también se le puede considerar muy buena. En el comportamiento del ARMAPol apreciamos que si nos atendemos sólo a la Figura 3.6.27(a) evidencia una exactitud buena y dependiente de la separación de las fuentes, con una disminución de la precisión conforme se incrementa la separación entre las fuentes. Sin embargo, al observarlo en la Figura 3.6.27(b) se aprecia que confunde a las fuentes y que prácticamente nos da siempre el mismo resultado.

#### • Comparando algoritmos en función del orden del modelo de señal

En presencia de una sola fuente hemos visto en resultados anteriores cómo los algoritmos mejoran en exactitud. La pregunta que nos hacemos es si esto se conserva cuando en el escenario existen dos fuentes en activo. El experimento se realiza con el mismo escenario de experimentos anteriores en lo relativo a la agrupación de sensores considerada, con la consabida diferenciación en el número de sensores para el algoritmo STMV. Hemos optado por disponer fuentes con dos separaciones distintas: 20°, fuente 1 en 10° y fuente 2 en -10°, y 30° de separación con fuente 1 en 15° y fuente 2 en -15°. El orden de los procesos lo hemos variado desde 2 hasta 10, para sección AR, y un orden menos que el AR para el orden MA.

Los resultados visibles en la Figura 3.6.28(a) para la separación de 20° y Figura 3.6.28(b) para la separación de 30° muestran casi una insensibilidad al orden de los procesos. Si realizamos una mirada detenida en la Figura 3.6.28(a) se observa que los algoritmos ARExtFast y el ARMAExtFast presentan una mejora de la exactitud para órdenes comprendidos entre 5 y 6, que es algo más significativa para el ARMAExtFast. Cuestión que se vuelve a repetir en la Figura 3.6.28(b) extendiéndose hasta el orden 7. Respecto al ARMAPol nuevamente nos encontramos con un comportamiento algo errático, p.ej., mientras que con la separación de 20° entre fuentes nos presenta el peor resultado para orden 4, ocurre lo contrario cuando la separación es de 30°, independientemente de esto hechos puntuales la exactitud es muy mala y prácticamente el incremento en el orden del proceso no mejora sus prestaciones, al menos de una manera significativa.

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



Figura 3.6.29. Resultados para diferencia de niveles entre fuentes igual a 10 dB. Algoritmos específicos de fuente ARExtFast (a), ARMAExtFast (b) y ARMAPol (c).

# • Comparando algoritmos en función de la diferencia de niveles entre fuentes

El experimento cuyos resultados vamos a exponer en este apartado evalúa la capacidad de los algoritmos, cuando las fuentes no tienen la misma amplitud. Concretamente vamos a evaluar situaciones donde una fuente tiene 3 dB, 6 dB y 10 dB menos que la otra. Concretamente fuente2 3dB por debajo de la fuente1, luego 6 dB y por último 10 dB. El resto del escenario es exactamente igual a los experimentos anteriores. Las fuentes se irán situando en 10 direcciones distintas, de modo que una empezará en  $0^{\circ}$  y terminará en  $90^{\circ}$  y la otra lo hará en  $90^{\circ}$  y finaliza en  $0^{\circ}$ , ambas con paso de  $5^{\circ}$ . En este caso en la simulación incluimos una particularidad adicional, esto es ambas fuentes llegan a coincidir en la misma dirección, exactamente sobre  $45^{\circ}$ .

De las tres relaciones de niveles empleadas en los experimentos en la Figuras 3.6.29 y 3.6.30 sólo hemos incluido los resultados obtenidos cuando la diferencia era de 10 dB, aunque comentaremos los resultados más significativos obtenidos para 3 y 6 dB.

Los resultados para el algoritmo ARMAPol, Figura 3.6.29(b), siguen siendo muy malos, aunque respecto a los obtenidos para fuentes del mismo nivel, se observa que los errores en las estimaciones de la fuente más potente mejoran, y esto lo hace en mayor medida cuando la diferencia entre ambas es de 10 dB, para 6dB es algo peor aunque mejor que para la diferencia de 3 dB. Este algoritmo sigue con buena exactitud a la fuente más potente hasta los 70°, a partir de ahí la exactitud se hace inaceptable. La precisión para esa misma fuente se hace inviable prácticamente a partir de los 60°. Para la fuente 2 los resultados son desastrosos tanto para la exactitud como para la precisión, esto viene a confirma una característica ya constatada anteriormente de este algoritmo, Figura 3.6.23(b), y es su incapacidad para separar las direcciones de las dos fuentes presentes en el escenario. Para las otras dos diferencias los resultados son de todo punto deficientes, encontrándose que conforme las fuentes van igualando sus niveles el algoritmo realiza estimaciones cada vez peores.

Los algoritmos específicos de fuente ARExtFast (Figura 3.6.29(a)) y ARMAExtFast (Figura 3.6.29(b)), presentan ambos capacidad para asociar dirección de incidencia y fuente correspondiente. Esto como vemos se mantiene inalterable aunque una de las fuentes este 10 dB por debajo de la otra, sobre todo si tenemos en cuenta que ambas fuentes comparten una misma zona espectral. Ambos algoritmos presentan una mejor exactitud cuando la separación entre las fuentes es grande y a la vez cuando la diferencia de niveles entre fuentes es nula o pequeña. Sin embargo, la precisión no se altera apreciablemente con la separación entre las fuentes, y si que lo hace con el nivel de la fuente, ya que en general los peores resultados para la precisión se obtienen para la fuente 2, en este caso la de menor nivel. Otra característica a destacar, es que aunque las dos fuentes estén emitiendo desde la misma dirección ambos algoritmos son capaces de encontrar a cada una por separado. En general el ARMAExtFast es levemente mejor, aunque ambos algoritmos presentan una exactitud baja, pero acotada en un máximo de 10°.

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



**Figura 3.6.30.** Resultados para diferencia de niveles entre fuentes igual a 10 dB para el Algoritmo STMV.

Por último el algoritmo STMV tomado como referencia, Figura 3.6.30, presenta un grave problema a la hora de asociar fuente y dirección de incidencia justo a partir del punto donde ambas se encuentran. Se observa que su exactitud para la fuente 1 hasta la DOA de 40°, mientras en ese mismo tramo para la fuente 2 es desastroso, la razón esta justo en que a partir de ahí asocia erróneamente fuente y dirección de incidencia. Para la fuente 2 presenta una exactitud razonable hasta 45°. Justo en 45° donde ambas coinciden el algoritmo da exactitud casi perfecta para una de ellas mientras que la otra la pone 20° más allá de su posición real. La precisión en aquellos casos donde la exactitud es buena también lo es, fuera de ahí es muy mala.

#### 3.6.4. Simulaciones con el Algoritmo de Identificación

Al algoritmo de identificación presentado en 3.5.4 lo hemos sometido a distintos experimentos a fin de evaluar sus prestaciones. En este apartado vamos a presentar estos resultados, comentando aquellas cuestiones más relevantes en relación con el producto de esos experimentos.

Para poder probar nuestro algoritmo hemos preparado una base de señales, clics de cachalotes. Estos clics han sido extraídos de registros sonoros obtenidos en campo, concretamente en las aguas de Gran Canaria, Tenerife y Fuerteventura [André 1997]. Por tanto, el ruido que acompaña a estos registros es ruido del medio marino y del propio barco usado como plataforma del sistema de registro. La base de señales que vamos a usar la hemos dividido en dos bloques bien diferenciados. Un primer bloque, S1, compuesto por 100 señales de clics cuya relación señal a ruido oscila entre 15 y 20 dB (niveles altos), y un segundo bloque con 201 señales, S2, donde los valores SNR varían entre 5 y 10 dB (niveles medios), Figura 3.6.31. Para todas y cada una de las señales de los dos bloques se han obtenido sus modelos autorregresivos óptimos, en el sentido de mínimo error de reconstrucción, para ello hemos considerando modelado de órdenes en el margen de 2 a 14.

Cap.3 – Agrupaciones Concentradas de Sensores -Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



Figura 3.6.31. Esquema del procesamiento realizado sobre las señales de las dos bases de señales empleadas en los experimentos.

Al utilizar nuestro algoritmo de identificación sobre estas bases de señales constatamos que en muchos casos había clics cuyos modelos eran muy similares en sus cualidades acústicas. La conclusión a la que llegamos es que en la base de señales el mismo individuo aparece varias veces, de hecho sabemos que el número de cachalotes que viven en esas aguas es bastante inferior al número de señales utilizadas. Luego, un mismo individuo puede haber sido registrado en distintas y diversas circunstancias. Estas circunstancias van desde un registro en días distintos con distintas condiciones de ruido, o incluso en el mismo día pero con el animal mirando a los sensores de la agrupación o de espaldas al mismo, más o menos profundidad, más o menos lejano, etc., condiciones todas ellas que cambian aspectos puntuales de la señal pero no los generales, de ahí que los modelos resultantes sean muy parecidos. En aras a contemplar esto para nuestras simulaciones hemos realizado un agrupamiento de aquellos modelos que resultan con un grado apreciable de similitud, Figura 3.6.32. Para hacerlo hemos usado la correlación cruzada frecuencial entre todos y cada uno de los clics, señales, presentes en la base de señales. Una vez obtenidas las citadas correlaciones, se agruparon todos aquellos clics que entre sí presentasen valores normalizados de la correlación superior a 0,6. En la Figura 3.6.32(a) cada marca representa una correlación normalizada superior al 0,6 y, por tanto, se asocian formando un grupo. Desde nuestro punto de vista el significado de esto es que pertenecen al mismo individuo o que son individuos acústicamente muy semejantes. Este hecho se ve reforzado mediante una inspección ocular. Sobre la misma figura y a modo de ejemplo hemos circundado algunos grupos. En la Figura 3.6.32(b) presentamos el resultado del mismo proceso para la base de señales de SNR media. Como resultado hemos obtenido que en bloque de señales S1 tenemos unos 34 individuos y en el S2 17 individuos, cantidades que resultan

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



Figura 3.6.32. Resultados del agrupamiento entre clics de la base de señales de alta SNR, bloque S1 (a) y baja SNR bloque S2 (b).

razonables con el conocimiento que tenemos de la población de cachalotes en estas aguas [André 2000].

El escenario considerado para los experimentos realizados consta de una agrupación con sólo dos sensores y una o dos fuentes incidentes. Las señales pueden incidir desde cualquier dirección, en cualquier caso no es objetivo de este algoritmo determinar la DOA, y si de los algoritmos vistos en los apartados correspondientes, algoritmos que precederán al de identificación. Sin embargo, para realizar los experimentos hemos probado con distintas direcciones de incidencia.

Un primer experimento para poner a prueba nuestro algoritmo de identificación ha sido simular la incidencia de un clic. A continuación comparamos este clic con

Dirección de Incidencia	SG	CG
0°	0,98	1
20°	0,98	1
<b>40°</b>	0,96	0,98
60°	0,94	0,98
80°	0,92	0,95

Tabla 3.6.1. Probabilidades de acierto para el bloque de señales S1.

Tabla 3.6.2. Probabilidades de acierto para el bloque de señales S2.

Dirección de Incidencia	SG	CG	
0°	0,74	0,98	
20°	0,76	0,99	
40°	0,8	0,99	
60°	0,82	0,99	
80°	0,83	1	

Tabla 3.6.3. Probabilidades de acierto con parejas de señales para el bloque de señales S1.

Direcciones de Incidencia	SG	CG	
[-3°,3°]	0,98	0,92	
[-30°,20°]	0,98	1	
[-40°,40°]	0,94	0,97	
[-60°,60°]	0,91	0,95	

las señales sintéticas obtenidas desde nuestra base de modelos AR. Además, en este primer experimento fuimos variando la dirección de incidencia. A partir de los resultados obtenidos calculamos la probabilidad de acierto, casos donde se identificaba correctamente el clic incidente con su modelo en la base de modelos AR. La experiencia se realizo con la totalidad de la base de señales considerada (SG) y con la base considerando los grupos encontrados (CG), el experimento se repitió para los dos bloques de señales creadas al efecto. Los resultados obtenidos se reflejan en la Tabla 3.6.1.

Dirección de Incidencia	SG	CG
[-3°,3°]	0,28	0,4
[-30°,20°]	0,51	0,7
[-40°,40°]	0,63	0,85
[-60°,60°]	0,72	0,95

Tabla 3.6.4. Probabilidades de acierto con parejas de señales para el bloque de señales S2.

**Tabla 3.6.5.** Probabilidades de acierto con parejas de señales en localizaciones variables de -90° a 90° para una fuente y 90° a -90° para la otra.

Bloque de Señales	SG	CG
S1	0,95	0,98
S2	0,56	0,77

Como podemos ver en la Tabla 3.6.1 los resultados sin agrupar (SG), ya de por sí muy buenos, mejoran levemente cuando consideramos los grupos (CG). Así mismo, se observa un empeoramiento de la probabilidad de acierto cuando la orientación tiende hacia los extremos de la agrupación, direcciones de incidencia casi paralelas a la agrupación.

En la Tabla 3.6.2 se presentan los resultados obtenidos para el bloque de señales S2. En este caso resulta bastante más significativo usar agrupamiento, CG, ya que de lo contrario las probabilidades caen significativamente con respecto a los valores obtenidos para el bloque de señales S1. Otro aspecto destacable de estos resultados es su aparente insensibilidad a la dirección de incidencia cuando consideramos el agrupamiento de señales, de hecho la probabilidad de acierto en la dirección de 80° es del cien por cien.

Con el siguiente experimento realizado, queremos comprobar las probabilidades de acierto cuando en el escenario hay dos fuentes ubicadas en direcciones distintas. Para ello hemos considerado las siguientes parejas de ángulos de incidencia [-3°,3°], [-30°,20°], [-40°,40°] y [-60°,60°]. La selección de las parejas de fuentes fue realizada de manera aleatoria, pero era la misma en todas las parejas de ángulos de llegada. En la Tabla 3.6.3 aparecen las probabilidades de acierto para el bloque de señales S1.

Al observar estos resultados podemos decir que funciona peor cuando la dirección de llegada entre las dos fuentes es cercana angularmente hablando. En cambio, al irse alejando el resultado mejora, pero tal y como pasaba en el experimentos anterior, una fuente, en este bloque de señales, el rendimiento es peor al irse acercando la dirección de llegada al endfire de la agrupación. Sin embargo, las



Figura 3.6.33. Resultado de la simulación del tercer experimento.

**Tabla 3.6.6.** Probabilidades de acierto en la identificación con parejas de señales y ángulos de incidencia se asignación aleatoriamente, y error aleatorio en la estimación DOA de  $\pm 5^{\circ}$ .

Bloque de Señales	SG	CG	
S1	0,93	0,95	
S2	0,37	0,75	

diferencias no son muy significativas. En la Tabla 3.6.4 se muestran las probabilidades de acierto para el bloque de señales S2.

Tal y como era de esperar, estos resultados son mucho peores que los de S1, debido a una menor SNR de estas señales. Podemos destacar que también aquí los resultados son peores cuando la dirección de llegada de las fuentes es cercana.

El tercer experimento que hemos realizado ha consistido en disponer un escenario con dos fuentes, seleccionadas aleatoriamente de entre las componentes de cada bloque de señales, S1 y S2. Inicialmente una fuente la situamos en la dirección de incidencia 90° y la otra en -90°. A continuación vamos variando esos ángulos desde 90° a -90° para una fuente y de -90° a 90° para la otra en pasos de 2°. En la Tabla 3.6.5 exponemos las probabilidades de acierto para cada uno de los casos contemplados, es decir bloque de señales S1, con y sin agrupamiento, y bloque de señales S2, también con y sin agrupamiento. Estos resultados muestran gran similitud con los anteriores. La Figura 3.6.33 recoge el resultado obtenido para el bloque de señales S1 con la opción SG. En la gráfica aparecen indicados con círculos las parejas correctamente identificadas, mientras que la cruces de color rojo indican parejas identificadas erróneamente.

El último experimento que presentamos consiste en una simulación, donde tanto las parejas de fuentes como las direcciones de llegada fueron seleccionadas aleatoriamente. También se hemos introducido un error aleatorio en la DOA para Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



**Figura 3.6.34.** Resultado del experimento con parejas seleccionadas aleatoriamente dentro del bloque de señales S2 sin agrupamiento (a) y con agrupamiento (b).

estudiar el efecto que tiene este tipo de errores en la identificación en sí. Este error está en el rango de ±5° sobre la dirección correcta. El resultado se puede observar gráficamente en la Figura 3.6.34, donde las parejas con las que realizamos la simulación se marcan con un círculo y las parejas identificadas se marcan con una cruz de color rojo. Para las parejas que han sido correctamente identificadas, el círculo y la cruz coinciden, no coincidiendo para las que no han sido correctamente identificadas. En la Figura 3.6.34(a) recogemos esta simulación para el caso en que para el bloque de señales S2 no usamos agrupamiento, numéricamente la probabilidad de acierto se recoge en la Tabla 3.6.6 con un valor de 0,37. Este resultado está bastante por debajo de los obtenidos con el bloque de señal S1, con y sin agrupamiento, recogidos en la primera fila de la citada tabla. Con respecto a los resultados recogidos en la Tabla 3.6.5, en la Tabla 3.6.6 donde único se experimenta un cambio significativo es justamente en el caso del bloque de señales S2 sin agrupamiento. Por lo tanto, los errores en la DOA afectan apreciablemente en el caso de señales con SNR medias, es decir por debajo de los 10 dB.

En la Figura 3.6.34(b) contemplamos los resultados cuando en el bloque S2 consideramos el agrupamiento. Al igual que describimos anteriormente aquí los círculos en azul contemplan las parejas reales y las cruces en rojo las parejas identificadas, la coincidencia entre círculos azules y cruces rojas indican identificación correcta, adicionalmente en esta gráfica aparecen círculos negros. Estos círculos negros circundan aquellas cruces rojas que no siendo una identificación directa si se encuentra dentro del grupo, por lo tanto pasa a ser una identificación correcta. En estas circunstancias en la Tabla 3.6.6 la probabilidad de aciertos sube hasta el 0,75.



Figura 3.6.35. Trayectoria seguida por la fuente acústica (trazo rojo) y perfil del fondo marino (trazo azul).

### 3.6.5. Simulaciones con Algoritmo Conjunto de Localización, Identificación y Seguimiento

Los resultados de los experimentos que presentaremos en este apartado beben en gran medida de los resultados obtenidos hasta ahora. Toda vez que por separado y hasta aquí, hemos establecido un proceso de "selección" de algoritmos, fundamentalmente de modelado de señales, de detección de dirección de incidencia y de identificación, todos ellos para señales específicas.

Antes de continuar hemos de precisar que en estos experimentos seguimos el algoritmo de localización, identificación y seguimiento en cualquiera de los modos presentados en el apartado 3.5.5. El escenario a considerar será el medio marino, concretamente aguas próximas a las islas Canarias, concretamente el tramo entre las islas de Gran Canaria y Tenerife. Para esta zona disponemos de medidas de batimetría, que nos permiten conocer los perfiles del fondo y de la velocidad de propagación, esenciales para poder sintetizar trayectorias de fuentes lo más próximas posibles a un escenario real. La profundidad de la zona e información de avistamientos hacen más que posible la presencia de estos animales.

Para los experimentos hemos usado nuestro simulador *Cetus3D*. Con su concurso hemos generado y simulado los fenómenos de propagación, para una fuente acústica (cachalote) siguiendo una determinada trayectoria, Figura 3.6.35. Esta trayectoria contempla una situación típica de inmersión durante una cacería para alimentarse hasta unos 1300 metros de profundidad, donde permanece un cierto tiempo con desplazamiento paralelo al fondo (búsqueda de presas), hasta 500 m y vuelta a la superficie. En horizontal el recorrido es de 3 Km.

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



Figura 3.6.36. Detalle del escenario simulado donde aparecen las dos agrupaciones contempladas y los modos de propagación.



Figura 3.6.37. Direcciones de incidencia para cada modo de propagación y posición de la fuente con la agrupación desplegada horizontalmente.

Ejemplos de este comportamiento los podemos ver en [Teloni 2003, Zimmer 2005a] entre otros. En estas circunstancias podemos considerar que la propagación (prácticamente) en línea recta. A partir de todo esto obtenemos las señales incidentes en cada uno de los sensores de la agrupación, en nuestro caso sólo dos sensores. Además, hemos contemplado dos orientaciones para esta agrupación, una vertical (perpendicular a la superficie) y otra horizontal (paralela a la superficie). La agrupación se ha situado a una profundidad de 40 metros.

#### • Experimento con agrupación horizontal

La disposición de la agrupación de hidrófonos es paralela a la superficie, según podemos ver en la Figura 3.6.36, y provoca que considerando los rayos directos la fuente se sitúe en DOAs que irán desde 90° a -90°. Sabemos, además, que el fondo y la superficie tienen efecto en la propagación. Entonces, vamos a suponer la llegada de señal a través de otros dos modos más. Estos modos adicionales serán la reflexión en la superficie y la reflexión en el fondo. Llamamos la atención sobre el perfil fondo que, según vemos en las Figuras 3.6.35 y 3.6.36, no es plano presentando pendientes de distintos valores y orientación.

En la Figura 3.6.37 se recogen las direcciones de incidencia para los modos de propagación directo, reflexión en la superficie y reflexión en el fondo, todo ello en función de la posición de la fuente. Observamos que hay dos modos, directo y reflexión en superficie, que prácticamente coinciden en sus direcciones de incidencia.

Por otro lado, la correspondiente al fondo permanece constante durante las primeras 300 posiciones, es decir mientras desciende, con algunas pequeñas inflexiones. También sucede igual hasta la posición 400, aunque con incidencia sobre el broadside de la agrupación. A partir de la posición 400 aparecen continuos cambios abruptos de dirección, esto se debe a la morfología del fondo cuando la fuente inicia el ascenso.

Conocidas las direcciones de incidencia construimos las señales presentes en cada uno de los hidrófonos, para ello suponemos una emisión de 190 dB de presión sonora y una relación señal a ruido de 20 dB.

El siguiente paso ha sido aplicar nuestro algoritmo de DOA, ARMAExtFast sobre las señales recibidas en la agrupación de sensores y el algoritmo de seguimiento. Los resultados los podemos ver en varias gráficas. Con cada una de las gráficas queremos mostrar un aspecto distinto de las prestaciones de nuestros algoritmos, ante los complejos fenómenos que se suceden en la propagación.

En la Figura 3.6.38 tenemos dos conjuntos de gráficas, están Figura 3.6.38(a), 3.6.38(c) y 3.6.38(e) que nos muestran respectivamente para el modo directo, modo por reflexión en superficie y modo por reflexión en el fondo, el error en la estimación de la DOA (simple diferencia con el real), cuando aplicamos sólo el algoritmo de DOA y cuando a este le aplicamos el filtro de Kalman. Se aprecia en todas ellas que en media la corrección e Kalman mejora la exactitud de la DOA estimada. En la Tabla 3.6.7 se refleja numéricamente este hecho, es decir en todos los casos la introducción de la corrección por filtro de Kalman introduce una mejora, reduciendo levemente los ya de por si valores bajos del RMSE. Es en los

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



**Figura 3.6.38.** Resultados de Error y RMSE segmentado para cada modo de propagación. Agrupación con despliegue horizontal.

algoritmo	RMSE	RMSE	RMSE
	Directo	Superficie	Fondo
ARMAExtFast	0,0915	0,0800	0,2747
ARMAExtFast con	0,0785	0,0736	0,1741
Filtrado de Kalman	(14%)	(8%)	(36%)

**Tabla 3.6.7.** Valor RMSE en función del modo de propagación y el algoritmo considerado.Agrupación con despliegue horizontal.



**Figura 3.6.39.** Direcciones de incidencia para cada modo de propagación y posición de la fuente con la agrupación desplegada verticalmente.

casos de valor RMSE mayor donde se observa una mejora más clara. Las propiedades correctoras del filtrado de Kalman aplicado quedan un poco infravaloradas con sólo mostrar las graficas comentadas y la tabla mencionada, es por ello que las gráficas presentadas en Figura 3.6.38(b), 3.6.38(d) y 3.6.38(f) tratan se mostrar su capacidad, digamos donde se le requiere. En estas figuras presentamos lo que hemos llamado el RMSE segmentado, consiste éste en agrupar un número (p.ej., 15) de estimas y sus corregidas, y calcular el error sobre ellas. La comparación así realizada permite zonificar la actuación correctora del filtro de Kalman y justo ese es el resultado que obtenemos. Podemos ver que justo en aquellas zonas donde el error cometido en la estimación es mayor, también lo es la corrección. Para el modo directo y el de reflexión en la superficie, esto ocurre en las direcciones cercanas al endfire y, para el modo por reflexión en el fondo justo en la zona donde mayores fluctuaciones se presentan, realizando en este caso correcciones bastante significativas. Sin embargo, en las

Cap.3 – Agrupaciones Concentradas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación de Cetáceos



**Figura 3.6.40.** Resultados de Error y RMSE segmentado para cada modo de propagación. Agrupación con despliegue vertical.

algoritmo	RMSE Directo	RMSE Superficie	RMSE Fondo
ARMAExtFast	0,1334	0,1513	0,6413
ARMAExtFast con Filtrado de Kalman	0,1072(19%)	0,1120(26%)	0,4924(23%)

**Tabla 3.6.8.** Valor RMSE en función del modo de propagación y el algoritmo considerado.Agrupación con despliegue vertical.

zonas donde ya de por si la DOA estimada presenta una exactitud bastante buena las correcciones no aportan gran cosa.

#### • Experimento con agrupación vertical

Las condiciones de este experimento son las mismas que las indicadas para el anterior, sólo que en este la agrupación se encuentra desplegada perpendicular a la superficie. Los resultados que se presentan obedecen a ese cambio en la geometría, lo que trae consigo también cambios en la DOAs a estimar, tal y como se puede ver en la Figura 3.6.39. Ahora las trayectorias de los modos directo y reflexión en la superficie presentan DOAs que divergen, yendo y volviendo ambas al broadside de la agrupación pasando por el endfire de la misma, aunque en lados opuestos. El modo de propagación por el fondo presenta ahora direcciones de incidencia siempre muy cercanas al endfire de la agrupación, salvo en las posiciones que van desde la posición 400 en adelante, donde vuelven a manifestarse incidencias con cambios bruscos de dirección. Esto se debe a que en la parte ascendente de la trayectoria, la fuente "empieza a ver" un fondo con un plano ascendente que tiene inclinación y orientación distintas a la del resto del fondo, Figura 3.6.35.

A la vista de los resultados recogidos en las graficas de Figura 3.6.40 y Tabla 3.6.8, para cada uno de los modos, a grandes rasgos podemos observar que el comportamiento no difiere mucho del encontrado para el caso de la agrupación desplegada horizontalmente. En el caso de la corrección mediante filtro de Kalman, si nos referimos a los resultados numéricos recogidos en la Tabla 3.6.8, al menos para los modos directo y reflexión en superficie se aprecian mejoras algo mayores a las encontradas en el experimento anterior. Si observamos con algo de detenimiento las gráficas que aparecen en Figura 3.6.40(b), 3.6.40(d) y 3.6.40(f) nuevamente aquellos segmentos que presentan mayores errores experimentan correcciones significativas gracias a la aplicación del Filtrado de Kalman, sobre todo cuando nos referimos al modo de propagación por reflexión en el fondo. Esta circunstancia es particularmente evidente en las zonas de mayor erro que, como sabemos, se dan para DOAs próximas el endfire de la agrupación, esto es, en la vertical de esta agrupación.

# CAPÍTULO 4

Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización y Seguimiento con Redes Inalámbricas de Sensores

Abordamos en este capítulo el problema del diseño de algoritmos aplicados a la localización y seguimiento mediante agrupaciones distribuidas de sensores. Una de las diferencias fundamentales de estas con respecto a las concentradas reside en el espacio que ocupan. Mientras que en las concentradas los sensores están muy próximos entre sí, distancias cortas inferiores a la longitud de onda de las señales a captar en las distribuidas la separación entre sensores es grande en términos de la longitud de onda. En ambos casos los sensores están en campo lejano de la fuente. La idea que subyace en el despliegue de una agrupación distribuida de sensores en el contexto de esta tesis es permitir la inspección de un territorio más o menos amplio de la manera más completa posible. Esto por lo pronto implica separaciones entre sensores de varias longitudes de onda, como mínimo. Luego, los conceptos usados de manera común en agrupaciones concentradas no son aplicables. El tratamiento y procesamiento de las señales captadas por los sensores será diferente y los algoritmos no se podrán extrapolar directamente de un contexto al otro. El problema debe formularse en base a otras condiciones de contorno, incompatibles con la formulación clásica al uso en ASP. El objetivo en ambos casos es el mismo, pero los datos disponibles en cada caso no son concurrentes, aunque es más que probable que en origen sean de una misma naturaleza, p.ej. acústica o electromagnética.

Entre las agrupaciones distribuidas merecen especial interés las inalámbricas, WSN, ver capítulo 2 apartado 2.3, aquellas donde los sensores o agrupaciones de sensores distribuidas tienen capacidad para comunicarse con un *Centro de Proceso* directa o indirectamente, o bien con los sensores adyacentes. A estos dispositivos comúnmente se les denomina sensores o más coloquialmente *motas*. Es importante recordar que se trata de auténticos *nodos* de comunicación con capacidad para incorporar varios sensores, al menos uno. En esta tesis el énfasis lo pondremos en redes inalámbricas distribuidas compuestas por nodos que tienen capacidad para recoger información del medio circundante dentro de su radio de acción. Esta reseña que aquí hacemos tiene gran importancia, por ejemplo, al realizarse la comunicación de manera inalámbrica entre la totalidad de los nodos y la central de proceso, es muy probable que los datos de cada nodo no lleguen ordenados e incluso que todos no sean producto del mismo evento, es más pueden haber datos de nodos que por colisiones, etc., directamente se pierdan.

Nuestro gran objetivo en este capítulo de la tesis es el desarrollo de nuevos algoritmos, en el ámbito de las WSN. En primer lugar, algoritmos para acometer la tarea de Localizar nodos de ubicación desconocida dentro de la red considerada. Y en segundo lugar, desarrollaremos algoritmos para el Seguimiento de nodos móviles dentro de la red.

Como paso previo al estudio y posterior desarrollo de algoritmos de localización y seguimiento, vimos la necesidad de disponer de un entorno de simulación adaptado a nuestros requisitos, de ahí que creamos nuestro propio simulador, al que hemos denominado: Location and Tracking Simulator based on Wireless Sensor Network (LoTrackS-WSN). A este entorno dedicamos el primer apartado donde explicamos la herramienta que nos será de gran utilidad para estudiar los algoritmos existentes, introducir mejoras, desarrollar ideas, etc., pudiendo todo ello ser probado, prácticamente sin coste alguno, salvo el tiempo de computación.

Se impone también, al menos, un mero repaso a los métodos de localización, cuestión que abordamos en el segundo apartado de este capítulo. El propósito es elegir sobre qué metodología vamos a dirigir nuestros esfuerzos. En este aspecto será decisivo para la elección de la metodología, tener un conocimiento preciso del material disponible para nuestro sistema, p.ej., nodos sensores. Una vez tomada esa decisión, se podrán vislumbrar cuáles serán las expectativas y los límites de nuestra elección, así mismo podremos establecer los retos a los que nos vamos a enfrentar.

En el tercer apartado abordamos el problema de la localización usando niveles de potencia, para ello adoptamos un modelos de propagación y estudiamos una serie de algoritmos de localización que han merecido nuestro interés. Introducimos aquí nuestras primeras contribuciones a la mejora de estos algoritmos en base a la estimación de la constante de atenuación.

Otro de los grandes retos dentro de las WSN es el seguimiento de fuentes, o nodos móviles, como se les quiera ver, dentro del ámbito de una de estas redes. En el cuarto apartado, tras un estudio del modelo más extendido para abordar esta problemática, Filtrado de Kalman, hemos particularizado dichos algoritmos a nuestros requisitos, además de incorporar todas las contribuciones que sobre la medida de las distancias hemos incorporado en los algoritmos al efecto.

El refrendo de la bondad de nuestras contribuciones en los algoritmos de localización y seguimiento, entendemos, debe hacerse desde una óptica práctica. Es por ello que en el quinto apartado presentamos una batería de experimentos mediante simulaciones y medidas de campo, y sus correspondientes resultados. Los resultados obtenidos, veremos, avalan que nuestros algoritmos introducen mejoras respecto a los estudiados. Algoritmos que no realizan estimaciones de parámetros de propagación electromagnética como es nuestro caso.

# 4.1 Entorno de Simulación de Propagación Electromagnética para Redes Inalámbricas de Sensores

La estrategia de despliegue de una WSN, entendida esta como la selección del número de sensores y su distribución física, en un escenario determinado, es una operación crucial para el devenir de sus prestaciones. En primera instancia podríamos pensar en hacer pruebas con despliegues reales. Esto puede conllevar problemas en escenarios que no tengamos a disposición fácilmente, el número de sensores es elevado, etc. Por tanto, disponer de un sistema de simulación se hace imprescindible. En este sentido los sistemas de simulación con capacidad para predecir con cierto grado de precisión el comportamiento de la WSN, al menos en sus aspectos más relevantes, son de gran interés.

Son varias las entidades académicas y comerciales que han ideado sistemas de simulación en este ámbito. Sin embargo, la gran mayoría de ellos están orientados a la simulación del comportamiento de la red (tráfico de paquetes), protocolos y mecanismos de comunicación entre los distintos nodos de la red, es decir simulan mayormente hasta la capa de red. El canal inalámbrico de radiofrecuencia (condiciones físicas del escenario donde se despliega la red) no es considerado con la precisión y un grado de realismo suficientes. En general se recurre a modelos estadísticos o físicos que sólo contemplan modos básicos de propagación. Además, varios de ellos están ideados para nodos inalámbricos de un tipo concreto, lo que les limita a la hora de aplicaciones más generales. Simuladores como TOSSIM [Levis 2003], OPNET [OPNET 2010], GloMoSim [Nuevo 2004], OMNet++ [Varga 2008], SensorSim [Park 2000], J-Sim [Sobeih 2006], SIDH [Carley 2004], SENS [Sundresh 2004], ATEMU [Polley 2004] y NS-2 [Downard 2004] entran dentro de este grupo de simuladores, algunos de ellos más específicos para WSN mientras otros tienen un carácter más general. La gran mayoría están programados en C o C++ y otros, los menos, en Java. El Prowler, [Simon 2003], es otro de los simuladores, en este caso programado bajo

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



Figura 4.1.1. Vista esquemática del sistema de simulación LoTrackS-WSN.

entorno MATLAB. En este sistema se simulan la transmisión, propagación y recepción de radiofrecuencia, incluyendo las colisiones en una red de radiofrecuencia para el caso, así como la operación de la capa MAC. Además, se puede implementar cualquier aplicación sobre cualquier número de motas. La capa MAC y la propagación, así como las aplicaciones son tratadas como programas añadidos. Por último, indicar que en este simulador el canal inalámbrico está modelado mediante modelos estadísticos.

Las prestaciones, ventajas y desventajas más relevantes de los simuladores arriba citados se pueden encontrar en [Egea-López 2005, Basaran 2006, Singh 2008 y Korkalainen 2009].

Un sistema de simulación, al menos en nuestro contexto, debe disponer como mínimo de tres módulos fundamentales: modulo geométrico, modulo de radiofrecuencia y modulo de aplicaciones.

El modulo geométrico será el que contenga los elementos necesarios para la introducción y especificación del escenario considerado. Una primera disyuntiva se plantea en el ámbito de los escenarios, interiores o exteriores, o ambos. Una vez decidido el ámbito habrá que convenir el grado de detalle, p.ej. si vamos a contemplar la presencia de obstáculos. También hemos de decidir hasta qué nivel de detalle lo vamos a hacer, p.ej. si tenemos en cuenta la presencia de árboles o no, puertas, ventanas, etc. Dicho de otra manera, si tomamos en consideración efectos como la reflexión, la difracción, la refracción o el Doppler. En nuestro caso hemos optado por un sistema de simulación para exteriores.

En el modulo de radiofrecuencia se integran los mecanismos de la propagación en el escenario considerado, generación de paquetes de datos, modulación, balances de potencias, efecto del ruido, etc. tanto en emisión como en recepción. Para ello, existen distintos modelos, apartado 2.2.3, para llevar a cabo la realización de los cálculos que determinen los parámetros de las señales electromagnéticas en distintas situaciones.

El modulo de aplicación será donde se utilicen algoritmos que con los datos proporcionados por el sistema de simulación realice alguna tarea de nivel superior, p.ej. localización, seguimiento, etc., además de la presentación de resultados en una interfaz. Esta parte del sistema de simulación debe soportar la incorporación práctica de nuevos algoritmos. El añadido de estos al sistema de simulación puede ser circunstancial o permanente, p.ej. podemos implementar un nuevo algoritmo y probarlo comparativamente con otros, y según los resultados decidir añadirlo a la batería de aplicaciones o no.

En cuanto a cómo está organizada la forma de operar, un aspecto importante es la independencia entre cada uno de los módulos. Esto es, podemos, para un determinado escenario, realizar las tareas relativas al modulo geométrico y guardarlas en un archivo. Este módulo, desde el punto de vista computacional, es justamente el que más tiempo de cálculo consume. Para un escenario específico y un despliegue de la red WSN con los elementos móviles de la misma, es posible la realización a posteriori de las tareas de los otros dos módulos. Esto hace posible que los procedimientos algorítmicos de los módulos de radiofrecuencia y de aplicación puedan cambiar sin que ello implique realizar nuevamente todo el proceso. Gráficamente las ideas expuestas anteriormente se pueden apreciar en la Figura 4.1.1.

simulación Nuestro entorno de ha sido desarrollado en MATLAB, fundamentalmente por la flexibilidad y prestaciones que este entorno nos ofrece a la hora de la implementación y la verificación de los procedimientos, que es relativamente rápida. Estos aspectos son mucho más lentos en otros entornos de programación, ya que requieren un mayor cuidado en, p.ej. la declaración de las variables y sus tipos, en la creación de matrices y vectores, etc. Otros entornos son más óptimos y portables cuando se trata de un producto totalmente acabado y perfectamente testeado en sus aplicaciones. Luego, la decisión de usar MATLAB o no gira alrededor de la fase de desarrollo en que nos encontramos, es decir si estamos desarrollando un prototipo para la investigación o preparando un producto comercial.

En la Figura 4.1.2 podemos ver la interfaz que hemos creado para interactuar con nuestro simulador. La parte central de la interfaz la domina el escenario, se trata de una imagen donde vemos desplegada una serie de nodos fijos y en la que aparece también la trayectoria de un nodo móvil. En la parte lateral izquierda de la interfaz aparecen una serie de "secciones de comandos" para la introducción de los datos relativos a la simulación: Modo de trabajo, distribución de los nodos, posiciones del nodo móvil, escenario a considerar, parámetros del transmisor, etc. Por último, en la parte inferior izquierda tenemos los botones de ejecución de los procesos, tales como guardar simulaciones, carga de las mismas, ejecución de procesos, ayudas, etc.



Figura 4.1.2. Interfaz de usuario del simulador LoTrackS-WSN.

Seguidamente daremos cuenta con algo más de detalle, de lo que hemos considerado más interesante, para cada uno de los módulos, a la hora de implementar nuestro simulador, al que hemos denominado *"LoTrackS-WSN"*.

#### • Modulo geométrico

Este modulo está encargado de "leer" y "traducir" a un lenguaje, digamos, algorítmico la información sobre el escenario [Lessing 2004]: dimensiones y límites del mismo, situación y orientación dentro del escenario de los grandes obstáculos (edificios, construcciones, superficies especiales como p.ej., lagos, zonas verdes arboladas, etc.), coeficientes de reflexión de las superficies de esos grandes obstáculos. En nuestro caso vamos a tener en cuenta obstáculos en tres dimensiones. El despliegue de los nodos de la WSN será también una parte de este modulo, permitiendo situar a cada nodo en el escenario incorporando su posición en el mismo, coordenadas (x,y,z). Como complemento en la Figura 4.1.3 podemos ver la imagen de un determinado escenario y una visualización esquemática del mismo, información esta última que es la manipulada en este modulo para realizar sus tareas. Básicamente en ese escenario están modelados aquellos elementos que aparecen señalados en la imagen, que son el edificio central grande, otro edificio de menores dimensiones y unas charcas.

Una vez definido o cargado el escenario la función siguiente de este modulo aplica un modelo de propagación en RF. En nuestro caso hemos optado por un modelo de rayos basado en la teoría óptica. A tal efecto se han considerando los distintos Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



**Figura 4.1.3.** Escenario tal y como lo ve el usuario en la imagen de la izquierda e información esquemática para los algoritmos del modulo geométrico en el dibujo de la derecha.

caminos que se puedan dar entre transmisor y receptor dentro del escenario en cuestión: línea directa, reflexiones hasta segundo orden y difracciones, que han sido tratadas siguiendo alguna de las pautas marcadas en [Papkelis 2007]. Por tanto, este modulo será el encargado de establecer todas las vías posibles entre la totalidad de los transmisores y receptores activos.

Los datos que cada vía debe incorporar serán tipo de trayectoria (directa, reflexión, difracción, etc.), distancia (espacio a recorrer) y orientación (acimut y elevación) de la incidencia. Así mismo para cada reflexión se hace necesario identificar el coeficiente de reflexión de la superficie o superficies de incidencia. Como se desprende de todo lo dicho la simulación en lo referente a las condiciones geométricas se lleva a cabo en un espacio de tres dimensiones, lo que a la vez que esto lo hace más general, también lo hace más exhaustivo desde el punto de vista computacional.

#### • Modulo de Radiofrecuencia

La ejecución de este modulo depende de la tarea previa del modulo geométrico, por sí sólo no puede realizar tarea alguna, necesita datos para poder hacerla. Estos datos pueden haber sido elaborados previamente y cargarse, o bien pueden ser producto de una ejecución secuencial, es decir, una vez terminada la ejecución del modulo geométrico se sigue con este modulo de radiofrecuencia en una misma sesión.

El objetivo fundamental de este modulo es proporcionar los niveles de señal recibidos en cada una de las localizaciones seleccionadas, esencialmente la posición de los nodos fijos de la WSN. Para ello aplica directamente leyes básicas de la propagación para las incidencias directas, Ec.2.2.2. La solución para modos de propagación por reflexión se apoya también en la ley básica de la propagación, pero contemplando las propiedades de las superficies donde se refleja. También se aplica la absorción del medio (p.ej., vapor de agua, lluvia) en la propagación de

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



Figura 4.1.4. Niveles RSSI en cada nodo fijo, gráfica superior, y grupos de los cuatros primeros nodos activos clasificados de mayor a menor nivel, gráfica inferior.

la onda electromagnética y la acción de ruido en un canal AWGN. Además, se han habilitado procedimientos especiales para los casos de la difracción, apartado 2.2.1, tanto por encima de los edificios y obstáculos, como por los laterales de estos.

La operación de este modulo comienza en una parte más básica, que es la generación de la señal a transmitir. Para ello el usuario puede elegir entre una serie de paquetes de datos básicos. Dado que estos sistemas están basados en la IEEE 802.15.4, según vimos en el apartado 2.3.2, para las capas PHY y MAC hemos implementado todo el proceso de generación, modulación y transmisión según se específica en la citada norma. Los datos de las trayectorias posibles que fueron calculadas en el modulo geométrico se usan en este punto. Calculamos la señal resultante en el receptor considerado conjugando los distintos modos de propagación contemplados. A continuación en el receptor se desarrolla el proceso de recepción, demodulación y decodificación hasta obtener el paquete de datos en recepción. Como producto de este proceso obtenemos también los niveles RSSI en cada nodo.

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



**Figura 4.1.5.** Niveles reales recibidos en espacio libre en función de la distancia desde un nodo transmisor para una potencia de 0 dBm [Stoyanova 2007] (a) y resultados obtenidos en el simulador para la misma experiencia (b).

En el simulador es posible obtener otros resultados. Los más destacables, son la SNR en cada nodo y la cuantificación de errores en las secuencias binarias transmitidas. En la Figura 4.1.4 podemos ver un ejemplo de los niveles RSSI, gráfica de la parte superior, recogidos en cada uno de los nodos sensores, para el caso de un nodo móvil que se posiciona en diez localizaciones desde las cuales emite señal electromagnética que es recibida por trece nodos fijos. Podemos

observar cómo cada "sample" o muestreo del nodo móvil provoca distintos niveles en los nodos fijos (Sensor, en abscisas) en función de la potencia del campo electromagnético presente en la zona de ese nodo. Este resultado se manifiesta de gran utilidad puesto que permite estudiar la mejor disposición de los nodos en el despliegue para poder captar con mayor exactitud al nodo móvil en las posiciones de interés, así como observar aquellos nodos que pueden ejercer de pivotes principales. Como complemento a la información obtenida de esta distribución de niveles en la parte inferior tenemos para cada evento, transmisión del móvil, qué nodos reciben los cuatro mayores niveles, clasificados del primero al cuarto. Esto permite estudiar qué grupos de sensores son más importantes de cara a la tarea de localización. También es posible observar las transiciones que se producen y a posteriori ver cómo afecta a la exactitud de la localización. Por ejemplo, en la parte inferior de la Figura 4.1.4, podemos ver cómo para los tres primeros eventos (emisiones de señal electromagnética del nodo móvil) el conjunto de los cuatro primeros sensores no cambia, lo que sí cambia es su ordenamiento en función del nivel de RSSI. Estas transiciones entre un mismo grupo, sólo en el orden, son suaves y en la mayoría de los algoritmos se observa un buen comportamiento. Sin embargo, para el cuarto evento entra en juego un nuevo nodo fijo en detrimento del nodo fijo 3 que desaparece del grupo, esto provoca una transición abrupta.

En la mayoría de los casos este cambio provoca mayor inexactitud puntual en la totalidad de los algoritmos y por otra parte pone de manifiesto la entrada en otro sector o zona. Justamente estos resultados se corresponden con el despliegue de nodos que puede observarse en la Figura 4.1.2, donde cada nodo fijo tiene al lado su Sensor ID.

Resulta de bastante interés disponer de algún tipo de evidencia práctica que permita verificar la bondad de los resultados que nos proporciona el simulador. Para ello hemos usado uno de los experimentos de campo desarrollados en [Stoyanova 2007], Figura 4.1.5(a). El experimento realizado en espacio libre ha consistido en situar un transmisor y un receptor a distancias entre 0 y 50 metros, la altura del receptor y la del transmisor fueron ambas iguales a 2 m, con una potencia de transmisión de 0 dBm. Según podemos observar en la Figura 4.1.5(b) nuestro simulador, trabajando con unos parámetros definidos a partir de los detalles dados por los autores, arroja unos resultados que en la práctica se aproximan bastante a los reales.

#### • Modulo de aplicación

Tal como ya hemos mencionado nuestro simulador tiene por objeto ayudar en el desarrollo de algoritmos aplicables a las WSN en tareas de Localización y Seguimiento de Nodos Móviles. Este modulo incorpora distintos algoritmos para procesar los niveles recibidos en los nodos fijos, ya que nuestra línea de investigación en este ámbito se centra en los algoritmos que usan la RSSI como dato principal.

El número de estos se puede ampliar, ya que hemos concebido su aplicación como submódulos con lo que pueden ser incorporados nuevos algoritmos. El simulador permite una comparación directa entre los distintos algoritmos en base a medidas como la exactitud en la determinación de la localización. Como ejemplo de lo dicho en la Figura 4.1.6(a) tenemos una ampliación del escenario simulado. En el Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



**Figura 4.1.6.** Ejemplo de localización de nodo móvil. En (a) posiciones que ocupa y en (b) estimación de esas posiciones mediante algoritmos de localización.



**Figura 4.1.7.** Ejemplo de Seguimiento de nodo móvil. En (a) trayectoria seguida y en (b) estimación de esa trayectoria mediante un algoritmo de seguimiento.

mismo aparecen cruces de color blanco (localizaciones reales del nodo móvil). Además, en la misma se pueden observar una serie de nodos fijos (círculos de color azul claro). En la Figura 4.1.6(b) aparecen un conjunto de nuevas marcas: cuadrados de color amarillo que corresponden a las estimaciones obtenidas de un algoritmo de localización de entre los implementados en el simulador. Junto con estas aparecen otras, unos círculos de color rojo, estos corresponden a estimaciones realizadas con el mismo algoritmo incluyendo una variante. Esta variante es una de las contribuciones de esta tesis en el ámbito de la localización en redes WSN, cuestión que abordaremos más adelante en este capítulo. En este segundo algoritmo la constante de atenuación ( $\alpha$ , *Ec.2.2.3*) se considera variable y como tal se determina para cada localización mediante un algoritmo ideado que veremos más adelante en este capítulo. En la mayoría de los casos se observa una mayor exactitud en la estimación con este último algoritmo de localización.

Además de algoritmos para localización nuestro simulador contiene algoritmos para realizar seguimiento de nodos móviles. Para el modo de seguimiento podemos ver en la Figura 4.1.7(a) la trayectoria descrita por un nodo móvil (trazo de cruces blancas) y en la Figura 4.1.7(b) observamos el seguimiento (cuadrados de color amarillo) realizado mediante un algoritmo basado en el filtrado de Kalman.

# 4.2 Una Perspectiva de los Métodos de Localización

Muchas de las técnicas usadas para resolver el problema de localización de una o varias fuentes en el ámbito del ASP, no son aplicables a las agrupaciones distribuidas. Esto se debe a que la separación entre sensores es grande en términos de la longitud de onda; por lo que los conceptos clásicamente usados en agrupaciones concentradas no son aplicables. Se impone así la necesidad de buscar metodologías y algoritmos alternativos basados en información básica diferente. Por ejemplo, si antes no era importante hablar de diferencias de amplitud de señales y sí de diferencias de fase, ahora sí tiene sentido trabajar con diferencias de amplitud (p.ej., potencia). Otro aspecto a destacar es que mientras en las agrupaciones concentradas los sensores están agrupados en el centro geométrico de la agrupación, en las distribuidas esto no es así.

Entre las agrupaciones distribuidas merecen especial interés las inalámbricas. En estas los sensores o agrupaciones de sensores están distribuidos y la comunicación es por radiofrecuencia. Tienen capacidad para comunicarse con un Centro de Proceso directa o indirectamente, o bien con los sensores adyacentes. Aunque comúnmente se les denomina sensores hemos de entender que se trata de auténticos nodos de comunicación que pueden incorporar diversos sensores. Ante este escenario surgen entonces una serie de necesidades: Procesado descentralizado, procesado colaborativo, consumo de energía, conocimiento o no de la posición exacta del sensor (autolocalización), sincronización, procesado de señal incoherente, radio de acción por atenuación y sensibilidad del sensor, naturaleza de las señales captadas, como las más relevantes.

Como ya hemos avanzado, el énfasis lo pondremos en las redes inalámbricas distribuidas, concretamente las WSN, compuestas por nodos que tienen capacidad para recoger información del medio circundante dentro de su radio de acción. Los nodos están dotados de capacidad de procesado sobre la información captada y con la facultad de comunicarse con los nodos de su entorno o directamente con el Centro de Proceso.

A la hora de definir formalmente una WSN en primera aproximación podemos considerar que está compuesta de n nodos, con un alcance en comunicación r, y distribuida en un campo de sensores de planta cuadrada y dos dimensiones Q=[0,s]x[s,0], siendo s la magnitud en m del lado. Con todo ello representaremos a la red mediante un gráfico Euclídeo (E) [Boukerche 2009]:

- $V = [v_1, v_2, \dots, v_n]$  es el conjunto de nodos de sensores
- $\langle i,j \rangle \in E$  si  $v_i$  alcanza a  $v_j$ ; es decir la distancia entre ellos es inferior a r.
- $\omega(e) \le r$  es el peso o ponderación del segmento  $e = \langle i, j \rangle$ , esto es, la distancia entre  $v_i \ge v_j$ .

En un gráfico Euclídeo, cada nodo tiene una coordenada  $(x_i, y_i) \in \mathbb{R}^2$  en un espacio bidimensional, lo que representa la localización del nodo *i* en Q.

Para designar el estado actual de cada uno de los nodos se suele usar los siguientes términos clásicos, al menos en la bibliografía al respecto. A los nodos de los que se desconoce su localización se les denominan **Nodos Desconocidos** (U), siendo la estimación de su posición el objetivo principal de los sistemas de localización. Los nodos que inicialmente son desconocidos, pero que están orientados a estimar su posición usando el sistema de localización, son los **Nodos Fijos o Estáticos** (S), el número de estos y el error en la estimación de su posición son los principales parámetros de calidad de un sistema de localización. Aquellos nodos que no necesitan el sistema de localización, obtienen su localización por posicionamiento manual o mediante medios externos, p.ej. Global Position System (GPS), se les conoce como **Nodos Baliza o Ancla** (B), de su definición se desprende que forman la base de los sistemas de localización usados en WSN. Los **Nodos Referencia** (R) disponen de información de localización. Un nodo referencia es a su vez un nodo baliza o fijo.

En el contexto de las redes distribuidas el problema de la localización de fuentes, por ejemplo desde el punto de vista de la autolocalización de nodos de una red, puede simplificarse y definirse del modo siguiente: Dada una red G = (V,E) y un conjunto de nodos baliza B y sus posiciones  $(x_b, y_b)$ , para todos los  $b \in B$ , queremos encontrar la posición  $(x_u, y_u)$  de casi todos los nodos desconocidos  $u \in U$ , transformando estos nodos desconocidos en nodos fijos S. Por tanto, la posición de los nodos no necesita ser predeterminada, lo que permite un despliegue aleatorio en terrenos inaccesibles o en operaciones de auxilio ante catástrofes.

En el contexto de las WSN son de aplicación, por ejemplo, métodos basados en TOA y TDOA que requieren nodos sincronizados con precisión, además de la incorporación en el paquete de datos transmitido de información relativa al instante de emisión [Ilyas 2005]. Los métodos basados en diferencias más aplicados en WSN requieren calcular la diferencia de tiempo que varias señales emitidas desde el nodo emisor toman para llegar a otro nodo, p.e, [Priyantha 2000, 2001]. Para ello se requiere que los nodos estén equipados con un hardware extra que les permita enviar dos tipos de señales con distintas velocidades de propagación de manera simultánea, como señales de radio y acústicas (sonidos o ultrasonidos). Estos métodos se muestran bastante precisos, pero presenta desventajas tales como necesitar hardware adicional para enviar la segunda señal, con el consiguiente incremento del coste del nodo. Además, el alcance de la segunda señal es normalmente bajo, oscilando entre los 3 m y 10 m.

Uno de los mayores desafíos científicos en este campo está en el tipo de información básica a utilizar. De todos (retardos, niveles de potencia recibida, etc.) el nivel de potencia recibida es el que más se usa porque la mayoría de los nodos de sensores lo dan como información sin necesidad de añadir dispositivos adicionales. Su uso plantea problemas derivados de la interacción de las ondas en su propagación por el entorno. Así, reflexiones, difracción, etc. afectan de tal forma que no son pocos los investigadores que se cuestionan la utilidad de la potencia. En esta tesis vamos a ir un paso más adelante investigando sobre cómo

Método	Precisión	Máxima Distancia	Hardware Extra	Retos
RSSI	Metros (2-4m)	Alcance de Comunicación	Ninguno	Variación de RSSI e interferencias
ТОА	Centímetros (2- 3 cm)	Alcance de Comunicación	Ninguno	Sincronización de nodos
TDOA	Centímetros (2- 3 cm)	Unos pocos metros (2-10 m)	Transmisor de ultrasonidos	Máxima distancia de trabajo
AOA/DOA	Unos pocos grados(5°)	Alcance de Comunicación	Conjunto de receptores	Trabajar sobre nodos de pequeñas dimensiones
Alcance en Comunicación entre nodos	Mitad del Alcance en Comunicación	Alcance de Comunicación	Ninguno	_

**Tabla 4.2.1**. Tabla comparativa de métodos de estimación de distancia y direcciones<br/>entre nodos para WSN.

afecta la propagación a dichos valores y la forma de hacer un posprocesado que en buena medida corrija los citados problemas.

En lo relativo a la información básica a utilizar existen diferentes alternativas que hemos de analizar en función de las condiciones de trabajo y los objetivos marcados. Así, tenemos la que da lugar a resultados muy precisos pero con alto coste (energético, de tiempo y recursos de proceso, hardware, etc.), mientras que otras no son tan precisas, pero pueden estar disponibles en la mayoría de los nodos. Estas alternativas incluyen RSS (Received Signal Strength), TOA/TDOA, AOA/DOA y el de alcance en comunicación [Niculescu 2003a, Niculescu 2003b, Zhao 2004, Holger 2005, Boukerche 2009]. En la Tabla 4.2.1 podemos apreciar una comparativa de todos los tipos de información el más accesible en la inmensa mayoría de dispositivos es RSS y, por este motivo, lo hemos elegido como información básica en esta tesis al trabajar con agrupaciones distribuidas.

Los métodos basados en RSS estiman la distancia entre dos nodos en base a la intensidad de la señal recibida desde uno de los nodos. La propagación de las ondas condiciona mucho el nivel de RSS [Li 2005, Nishi 2008]. A modo de ejemplo, dos modelos básicos de propagación son los dados por las expresiones Ec.2.2.3 (propagación ideal en campo libre sin obstáculos ni interferencias) y Ec.2.2.4 (espacio libre considerando reflexión en el terreno).

Podemos entender *Localizar* como la acción de determinar o señalar el emplazamiento que debe tener alguien o algo, básicamente estimar sus coordenadas cartesianas (x,y,z) o polares distancia radial, ángulo de azimut y ángulo de elevación  $(r,\varphi, \theta)$ . El contexto en que tratamos de llevar a cabo esa acción, sea con Agrupaciones Distribuidas o Concentradas nos orientará hacia una u otra metodología.

# 4.3 Localización Mediante Niveles de Potencia

Ya hemos visto en el apartado anterior que existen distintas metodologías para abordar el problema de la localización en una WSN. Por otro lado, también son varias las modalidades de señal útil para acometer un problema de localización. Así, por ejemplo, podemos usar señales acústicas, electromagnéticas, sísmicas, magnéticas, etc. Además, pueden estar disponibles distintos tipos de medidas como, por ejemplo, potencia de señal, direcciones de llegada, distancia, variación de la distancia con el tiempo, etc. En el marco de esta tesis la modalidad de señal útil elegida es electromagnética y la medida a realizar en el nodo es el nivel de potencia dado en valores de RSSI (apartados 2.2.4 y 2.3.2).

Esta elección no está exenta de controversias, ya que existen autores que abiertamente dudan de la utilidad de los valores RSSI, para desarrollar algoritmos de localización fiables sobre todo en interiores. Por ejemplo, los autores de [Lymberopoulos 2006, Awad 2007] exponen que a problemas clásicos como: multitrayecto, desvanecimientos y sombras electromagnéticas, hay que añadir variabilidades en el transmisor, en el receptor y en la orientación de la antena. Sin embargo, otros muchos [He 2003,Li 2005, Nguyen 2005, Srinivasan 2006, Awad 2007, Whitehouse 2007, Nishi 2008, Tateishi 2008] siguen apostando por su uso, para ello introducen refinamientos más o menos acertados en el tratamiento algorítmico de dichos valores.

El contexto en que nos vamos a mover en nuestro desarrollo implica el concurso de un emisor, que será siempre un nodo móvil (el móvil, en adelante) y el receptor uno o varios nodos fijos. Si bien todo el desarrollo se presenta para propagación de ondas electromagnéticas, el mismo es generalizable a otros casos en que tenga validez el modelo de propagación que veremos más adelante o uno similar (p.ej., ondas acústicas).

La idea fundamental que trabajaremos es localizar una fuente móvil a partir del conocimiento de la posición de unos nodos fijos y el nivel de potencia de señal medida, concretamente las muestras de valores RSSI que llegan hasta ellos provenientes del móvil. Planteamos un algoritmo genérico de uso de los valores de RSSI en el que el efecto de la constante de atenuación (a, Ec.2.2.3) sea mitigado (idealmente eliminado) para su uso posterior en varios algoritmos de localización. A este efecto partimos del modelo de propagación en que se resalta el efecto de a, formulamos los algoritmos de localización y estimamos la constante de atenuación que se incorpora a dichos algoritmos.

## 4.3.1. Adopción de un Modelo de Propagación

El modelo de partida es el de Friis en espacio libre que presentamos en la Ec.4.3.1 adaptada a nuestras necesidades. En él la potencia recibida  $p_i$ , en vatios, a una distancia mayor que una de referencia  $d_0$  (usualmente 1 metro) se expresa de la siguiente forma:

$$p_{i} = \frac{p_{i}\lambda^{2}g_{i}g_{ri}l_{it}}{(4\pi)^{2} |\mathbf{x} - \mathbf{s}_{i}|^{\alpha_{i}}} + n_{i}, \qquad i = 1, \cdots, N$$
 (Ec.4.3.1)

donde **x** es la posición del emisor (a determinar),  $\mathbf{s}_i$  es la posición del i-ésimo nodo fijo, N es el número de nodos fijos,  $p_t$  es la potencia transmitida (en vatios),  $\lambda$  es la longitud de onda (común en todas las emisiones),  $g_t$  y  $g_{ri}$  son las ganancias de las antenas transmisora y receptora, en  $l_{it}$  representamos las pérdidas conjuntas en los circuitos emisor y receptor además de las pérdidas por desajustes de polarización o apuntamiento de las antenas,  $a_i$  es la constante de atenuación, que vale 2 en espacio libre, y  $n_i$  es un ruido aditivo. Por simplificar denominaremos  $|\mathbf{x}-\mathbf{s}_i| = d_i$ .

De las variables intervinientes en la ecuación Ec.4.3.1 conocemos todas salvo las distancias  $d_i$ , las ganancias  $g_t$  y  $g_{ri}$ , la constante de atenuación  $a_i$  y el ruido interferente. Más adelante volveremos sobre estos elementos. Continuamos hacia una presentación más realista del modelo de propagación en la que de momento omitimos el efecto de ruido  $n_i$ .

Siendo realistas en las aplicaciones prácticas no hay propagación en espacio libre, sino que se tienen lugar reflexiones en diversas superficies tales como suelos, paredes, etc., provocando que la señal que llega al receptor sea la resultante de la interacción de varios modos. Una corresponde a la onda directa que concierne al modo de propagación en espacio libre y las demás serán réplicas de esta con diferentes retardos y niveles. En estas condiciones la constante de atenuación,  $a_i$ , toma valores diferentes de 2. Está comúnmente aceptado que el margen de valores está comprendido en el intervalo  $\alpha_i \in [1,5]$ , ver Figura 2.2.10 y las referencias [Woerner 1995, Andersen 1995, Erceg 1999]. Los valores inferiores a 2 corresponden a niveles en los que la interacción de las ondas directa y las reflejadas es aditiva, esto es, el nivel  $(p_i)$  resultante es superior al que corresponde al campo libre. Cuando la interacción es sustractiva los valores son superiores a 2. Este puede ser el caso, por ejemplo, en que sólo hay reflexiones en el suelo. Cuando se da este tipo de interacción el nivel  $(p_i)$  resultante es inferior al que corresponde en campo libre. Esta consideración es fundamental pues, como veremos más adelante, da lugar a un trabajo específico en el que nos plantearemos cómo estimar su valor en cada emisión.

Otra forma de expresar la ecuación Ec.4.3.1 es mediante su equivalente logarítmico (aplicando 10  $\log_{10}(.)$ , dB) de la siguiente forma:

$$P_{i} = K_{i} + G_{t} + G_{ti} + L_{it} - 10 \cdot \alpha_{i} \cdot \log_{10} d_{i} + N_{i}$$
 (Ec.4.3.2)

donde ahora todas las cantidades se dan en decibelios (dB) y  $K_i$  engloba las constantes de la ecuación Ec.4.3.1. Desde un punto de vista práctico tanto  $G_t$  como  $G_r$  son desconocidas por lo que necesitamos alguna aproximación. De las gráficas de ganancia hemos sacado datos con los que se simulan multitud de orientaciones relativas emisor-receptor para obtener sus productos/sumas logarítmicas correspondientes. Con estos valores se ha obtenido la media de los mismos y es el valor que se usará en Ec.4.3.2 y todas las expresiones derivadas. En este mismo sentido una forma alternativa [Tateishi 2008], y más útil para nuestros propósitos, es la siguiente:

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores

$$P'_{i} = -10 \cdot \alpha_{i} \cdot \log_{10} d_{i} + N_{i}$$
 (Ec.4.3.3)

donde  $P_i$  engloba todos los elementos de la derecha de *Ec.4.3.2* excepto el que representa el efecto de la constante de atenuación  $a_i$  y la distancia  $d_i$ .

Hagamos ahora algunas consideraciones de interés.

- En las ecuaciones Ec. 4.3.1 y Ec. 4.3.2 se dan por conocidas las ganancias de las antenas (G<sub>t</sub> y G<sub>ri</sub>) y las pérdidas L<sub>i</sub>.
- En general las ganancias no son conocidas porque no se puede saber la dirección relativa entre emisor y receptor y, en consecuencia, cómo afectan. Baste pensar en que el móvil (p.ej., una persona) realiza movimientos de traslación y giros sobre sí mismo.
- Las pérdidas L<sub>i</sub> tampoco son conocidas pues, en general, no sabremos las pérdidas en los circuitos ni los desajustes de polarización como consecuencia de los giros que realice el móvil.
- El ruido interferente N<sub>i</sub> también es fuente de error.

Las consideraciones anteriores hacen que tengamos la necesidad de reparar en  $N_{\rm i}$ . Este elemento de la ecuación Ec.4.3.3 adquiere ahora un protagonismo fundamental, pues recoge el efecto conjunto de todas las fuentes de error y, en general, de parámetros desconocidos cuyo efecto conjunto necesitamos minimizar, pero a su vez será un aliado a la hora de hacer el planteamiento teórico.

A falta de un mejor conocimiento de la función de densidad de probabilidad de  $N_{\rm i}$ , haremos la suposición ya clásica de que es una variable aleatoria gaussiana multidimensional de media y covarianza con las que 'jugaremos' de forma razonada en función de nuestras necesidades. Esta elección de la función de densidad se debe a dos motivos principales. En primer lugar, es una opción de primera elección en estos casos y da lugar a unos desarrollos teóricos (en principio) manejables. Y en segundo lugar, con frecuencia lleva a buenos resultados.

#### 4.3.2. Estudio de Algoritmos de Localización

Son diversas las metodologías que se aplican en los algoritmos de localización basados en los niveles de potencia. Vamos a plantear algunas de ellas que tienen en común dos cosas:

- 1. El efecto de la constante de atenuación,  $a_i$ , es pernicioso para los objetivos. Este efecto se puede mitigar convenientemente si disponemos de una estimación suficientemente buena de esta constante.
- 2. No necesitan de un dispositivo externo específico para estimar numéricamente la distancia  $d_i$  sino que se puede hacer a partir de niveles de potencia.

En cualquier caso nos planteamos la necesidad de que en las ecuaciones que van de la Ec.4.3.1 a la Ec.4.3.3 desaparezca el efecto de  $a_i$  sobre la distancia,  $d_i$ . Para

esto utilizaremos estas ecuaciones según convenga en cada caso. En principio, durante todo este apartado consideraremos que  $a_i$  se conoce con exactitud.

#### • Algoritmo de Multilateralización

Para tratar este algoritmo retomamos la ecuación Ec.4.3.1 en una forma simplificada en la que prescindiremos del ruido interferente  $n_i$ .

$$p_{i} = \frac{k_{i}}{\left|\mathbf{x} - \mathbf{s}_{i}\right|^{\alpha_{i}}}$$
(Ec. 4.3.4)

donde ahora  $k_i$  recoge todas las variables excepto la relativa a la distancia emisor-receptor y la constante de atenuación.

Reescribimos *Ec.4.3.4* de la siguiente forma:

$$|\mathbf{x} - \mathbf{s}_i|^{\alpha_i} = \frac{k_i}{p_i} \tag{Ec. 4.3.5}$$

Si elevamos ambos miembros a  $2/a_i$  y desarrollamos el cuadrado resultante podemos llegar la siguiente expresión:

$$\left\|\mathbf{x}\right\|^{2} + \left\|\mathbf{s}_{i}\right\|^{2} - 2 \cdot \mathbf{x}^{T} \mathbf{s}_{i} = \left(\frac{k_{i}}{p_{i}}\right)^{2/\alpha_{i}}$$
(Ec. 4.3.6)

Como vemos  $(k_i/p_i)^{2/a_i}$  tiene magnitud de distancia, que llamaremos  $d_i$  para distinguirlo de la distancia en las ecuaciones anteriores. Así, podemos considerar de forma genérica que *Ec.4.3.6* se puede ver de la siguiente manera:

$$\|\mathbf{x}\|^{2} + \|\mathbf{s}_{i}\|^{2} - 2 \cdot \mathbf{x}^{T} \mathbf{s}_{i} = d_{i}^{T}$$
 (Ec. 4.3.7)

Hacemos ahora las siguientes apreciaciones:

- 1. Utilizando convenientemente la constante  $a_i$  conseguimos aislar las distancias.
- 2. Llegamos a una ecuación, *Ec.4.3.7*, que está en la base del algoritmo de trilateralización.

Para un nodo fijo cualquiera, p.ej. el *i*-ésimo, la ecuación Ec.4.3.7 da una condición cuadrática sobre la localización incógnita **x**. Necesitamos generar un conjunto de ecuaciones del que despejar **x**. Para ello sustraemos, por ejemplo, la ecuación correspondiente al sensor 1 del resto y obtenemos:

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores

$$-2(s_i - s_1)^T \mathbf{x} = (d_i - d_1) - (\|\mathbf{s}_i\|^2 + \|\mathbf{s}_1\|^2)$$
 (Ec.4.3.8)

Si denominamos  $\delta_i = (d_i - d_1) - (\|\mathbf{s}_i\|^2 + \|\mathbf{s}_1\|^2)$  llegamos a un sistema de ecuaciones como el siguiente:

$$C_{N-1} \cdot \mathbf{x} = \delta_{N-1} \tag{Ec. 4.3.9}$$

donde sin pérdida de generalidad consideramos  $\mathbf{x} \in \Re^2$  (componente 2D de  $\mathbf{x}$ ). Dado que la localización se hará en el plano 2D habrá un mínimo de N=3 sensores y el sistema de ecuaciones estará sobredeterminado. Entonces, la solución viene dada por

$$\mathbf{x} = \left[ (C_{N-1}^T \cdot C_{N-1})^{-1} C_{N-1}^T \right] \delta_{N-1}$$
 (Ec.4.3.10)

#### Algoritmo de los Baricentros

En este algoritmo la localización del móvil es estimada a partir de la siguiente expresión:

$$\mathbf{x}_{e} = \frac{\sum_{1}^{N} \mathbf{w}_{i} \cdot \mathbf{s}_{i}}{\sum_{1}^{N} \mathbf{w}_{i}}$$
(Ec.4.3.11)

donde las constantes  $\mathbf{w}_i$  son pesos que dependen de la distancia entre el móvil y los nodos fijos de los que conocemos sus posiciones exactas  $\mathbf{s}_i$  y ponderan la importancia de éstos. A la hora de estimar los pesos podemos hacer que dependan de diversos factores, p.ej., relaciones de potencia en los nodos fijos, importancia relativa dentro de la red. El que vamos a considerar en esta tesis se puede expresar en términos de la distancia entre emisor y receptor.

$$\mathbf{w}_{i} = \frac{\left(\left\|\mathbf{x} - \mathbf{s}_{i}\right\|\right)^{-1}}{\sum_{j=1}^{N} \left(\left\|\mathbf{x} - \mathbf{s}_{j}\right\|\right)^{-1}}$$
(Ec. 4.3.12)

Como vemos, cuanto menor es la distancia entre el móvil y un nodo fijo más importancia recibirá éste en la estimación de la posición pues su peso es mayor. Es, por decirlo de alguna manera, una forma de ponderar la importancia en función de la distancia que a su vez afecta a la potencia recibida. El problema que plantea Ec.4.3.12 es que, al igual que en el caso del algoritmo anterior, desconocemos las distancias ||**x**-**s**<sub>i</sub>||. Sí disponemos de los niveles de potencia y del


Figura 4.3.1. Ilustración del algoritmo RVI [Lee 2006].

modelo de propagación. Para incorporar dichos niveles en Ec.4.3.12 retomamos la ecuación Ec.4.3.5 y reescribimos Ec.4.3.12 de la siguiente forma:

$$\mathbf{w}_{i} = \frac{\left(\frac{k_{i}}{p_{i}}\right)^{(-2/\alpha_{i})}}{\sum_{j=1}^{N} \left(\frac{k_{j}}{p_{j}}\right)^{(-2/\alpha_{j})}} = \frac{(d'_{i})^{-1}}{\sum_{j=1}^{N} (d'_{j})^{-1}}$$
(Ec.4.3.13)

Al igual que en el apartado del algoritmo anterior podemos hacer algunas apreciaciones:

- 1. Nuevamente, utilizando convenientemente la constante  $a_i$  conseguimos aislar las distancias.
- 2. Llegamos a una ecuación, *Ec.4.3.13*, que está en la base del algoritmo de los baricentros.

#### • Algoritmo de Iteración Vectorial Ratiométrica

Este algoritmo, que en acepción en inglés se denomina "Ratiometric Vector Iteration (RVI)" a diferencia de los anteriores, está basado en la estimación de distancias relativas en lugar de distancias absolutas [Lee 2006]. Se trata de un algoritmo que necesita una estimación inicial,  $x_j$  Figura 4.3.1, lo más próxima a la posición verdadera, x, seguidamente itera hasta conseguir una posición más exacta a la que converge el algoritmo. En la realización de la tarea necesita disponer de las localizaciones de k ( $k \ge 3$ ) sensores ( $s_1, s_2, ..., s_k$ ), así como algún tipo de medida, en nuestro caso serán las RSSI calculadas en cada uno de los k sensores( $r_1, r_2, ..., r_k$ ).



Figura 4.3.2. Modelo esquemático del algoritmo LASM [Chen 2008].

A grandes rasgos, el algoritmo realiza operaciones iterativas tendentes a mover  $\mathbf{x}_j$ hacia  $\mathbf{x}$ , es decir, se trata de que la diferencia entre la relación de distancias  $|\mathbf{s}_1 \cdot \mathbf{x}| : |\mathbf{s}_2 \cdot \mathbf{x}| : |\mathbf{s}_3 \cdot \mathbf{x}| \ \mathbf{y} |\mathbf{s}_1 \cdot \mathbf{x}_j| : |\mathbf{s}_2 \cdot \mathbf{x}_j| : |\mathbf{s}_3 \cdot \mathbf{x}_j| \ \mathbf{s}_1 \cdot \mathbf{x}_j = |\mathbf{s}_i - \mathbf{x}_j|$ . Los vectores  $\mathbf{s}_i \cdot \mathbf{x}_j$  son multiplicados por un valor denominado "razón de diferencias de distancias",  $g_i$ , valor que viene dado por la siguiente expresión:

$$g_{i} = \frac{p_{i}^{(-1/\alpha_{i})}}{\sum_{j=1}^{k} p_{j}^{(-1/\alpha_{j})}}$$

Los productos resultantes se suman para componer un vector  $\mathbf{v}_j$  que se añade a  $\mathbf{x}_j$ , esto supone una traslación de  $\mathbf{x}_j$  hacia  $\mathbf{x}$ , proceso que se repite reiteradamente hasta que  $\mathbf{x}_j$  está suficientemente cerca de  $\mathbf{x}$ .

#### • Algoritmo Basado en un Modelo de Muelles

El Algoritmo originariamente denominado por sus creadores [Chen 2008] como LASM (Localization Algorithm based on a Spring Model) puede verse esquemáticamente en la Figura 4.3.2. En ella observamos el despliegue de una red donde las distancias entre vecinos se caracterizan mediante muelles y los nodos mediante círculos. Los nodos a su vez se subdividen en nodos ancla, aquellos que tienen una posición absoluta conocida, y los nodos ciegos aquellos cuyas posiciones no se conocen, por tanto aparecen dibujados en posiciones aleatorias. Los citados muelles se estiran o encogen lo que provoca que la fuerza total en cada nodo ciego sea distinta de cero.

Esta concepción de la WSN nos lleva a definir para cada muelle  $s_{ij}$  su fuerza de la forma siguiente:  $F_{ij} = -k_{ij}(l_{ij} - l_{ij0})$ , donde  $k_{ij}$  y  $l_{ij0}$  son atributos del muele ij, concretamente la constante del muelle y su longitud en reposo respectivamente. Este muelle "une" a los nodos i y j. En este contexto podemos definir también

parámetros como la aceleración, la fuerza total ejercida sobre cada nodo y las funciones de estado para posición y velocidad.

$$\mathbf{a}_{i} = \frac{\mathbf{F}_{i}}{m_{i}}$$
$$\mathbf{F}_{i} = \sum_{s_{ij} \in S} \mathbf{F}_{ij} - \eta \cdot \mathbf{v}_{i}$$
$$\mathbf{r}_{i}(t + \Delta T) = \mathbf{r}_{i}(t) + \mathbf{v}_{i}(t) \cdot \Delta T$$
$$\mathbf{v}_{i}(t + \Delta T) = \mathbf{v}_{i}(t) + \mathbf{a}_{i}(t) \cdot \Delta T$$

En las expresiones anteriores tenemos que  $m_i$  es la masa,  $\mathbf{r}_i$  la posición,  $\mathbf{v}_i$  la velocidad y  $\mathbf{a}_i$  la aceleración, del nodo *i*-ésimo.

Al igual que el algoritmo RVI también aquí es necesaria una inicialización que permita una ubicación previa de los nodos ciegos. En este sentido los autores de este algoritmo proponen asignar aleatoriamente una posición virtual con velocidad nula a los nodos ciegos. El paso siguiente es medir la distancia a sus vecinos en base a cálculos basados en valores RSSI, o metodologías basadas en medidas TDOA, TOA o AOA. También es esta etapa se necesita información de la posición de sus vecinos. Luego, recapitulando, tendríamos un primer paso, inicialización, y un segundo paso, medida de distancias. El tercer paso es el cálculo de las fuerzas,  $\mathbf{F}_{ij}$ , ejercidas sobre sus vecinos, la aceleración,  $\mathbf{a}_i$ , la nueva posición,  $\mathbf{r}_i$  y la velocidad,  $\mathbf{v}_i$ . En este paso es necesario establecer un valor adecuado para  $\Delta T$ . Cuanto más largo sea este valor más rápidamente se alcanzará la posición correcta. En el cuarto paso se comprueba si la fuerza que sus vecinos ejercen sobre él, es suficientemente pequeña o bien está por debajo de un umbral predeterminado. También se puede parar en base a un número determinado de iteraciones en base a un  $\Delta T$  determinado. En caso de no llegar a estos límites se repiten los pasos 2 y 3 iterativamente hasta alcanzarlo.

## 4.3.3. Estimación de la Constante de Atenuación

Durante todo el apartado anterior hemos trabajado sobre la idea de que  $a_i$  es conocida. Sin embargo, al presentar el modelo de propagación ya quedó claro que no es así. Además, al explicar la ecuación *Ec.4.3.3* se vio que son varias las fuentes de error en el modelo pues desconocemos varios de los parámetros que intervienen en la misma. También dijimos que consideraremos  $N_i$  una variable aleatoria gaussiana multidimensional con unas medias y covarianza que usaremos de forma razonada.

En primer lugar vamos a reescribir la ecuación *Ec.4.3.3* en forma matricial:

$$p_i = \mathbf{C} \cdot \boldsymbol{\alpha} + \mathbf{N} \tag{Ec. 4.3.14}$$

donde  $\mathbf{a} = [a_1, \dots, a_N]^T$  es la incógnita,  $\mathbf{p} = [p_1, \dots, p_N]^T$  y  $\mathbf{N} = [N_1, \dots, N_N]^T$  son los vectores de potencia y el error en cada nodo fijo, respectivamente, y la siguiente:

$$C = \begin{pmatrix} -10 \cdot \log_{10} d_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & -10 \cdot \log_{10} d_N \end{pmatrix}$$
(Ec. 4.3.15)

es una matriz diagonal de distancias logarítmicas. Si pasamos  $\mathbf{C} \cdot \mathbf{a}$  a la izquierda podemos ver que su estadística es la misma que la de  $N_i$ , esto es, gaussiana. Entonces, podemos expresar la función de densidad de probabilidad como:

$$p_N \propto \exp\left\{ \left( \mathbf{p} - \mathbf{C} \cdot \boldsymbol{\alpha} \right)^T \mathbf{Q}^{-1} \left( \mathbf{p} - \mathbf{C} \cdot \boldsymbol{\alpha} \right) \right\}$$
 (Ec. 4.3.16)

donde hemos omitido el denominador de  $p_N$  que depende de unas constantes y del determinante de **Q**. Este denominador carece de interés para nuestros propósitos. Hemos considerado que el error es un proceso de media cero y matriz de covarianza **Q**. Llegados a este punto se impone estimar **a** y para ello presentamos varios métodos.

#### • Minimización de la Probabilidad de Error

En este método, minimizar el argumento de la exponencial de Ec.4.3.16 es equivalente a minimizar  $p_N$ . Si obtenemos el gradiente [Pedersen 2008] respecto de a e igualamos a cero tenemos que

$$\boldsymbol{\alpha}_0 = \mathbf{C}^{-1} \cdot \mathbf{p} \tag{Ec. 4.3.17}$$

Como se puede apreciar, desde un punto de vista computacional, basta con una inversión de la matriz **C** y un producto por un vector. El problema de este método es que tal como se plantea conlleva un problema de partida. Este es que las distancias  $d_i$  no son conocidas de antemano. Una opción es sustituir  $d_i$  por  $d_i$  en *Ec.4.3.17*.

La otra opción es aplicar métodos iterativos en los que partiendo de una inicialización de  $a = a_{ini}$  podamos ir refinando las estimaciones hasta cumplir una condición de parada. Esto es lo que hacemos en los apartados que siguen.

#### • Método Iterativo de Primer Orden sin Restricciones

En este método se define una función de optimización  $f(\alpha)$  y se vuelve a estimar la incógnita de forma iterativa. El método más sencillo es el de paso descendente que se define de la siguiente forma [Dennis 1996]:

$$\boldsymbol{\alpha}_{k} = \boldsymbol{\alpha}_{k-1} - \lambda \cdot \nabla_{\alpha} f(\alpha), \quad k=1,\dots, \mathbf{K}$$
(Ec. 4.3.18)

donde  $\lambda$  es una constante que controla la actualización y  $\nabla_{\alpha} f(a)$  es el gradiente de f(a) respecto de a. La función de optimización es  $f(\alpha) = (\mathbf{p} - \mathbf{C} \cdot \alpha)^T \mathbf{Q}^{-1} (\mathbf{p} - \mathbf{C} \cdot \alpha)$ , en nuestro caso, y su gradiente [Pedersen 2008].

$$\nabla_{\alpha} f(\boldsymbol{\alpha}) = 2(\mathbf{p} - \mathbf{C} \cdot \boldsymbol{\alpha})^T \mathbf{Q}^{-1}, \quad k = 1, \dots, \mathbf{K}$$
 (Ec. 4.3.19)

Las iteraciones se realizarán hasta alcanzar uno de los siguientes límites:

- 1. El número máximo, K.
- 2. Si la diferencia cuadrática media entre dos estimaciones consecutivas es inferior a un valor dado.

Para la inicialización, a falta de datos empíricos, podemos tomar como plausible  $a_{ini}=[2,\cdots,2]^T$ , esto es, partimos del modelo de propagación en espacio libre.

En cada iteración, comenzando desde la primera con  $\mathbf{a}_{ini}$  aplicamos *Ec.4.3.11* para tener una estimación de las distancias  $d_i$ . Con cada nueva iteración se refinan tanto a como  $d_i$ .

Con esta implementación no hay restricciones en la solución, esto es, las componentes del vector **a** pueden tomar cualquier valor. Como vimos anteriormente, al presentar el modelo de propagación, sus valores están de suerte que  $a_i \in [1,5]$  o, dicho de otra forma,  $1 \le \alpha_i \le 5$ . En la ecuación *Ec.4.3.19* esta restricción no está contemplada y será objeto de estudio específico en un apartado posterior de esta misma sección.

#### • Método Iterativo de Segundo Orden sin Restricciones

Para este método tomamos la ecuación de Newton-Raphson [Dennis 1996], que tiene la expresión siguiente:

$$\boldsymbol{\alpha}_{k} = \boldsymbol{\alpha}_{k-1} - \nabla_{\alpha} f(\boldsymbol{\alpha}) \cdot \mathbf{H}(\boldsymbol{\alpha})^{-1}$$
 (Ec.4.3.20)

donde  $\mathbf{H}(\alpha)$  es el Hessiano de  $f(\alpha)$  y se expresa como  $\mathbf{H}(\alpha)=2 \cdot \mathbf{C}^{\mathrm{T}} \mathbf{Q}^{-1} \mathbf{C}$ . También en este método para la inicialización podemos tomar como plausible  $\alpha=[2,\dots,2]^{\mathrm{T}}$ . En cada iteración, comenzando desde la primera con  $\alpha_{\mathrm{ini}}$  aplicamos Ec.4.3.11 para tener una estimación de las distancias  $d_{\mathrm{i}}$ . Con cada nueva iteración se refinan tanto  $\alpha$  como  $d_{\mathrm{i}}$  de la misma forma que en el apartado anterior. Vemos que en este método eso se hace sin restricción alguna sobre los valores resultantes de  $\alpha$ .

#### • Método Iterativo de Segundo Orden con Restricciones

En este caso la función de coste de partida es Ec.4.3.20 pero hemos de añadir las restricciones, que son:

1.  $a_i \leq 5, \forall i$ 2.  $1 \leq a_i, \forall i$ 

La forma de proceder es la siguiente:

1. Se actualizan las estimaciones como en el método sin restricciones.

2. Se estudian individualmente las restricciones para cada nodo fijo y, de ser necesario, se acotan los valores de los multiplicadores.

## • Consideraciones sobre la Estimación de Distancias

En los diversos métodos de estimación de  $\alpha$  hemos tomado las distancias como conocidas. Sin embargo, sólo las conocemos de forma aproximada a dos formas:

- 1. A partir de *Ec.4.3.6* y *Ec.4.3.7*.
- 2. Como en cada iteración disponemos de una estimación de  $\alpha$  podemos aplicar *Ec.4.3.13* y volver a calcular las  $d_i$ .

En nuestros experimentos hemos tomado la opción 2 tal como se explicó en apartados anteriores.

# 4.4 El Problema del Seguimiento de Móviles y Aproximación mediante Medidas de Distancia

Para abordar el problema de seguimiento de móviles necesitamos definir un modelo de observación. Esto es lo que abordamos en el primer subapartado. Además, es necesario estudiar qué aparato matemático es el más adecuado. Existen en la literatura varios enfoques matemáticos. A grosso modo podemos considerar dos categorías principales: Filtrado de Kalman Extendido (Extended Kalman Filtering, EKF) [Welch 2006] y Métodos Estadísticos en la que el Filtrado de Partículas (Particle Filtering, PF) [Arulampalam 2002, Gustafsson 2002] es uno de sus principales exponentes. Dedicamos un subapartado a justificar la elección del EKF en base al modelo de observación elegido. Con todo esto estamos en disposición de hacer un estudio del modelo de movimiento y cómo incorporarlo al filtrado de Kalman que nos permitirá, conforme llegan medidas, estimar en cada momento el estado del sistema, esto es, la posición y velocidad del móvil. Finalmente, justificamos el uso de los algoritmos de localización vistos en apartados anteriores como fuente de medidas basadas en la distancia entre el móvil y los nodos de referencia.

# 4.4.1. El Modelo de Observación

Los humanos hemos estado observando cosas prácticamente desde siempre. Yendo un poco más hacia adelante en el problema de seguimiento vamos a considerar que además de observar filtramos las observaciones de forma conveniente. Antes de pasar al modelo de observación y posteriormente al filtrado veamos ejemplos de interés. Un ejemplo simple es el filtrado del agua. Nosotros podemos filtrar las impurezas del agua simplemente usando nuestras manos para quitar la suciedad. Otro ejemplo es la eliminación del ruido de nuestro entorno. Si pusiéramos atención a todos los ruidos que se suceden a nuestro alrededor nos volveríamos locos. De modo que aprendemos, a ignorar los sonidos superfluos (tráfico, obras, etc.) y a focalizar los importantes, tales como las voces de nuestros interlocutores. Hay también muchos ejemplos en la ingeniería donde es deseable el filtrado. Las señales de las comunicaciones vía radio con frecuencia están corrompidas con ruido. Un buen filtrado puede eliminar el ruido de señales electromagnéticas reteniendo la información útil.

El problema de diseño de observadores básicamente consiste en determinar (estimar) los estados internos de un sistema lineal, teniendo acceso únicamente a las salidas del sistema. La mayoría de las aproximaciones a este problema se basan típicamente en un modelo de espacio de estados. Así, hay un modelo de proceso que emula las transformaciones de los procesos de estados. Este, desde una visión muy simplificada, puede representarse como una ecuación lineal de diferencias estocásticas, similar a la siguiente:

$$\mathbf{x}_{k} = \mathbf{A} \cdot \mathbf{x}_{k-1} + \mathbf{B} \cdot \mathbf{u}_{k-1} + \mathbf{w}_{k-1}$$
(*Ec. 4.4.1*)

donde A es la matriz de transición de estados que, sin pérdida de generalidad, se puede considerar conocida;  $w_k$  es el ruido del proceso que se puede considerar gaussiano de media nula y matriz de covarianza Q; y B es una matriz de entradas determinista.

Además, existe también alguna forma de medida del modelo que describe la relación entre los estados del proceso y las medidas. Esto puede representarse generalmente mediante una expresión lineal similar a la ecuación siguiente:

$$\mathbf{z}_{k} = \mathbf{H} \cdot \mathbf{x}_{k} + \mathbf{v}_{k} \qquad (Ec. 4.4.2)$$

donde H es la matriz de medida y  $v_k$  representa el ruido de las medidas. Una observación importante respecto a las medidas es que estas no tienen porque ser específicamente elementos del estado, sino que pueden ser cualquier combinación lineal de los elementos del estado.

Un problema bastante común es el relativo al total desconocimiento del modelo de transformación del estado actual. Es posible realizar predicciones sobre intervalos relativamente cortos usando modelos basados en transformaciones de estados recientes, tales predicciones suponen que las transformaciones son predecibles, pero no siempre es el caso. El resultado es que al igual que sucede con la información del sensor, las estimas en curso del estado deben ser cualificadas cuando se combinan con las medidas como una secuencia global de estimas. Por eso, los modelos de los procesos incorporan típicamente algún grado de aleatoriedad o incertidumbre.

Consideramos el más común de los casos, esto es, trabajar con nodos (sensores) que facilitan medidas y estas llevan asociadas un ruido. Son muchas las fuentes de ruido en tales medidas. Por ejemplo, cada tipo de sensor tiene unas limitaciones fundamentales relacionadas con el medio físico, y cuando juntamos el conjunto de esas limitaciones las señales se degradan. Además, siempre se añade a la señal algo de ruido eléctrico, bien a través del sensor o bien en los circuitos eléctricos. La variación temporal de la relación de señal pura a ruido eléctrico afecta continuamente tanto a la cantidad como a la calidad de la información recogida. El resultado es que la información obtenida de cualquier sensor debe ser cualificada cuando se la interpreta como parte de una secuencia global de estimas, por tanto los modelos analíticos de las medidas típicamente incorporan alguna porción de ruido aleatorio o incertidumbre en la medida.

## 4.4.2. Seguimiento basado en un Vector de Estados

Una gran ventaja del modelo de observador que hemos visto en el apartado anterior es que disponemos de un aparato matemático adecuado para su uso en problemas prácticos y que está basado en el concepto de estado. Este es el filtrado de Kalman. Se compone de un conjunto de ecuaciones matemáticas que proporcionan un medio computacionalmente eficiente (recursivo) de estimar el estado de un proceso, de manera que minimiza el error cuadrático medio [Welch 2006, Simon 2009]. El filtro es muy potente en varios aspectos: soporta estimaciones de estados pasados, estados presentes e incluso de estados futuros, tareas que puede realizar incluso cuando la naturaleza precisa del sistema es desconocida. El filtrado de Kalman (Kalman Filtering, KF) fue desarrollado en los años 60 del pasado siglo XX, aunque sus raíces se remontan en el tiempo a la época de Karl Gauss allá por 1795. El filtrado de Kalman ha sido aplicado en áreas tan diversas como seguimiento genérico de fuentes de todo tipo o, más concretas, navegación marina, técnica aeroespacial, instrumentación en plantas de energía nuclear, modelado demográfico, aplicaciones industriales, y muchas otras.

## • El Proceso que se Estimado mediante Filtrado de Kalman

El filtro de Kalman aborda un problema general, como es el de estimar el estado  $\mathbf{x} \in \Re^n$  de un proceso observable a intervalos regulares, proceso que está gobernado por una ecuación estocástica de diferencias lineales.

$$\mathbf{X}_{k} = \mathbf{A} \cdot \mathbf{X}_{k-1} + \mathbf{B} \cdot \mathbf{u}_{k-1} + \mathbf{w}_{k-1}$$
(Ec.4.4.3)

con una medida  $\mathbf{z} \in \Re^m$  que es

$$\mathbf{z}_{k} = \mathbf{H} \cdot \mathbf{x}_{k} + \mathbf{v}_{k} \qquad (Ec. 4.4.4)$$

Las variables aleatorias  $\mathbf{w}_k$  y  $\mathbf{v}_k$  representan el ruido del proceso y de las medidas, respectivamente. Vemos, pues, que la notación y los conceptos en estas dos ecuaciones son compartidos con *Ec.4.4.1 y Ec.4.4.2*.

Tanto para  $\mathbf{w}_k$  como para  $\mathbf{v}_k$  vamos a suponer que son ruidos independientes entre sí, blancos y con distribuciones de probabilidad normales:

$$p(w) \sim N(0, Q)$$
 (*Ec.4.4.5*)

$$p(v) \sim N(0, \mathbf{R})$$
 (Ec. 4.4.6)

En la práctica, la matriz de covarianza del ruido del proceso,  $\mathbf{Q}$ , y la matriz covarianza del ruido de la medida,  $\mathbf{R}$ , podrían cambiar con cada paso temporal o medida, sin embargo aquí supondremos que son constantes.

La matriz **A** de dimensión n × n de la ecuación en diferencias *Ec.4.4.3* relaciona el estado en el paso temporal previo (*k*-1) con el estado en el paso actual (*k*), en ausencia de una función de excitación o bien ruido del proceso. Observemos que en la práctica podría cambiar con cada paso temporal, pero vamos a suponer que es constante. La matriz n × l **B** relaciona la entrada de control opcional  $\mathbf{u} \in \Re^1$  con el estado **x**. La matriz m × n **H** de la ecuación de medidas *Ec.4.4.4* relaciona el estado con la medida  $\mathbf{z}_k$ . En la práctica **H** podría cambiar con cada paso temporal o medida, pero al igual que para **A** supondremos que es constante.

Definamos  $\hat{\mathbf{x}}_{k} \in \mathfrak{R}^{n}$  como la estimación de un estado a priori al paso k que nos proporciona conocimiento del proceso previo a la paso k. Mientras que  $\hat{\mathbf{x}}_{k} \in \mathfrak{R}^{n}$  será nuestra estimación del estado a posteriori en el paso k dada la medida  $z_{k}$ . Luego, es posible definir los errores de la estimación a priori y a posteriori como:

$$e_k^- \equiv x_k - \hat{x}_k^-$$
, y  $e_k \equiv x_k - \hat{x}_k$  (Ec. 4.4.7)

Para derivar las ecuaciones del filtro de Kalman, comenzaremos por encontrar una ecuación que calcule la estimación de un estado a posteriori,  $\hat{\mathbf{x}}_{_{k}}$ , como una combinación lineal de una estimación a priori,  $\hat{\mathbf{x}}_{_{k}}^{-}$ , junto con una diferencia ponderada entre la medida actual,  $\mathbf{z}_{k}$ , y una predicción de la misma,  $\mathbf{H} \cdot \hat{\mathbf{x}}_{_{k}}^{-}$ , tal y como se muestra en la siguiente ecuación:

$$\hat{\mathbf{x}}_{k} = \hat{\mathbf{x}}_{\bar{k}} + \mathbf{K} \left( \mathbf{z}_{k} - \mathbf{H} \cdot \hat{\mathbf{x}}_{\bar{k}} \right)$$
(Ec. 4.4.8)

La diferencia  $(\mathbf{z}_k - \mathbf{H} \cdot \hat{\mathbf{x}}_k)$  en la ecuación anterior recibe el nombre de medida de la *innovación*, o *residuo*. El residuo refleja la discrepancia entre la predicción de la medida  $\mathbf{H} \cdot \hat{\mathbf{x}}_k^-$  y la medida actual  $\mathbf{z}_k$ . Un valor residual de valor cero significa que las dos están completamente de acuerdo.

La matriz **K** de dimensiones  $n \times m$  es la ganancia o factor de combinación que minimiza la covarianza del error a posteriori dada por:

$$\mathbf{P}_{\mathbf{k}} = E\left[\boldsymbol{e}_{\boldsymbol{k}}\boldsymbol{e}_{\boldsymbol{k}}^{T}\right]$$

Esta minimización puede lograrse en primer lugar sustituyendo la Ec.4.4.3 en la definición dada para  $e_k$ , Ec.4.4.7, luego sustituyendo en la expresión dada para la covarianza del error y seguidamente realizando la esperanza matemática indicada, continuamos tomando la derivada de la traza del resultado con respecto a **K**, igualamos a cero y resolvemos para **K**. Una forma del valor de **K** resultante que minimiza la covarianza del error sería la siguiente:

$$K_{k} = \mathbf{P}_{k}^{-} \cdot \mathbf{H}^{T} \left( \mathbf{H} \cdot \mathbf{P}_{k}^{-} \cdot \mathbf{H}^{T} + \mathbf{R} \right)^{-1} = \frac{\mathbf{P}_{k}^{-} \cdot \mathbf{H}^{T}}{\mathbf{H} \cdot \mathbf{P}_{k}^{-} \cdot \mathbf{H}^{T} + \mathbf{R}}$$
(Ec.4.4.9)

donde  $\mathbf{P}_{\mathbf{k}}^{-} = E\left[e_{\mathbf{k}}^{-}e_{\mathbf{k}}^{-T}\right]$  es la estimación de la covarianza del error a priori. Una observación algo más detenida de la ecuación *Ec.4.4.9* permite ver que cuando la covarianza del error de medida, **R**, se aproxima a cero, la ganancia **K** pondera el residuo de una forma más abrupta. Lo contrario ocurre cuando se aproxima a cero la estimación de la covarianza del error a priori  $\mathbf{P}_{\mathbf{k}}^{-}$ .

$$\lim_{\mathbf{R}_k \to 0} \mathbf{K}_k = \mathbf{H}^{-1}$$
$$\lim_{\mathbf{P}_k^- \to 0} \mathbf{K}_k = 0$$

Otro modo de pensar sobre la actuación ponderadora de K es que cuando la covarianza del error de medida, R, se aproxima a cero, la medida actual  $\mathbf{z}_k$  es cada vez más y más verdadera, mientras deja de serlo cada vez más la predicción de la medida,  $\mathbf{H}\hat{\mathbf{x}}_{\bar{k}}$ . Por otro lado, cuando la estimación de la covarianza del error a priori  $\mathbf{P}_k^-$  se aproxima a cero la medida actual  $\mathbf{z}_k$  es cada vez más errónea, mientras que la predicción  $\mathbf{H}\hat{\mathbf{x}}_{\bar{k}}$  se hace cada vez más certera.

#### • El Algoritmo Discreto del Filtro de Kalman

Para la estimación del proceso en el filtrado de Kalman se usa una forma de control realimentado. La estimación del proceso se realiza en algún instante y luego se obtiene realimentación en forma de medidas (ruidosas). Las ecuaciones del filtro de Kalman entran en uno de los dos grupos siguientes: ecuaciones de actualización temporal y ecuaciones de actualización de medidas. Las ecuaciones de actualización son las responsables de proyectar hacia adelante en el tiempo el estado actual y la estimaciones de la covarianza del error para obtener estimas a priori en el siguiente instante. Las ecuaciones de actualización de medidas son las responsables de la realimentación, p.ej., para incorporar una nueva medida en la estimación a priori con la que obtener una estimación a posteriori mejorada.

Las ecuaciones de actualización temporal se pueden ver también como ecuaciones de predicción mientras que las de actualización de medidas se pueden ver como ecuaciones correctoras. De hecho el algoritmo de estimación definitivo se asemeja



Figura 4.4.1. Algoritmo del filtrado de Kalman.

mucho al algoritmo corrector-predictor para la resolución de problemas numéricos.

La primera tarea durante la actualización de las medidas es calcular la ganancia de Kalman,  $\mathbf{K}_k$ . El siguiente paso es medir el proceso para obtener  $\mathbf{z}_k$ , y entonces generar a posteriori una estimación del estado mediante la incorporación de la

medida. Después de cada par de actualización temporal y de medida, el proceso es repetido con las estimas a posteriori y previas usadas para proyectar o predecir las nuevas estimas a priori. En Figura 4.4.1 podemos ver el organigrama del algoritmo descrito [Welch 2006].

#### • El Proceso de Estimación mediante Filtrado de Kalman Extendido

Como hemos descrito previamente, el filtro de Kalman aborda un problema general, como es el de probar a estimar el estado  $\mathbf{x} \in \Re^n$  de un proceso controlado discreto en el tiempo, proceso que está conducido por un ecuación estocástica de diferencias lineales. Pero, ¿Qué sucede si el proceso a ser estimado y o medido, y que conduce el sistema es no lineal? Algunas de las más interesantes y satisfactorias aplicaciones del filtrado de Kalman se encuentran en esta situación. Al filtro de Kalman que linealiza la media y covarianzas actuales se le conoce como Filtro Extendido de Kalman, EKF. De forma similar a las series de Taylor, podemos linealizar la estimación entorno a la actual.

Para ello usamos las derivadas parciales de las funciones del proceso y de medida, para el cálculo de las estimaciones, incluso en el caso de una relación no lineal. Para hacer esto, debemos empezar por modificar alguna de las bases presentadas en el apartado anterior. Asumimos nuevamente que tenemos un vector de estados  $\mathbf{x} \in \Re^n$ , la diferencia ahora es un proceso controlado por una ecuación estocástica de diferencias no lineales

$$\mathbf{x}_{k} = f(\mathbf{x}_{k-1}, \mathbf{u}_{k}, \mathbf{w}_{k-1}) \tag{Ec. 4.4.10}$$

acompañada de una ecuación de medidas  $\mathbf{z} \in \Re^m$  dada por:

$$\mathbf{z}_{k} = h(\mathbf{x}_{k}, \mathbf{v}_{k}) \qquad (Ec. 4.4.11)$$

donde nuevamente las variables aleatorias  $\mathbf{w}_k$  y  $\mathbf{v}_k$  representan el ruido del proceso y de las medidas. En este caso la función no lineal  $f(\cdot)$  en la ecuación de diferencias Ec.4.4.10 relaciona el estado en las k-1 etapas temporales previas con el estado actual en la etapa k. Incluyendo como parámetros una función de excitación,  $\mathbf{u}_k$ , y el ruido del proceso de media nula,  $\mathbf{w}_k$ . La función no lineal  $h(\cdot)$  es la ecuación de medidas Ec.4.4.11 relaciona el estado  $\mathbf{x}_k$  con la medida  $\mathbf{z}_k$ .

En la práctica no conocemos los valores de  $\mathbf{w}_k$  y  $\mathbf{v}_k$  en cada etapa. Sin embargo, podemos aproximar el vector de estados y el de medida sin ellos mediante:

$$\tilde{\mathbf{X}}_{k} = c \quad y \quad \tilde{\mathbf{Z}}_{k} = h(\tilde{\mathbf{X}}_{k}, 0) \tag{Ec. 4.4.12}$$

donde  $\hat{\mathbf{x}}_{k}$  es una estimación a posteriori del estado (desde una etapa previa k).

Es importante destacar que un defecto fundamental del EKF es que las distribuciones (o densidades en el caso continuo) de las distintas variables aleatorias ya no son normales después de sufrir sus respectivas transformaciones no lineales. El EKF es simplemente un estimador de estados *ad hoc* que, mediante linealización, sólo sirve de aproximación a la regla de Bayes óptima.

Para estimar un proceso con relaciones de diferencias y medidas no lineales, empezaremos escribiendo nuevas ecuaciones de gobierno que linealizan una estimación sobre las ecuaciones Ec.4.4.10 y Ec.4.4.11.

$$\mathbf{x}_{k} \approx \tilde{\mathbf{X}}_{k} + \mathbf{A} \left( \mathbf{x}_{k-1} - \hat{\mathbf{X}}_{k-1} \right) + \mathbf{W} \cdot \mathbf{w}_{k-1} = \mathbf{A} \cdot \mathbf{x}_{k-1} + \mathbf{W} \cdot \mathbf{w}_{k-1}$$
(Ec. 4.4.13)

$$\mathbf{z}_{k} \approx \tilde{\mathbf{z}}_{k} + \mathbf{H} \cdot \left( \mathbf{x}_{k} - \tilde{\mathbf{x}}_{k} \right) + \mathbf{V} \cdot \mathbf{v}_{k} = \tilde{\mathbf{z}}_{k} + \mathbf{H} \cdot \mathbf{x}_{k} - \mathbf{H} \cdot \tilde{\mathbf{x}}_{k} + \mathbf{V} \cdot \mathbf{v}_{k} = \mathbf{H} \cdot \mathbf{x}_{k} + \mathbf{V} \cdot \mathbf{v}_{k} \qquad (Ec. 4.4.14)$$

donde  $\mathbf{x}_k$  y  $\mathbf{z}_k$  son los vectores de estado y medida actuales,  $\mathbf{\tilde{x}}_k$  y  $\mathbf{\tilde{z}}_k$  son los vectores de estado y medida aproximados en base a las ecuaciones Ec.4.4.12,  $\mathbf{\hat{x}}_k$  es una estimación a posteriori del estado en la etapa k. Las variables aleatorias  $\mathbf{w}_k$  y  $\mathbf{v}_k$  representan el ruido del proceso y las medidas, respectivamente, al igual que en las ecuaciones Ec.4.4.3 y Ec.4.4.4. Por otro lado, veamos cómo obtener las matrices que aparecen en Ec.4.4.13 y Ec.4.4.14. En primer lugar, para la ecuación de estados,  $\mathbf{A}$  es la matriz del Jacobiano de derivadas parciales de f con respecto a  $\mathbf{x}$ :

$$A_{[i,j]} = \frac{\partial f_{[i]}}{\partial \mathbf{x}_{[j]}} (\hat{\mathbf{x}}_{k-1}, \mathbf{u}_{k}, 0)$$

y W es la matriz del Jacobiano de derivadas parciales de f con respecto a w:

$$W_{[i,j]} = \frac{\partial f_{[i]}}{\partial \mathbf{w}_{[j]}} (\hat{\mathbf{x}}_{k-1}, \mathbf{u}_{k}, 0)$$

Y en segundo lugar, para la ecuación de medidas,  $\mathbf{H}$  es la matriz del Jacobiano de derivadas parciales de h con respecto a  $\mathbf{x}$ :

$$H_{[i,j]} = \frac{\partial h_{[i]}}{\partial \mathbf{x}_{[j]}} (\tilde{\mathbf{x}}_{k}, 0)$$

y V es la matriz del Jacobiano de derivadas parciales de h con respecto a v:

$$V_{[i,j]} = \frac{\partial h_{[i]}}{\partial \mathbf{v}_{[j]}} (\tilde{\mathbf{x}}_{k}, \mathbf{0}) .$$

Hemos de precisar que por simplicidad notacional no hemos hecho uso del subíndice temporal k en los Jacobianos A, W, H y V.

A continuación vamos a definir una nueva notación para el error de predicción y el residuo de la medida

$$\tilde{\boldsymbol{e}}_{\mathbf{x}_{k}} \equiv \mathbf{X}_{k} - \tilde{\mathbf{X}}_{k} \qquad (Ec.4.4.15)$$

$$\tilde{\boldsymbol{e}}_{\boldsymbol{z}_{k}} \equiv \boldsymbol{Z}_{k} - \tilde{\boldsymbol{Z}}_{k} \qquad (Ec.4.4.16)$$

Recordemos que no disponemos de  $\mathbf{x}_k$  para la ecuación Ec.4.4.15, se trata del vector de estados actual que se intenta estimar. Por otro lado, si tenemos acceso a  $\mathbf{z}_k$  en la ecuación Ec.4.4.16, se trata de la medida actual que vamos a usar para estimar  $\mathbf{x}_k$ . Usando las ecuaciones Ec.4.4.15 y Ec.4.4.16 podemos escribir las ecuaciones de gobierno para un error del proceso del modo siguiente:

$$\tilde{\boldsymbol{e}}_{\mathbf{x}_{k}} \approx \mathbf{A} \left( \mathbf{X}_{k-1} - \hat{\mathbf{X}}_{k-1} \right) + \boldsymbol{\varepsilon}_{k} \qquad (Ec.4.4.17)$$

$$\tilde{e}_{z_k} \approx \mathbf{H} \cdot \tilde{e}_{z_k} + \eta_k \qquad (Ec. 4.4.18)$$

donde  $\varepsilon_k$  y  $\eta_k$  representan nuevas variables aleatorias independientes que tienen media nula y matrices de covarianza  $\mathbf{W} \cdot \mathbf{Q} \cdot \mathbf{W}^T$  y  $\mathbf{V} \cdot \mathbf{R} \cdot \mathbf{V}^T$ , siendo  $\mathbf{Q}$  y  $\mathbf{R}$  las matrices dadas en las ecuaciones *Ec.4.4.5* y *Ec.4.4.6*, respectivamente.

Con las consideraciones anteriores se puede llegar a un conjunto completo ecuaciones EKF tal como se expresa en la Figura 4.4.2. Se observa la sustitución de  $\hat{\mathbf{x}}_{\bar{k}}$  por  $\tilde{\mathbf{x}}_{k}$  a fin de ser consistentes con la notación a priori inicial, y que ahora añadimos el subíndice *k* a los Jacobianos **A**,**W**, **H**, y **V**, para reforzar la noción de que son diferentes (y deben ser calculados cada vez) en cada paso temporal.

Al igual que con el filtro discreto de Kalman, el básico, las ecuaciones de actualización temporal, Figura 4.4.2, proyectan la estimación del estado y covarianza de el instante previo etapa k-1 al instante actual etapa k. En el bloque de actualización temporal de las ecuaciones EKF, Figura 4.4.2, f proviene de la ecuación Ec.4.4.12. Los Jacobianos del proceso en la etapa k son  $A_k$  y  $W_k$ , y  $Q_k$  es la covarianza del ruido del proceso en la etapa k, Ec.4.4.5.

También para las ecuaciones de actualización de las medidas, Figura 4.4.2, de la misma manera que en las básicas del filtro discreto de Kalman, corregimos las estimas del estado y covarianza con la medida  $\mathbf{z}_k$ . De nuevo h viene de la ecuación *Ec.*.4.4.12,  $\mathbf{H}_k$  y V son los Jacobianos de la medida en la etapa k, y  $\mathbf{R}_k$  es la covarianza del ruido de la medida, ecuación *Ec.*4.4.6, en la etapa k (es de notar que ahora se permite que **R** cambie con cada medida).



Figura 4.4.2. Algoritmo del filtrado extendido de Kalman (EKF).

Una importante característica del EKF es que el Jacobiano  $\mathbf{H}_k$  de la ecuación de la ganancia de Kalman,  $\mathbf{K}_k$  sirve para propagar o magnificar adecuadamente únicamente las componentes relevantes de la información de medida. Por ejemplo, si no hay una asociación uno a uno entre la medida  $\mathbf{z}_k$  y el estado a través de *h*, el Jacobiano  $\mathbf{H}_k$  afecta a la ganancia de Kalman de modo que únicamente magnifica la porción del residuo  $\mathbf{z}_k \cdot h(\hat{\mathbf{x}}_k, 0)$  que afecta al estado. Por supuesto si sobre la totalidad de las medidas no hay una asociación uno a uno entre la medida  $\mathbf{z}_k$  y el estado vía *h*, entonces deberíamos esperar que el filtro diverja rápidamente, en cuyo caso el proceso sería inobservable.

# 4.4.3. Conjunción del Filtrado de Kalman y Medidas Relacionadas con la Distancia

En los apartados anteriores nos hemos acercado al modelo de observación. También hemos visto cómo el filtrado de Kalman nos aporta una descripción matemática del mismo. Así se puede predecir el estado del sistema en instantes posteriores conforme nos van llegando las medidas de que disponemos. En este apartado vamos un paso más adelante y concretamos cómo incorporamos los conceptos vistos para hacer seguimiento de fuentes en movimiento.

La incertidumbre en la estimación del estado debida a la dinámica aleatoria de un móvil, o al modelado erróneo de esa dinámica se representa típicamente mediante la matriz de la covarianza del ruido del proceso,  $\mathbf{Q}$ , que ya hemos visto en 4.4.1. La elección de esta matriz está basada, generalmente, en el resultado de un número elevado de experimentos o en el desarrollo de modelos físicos exactos [Blackman 1999].

El modelo de Singer [Singer 1970] es probablemente el estándar para modelar las maniobras de un móvil. Sin embargo, su principal debilidad reside en que depende del conocimiento de la aceleración, y no siempre es factible obtener una estimación precisa de la misma. Es el caso de cuando se dispone de medidas de la posición pero no de la velocidad.

Consideremos un sistema que usa la posición del blanco (x), la velocidad ( $v_x$ ) y, posiblemente, la aceleración ( $a_x$ ) como estados. Supongamos que la aceleración del móvil es un proceso de Markov de primer orden en la forma:

$$a(k+1) = \rho_m a(k) + \sqrt{1 - \rho_m^2} \cdot \sigma_m \cdot r(k)$$

donde  $\rho_m = \exp(-\beta T)$ , con  $\beta = 1/\tau_m$ ,  $\tau_m$  es la constante de tiempo de maniobra del blanco,  $\sigma_m$  es la desviación estándar del tiempo de maniobra del blanco, r(k) una variable aleatoria de distribución gaussiana y media nula que representa la desviación estándar unitaria, y T es el intervalo de muestreo. Veamos algunos ejemplos de valores de  $\beta$  en términos de la constante de maniobra. Cuando  $\tau_m=60$  estamos ante giros o cambios muy lentos. Si, por el contrario,  $\tau_m=1$  estamos ante cambios muy rápidos o turbulentos. En medio tendríamos valores del orden de  $\tau_m=20$  que corresponde a móviles rápidos pero no demasiado.

La matriz de transición resultante viene dada por la siguiente expresión:

$$\mathbf{A} = \begin{bmatrix} 1 & T & \frac{1}{\beta^2} (-1 + \beta T + \rho_m) \\ 0 & 1 & \frac{1}{\beta} (1 - \rho_m) \\ 0 & 0 & \rho_m \end{bmatrix}$$

Típicamente, el intervalo de muestre<br/>o es menor que la constante del tiempo de maniobra (T<<br/> $\tau_{\rm m})$ , usándose habitualmente la aproximación siguiente:

$$\mathbf{A} = \begin{bmatrix} 1 & T & \frac{T^2}{2} \\ 0 & 1 & T(1 - \frac{T}{2\tau_m}) \\ 0 & 0 & \rho_m \end{bmatrix}$$

La solución exacta para la matriz de covarianza del proceso de excitación es:

$$\mathbf{Q} = \frac{2\sigma_m^2}{\tau_m} \begin{bmatrix} q_{11} & q_{12} & q_{13} \\ q_{21} & q_{22} & q_{23} \\ q_{31} & q_{32} & q_{33} \end{bmatrix}$$

donde considerando las simetrías resultantes,  $q_{12} = q_{21}$ ,  $q_{13} = q_{31}$  y  $q_{23} = q_{32}$  tenemos que:

$$q_{11} = \frac{1}{2\beta^5} \left[ 1 - \exp(-2\beta T) + 2\beta T + \frac{2\beta^3 T^3}{3} - 2\beta^2 T^2 - 4\beta T \exp(-\beta T) \right]$$

$$q_{12} = \frac{1}{2\beta^4} \left[ \exp(-2\beta T) + 1 - 2\exp(-\beta T) + 2\beta T \exp(-\beta T) - 2\beta T + \beta^2 T^2 \right]$$

$$q_{13} = \frac{1}{2\beta^3} \left[ 1 - \exp(-2\beta T) - 2\beta T \exp(-\beta T) \right]$$

$$q_{22} = \frac{1}{2\beta^3} \left[ 4\exp(-\beta T) - 3 - \exp(-2\beta T) + 2\beta T \right]$$

$$q_{23} = \frac{1}{2\beta^2} \left[ \exp(-2\beta T) + 1 - 2\exp(-\beta T) \right]$$

$$q_{33} = \frac{1}{2\beta} [1 - \exp(-2\beta T)]$$

Hay varios casos de interés con restricciones. Para intervalos de muestreo cortos  $(T \ll \tau_m)$ , la matriz **Q** y la matriz de transición, **A**, quedarían, reduciéndose esta última a la matriz Newtoniana:

$$\lim_{\beta T \to 0} \mathbf{Q} = \frac{2\sigma_m^2}{\tau_m} \begin{bmatrix} \frac{T^5}{20} & \frac{T^4}{8} & \frac{T^3}{6} \\ \frac{T^4}{8} & \frac{T^3}{3} & \frac{T^2}{2} \\ \frac{T^3}{6} & \frac{T^2}{2} & T \end{bmatrix}; \quad \lim_{\beta T \to 0} \mathbf{A} = \begin{bmatrix} 1 & T & \frac{T^2}{2} \\ 1 & 1 & T \\ 0 & 0 & 1 \\ \end{bmatrix}$$

Si la constante de maniobra es mucho menor que el intervalo de muestreo ( $\tau_{\rm m} << T$ ), entonces no es posible obtener una estimación suficientemente precisa de la aceleración, por lo tanto el filtro sólo debe usar posición y velocidad como estados. En este caso la matriz de transición y la matriz de la covarianza de ruido del proceso quedarían:

$$\mathbf{A} = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad \mathbf{Q} = 2\sigma_m^2 \tau_m \begin{bmatrix} \frac{T^3}{3} & \frac{T^2}{2} \\ \frac{T^2}{2} & T \end{bmatrix}$$

La experiencia indica que el uso del estado aceleración sólo es válido cuando está disponible una medida de la velocidad. Cuando sólo se da la posición, una estimación precisa de la aceleración sólo es posible cuando  $\tau_{\rm m} > 10 \cdot T$ .

#### • Incorporación de Medidas de Distancia

En primer lugar formamos nuestro sistema usando un modelo de espacio de estados. Consideramos una red de N nodos fijos desplegados arbitrariamente. El vector de estados contiene las coordenadas planas y las velocidades del blanco a lo largo de los ejes x e y. La posición del móvil en el eje z es conocida. Luego, el vector de estados es  $\mathbf{x} = [x, v_x, y, v_y]^T$  donde x y y son las coordenadas en el plano, mientras  $v_x$  y  $v_y$  son la velocidad según los ejes x y y.

El estado del blanco en un instante responde al siguiente modelo estocástico discreto:

$$\mathbf{x}_{k} = \mathbf{A} \cdot \mathbf{x}_{k-1} + \mathbf{B} \cdot \mathbf{w}_{k-1}$$

Las medidas, realizables en cada paso temporal, están asociadas al vector de estados a través de la ecuación de medidas como:

$$\mathbf{z}_{k} = h(\mathbf{x}_{k}, \mathbf{v}_{k})$$

donde  $k \in \mathbb{Z}$  es un tiempo discreto que representa la muestra en el instante  $k \cdot T_s$ , siendo  $T_s$  el periodo de muestreo. Las matrices **A** y **B** son:

$$\mathbf{A} = \begin{bmatrix} 1 & T_s & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T_s \\ 0 & 0 & 0 & 1 \end{bmatrix}; \quad \mathbf{B} = \begin{bmatrix} T_s^2 / 2 & 0 \\ 0 & T_s^2 / 2 \\ T_s & 0 \\ 0 & T_s \end{bmatrix}$$

Las medidas de distancia están disponibles en cada instante. Por consiguiente, el vector de medidas es:

$$\mathbf{z}_{n,k} = [d_1, \cdots, d_N]$$
  
 $d_i = \sqrt{(x_i - x)^2 + (y_i - y)^2}$ 

donde ( $x_i, y_i$ ) es la localización del *i*-ésimo nodo fijo, con un vector de estados que incluye posiciones y velocidad dado por  $\mathbf{x} = [x, v_x, y, v_y]^T$ . Si suponemos una red de nodos fijos donde N = 3, la ecuación de medida linealizada en la paso k sería como sigue [Zhu 2006, Di Rocco 2007]:

$$\mathbf{z}_{k} = \mathbf{H} \cdot \mathbf{x}_{k} + \mathbf{\eta} = \begin{bmatrix} \frac{\partial d_{1}}{\partial x} & 0 & \frac{\partial d_{1}}{\partial y} & 0\\ \frac{\partial d_{2}}{\partial x} & 0 & \frac{\partial d_{2}}{\partial y} & 0\\ \frac{\partial d_{3}}{\partial x} & 0 & \frac{\partial d_{3}}{\partial y} & 0 \end{bmatrix} \cdot x_{k} + \mathbf{\eta}$$

donde  $\eta$  es el ruido blanco de la medida y donde los elementos de la matriz H vienen dadas por:

$$\frac{\partial d_i}{\partial x} = \frac{x - x_i}{\sqrt{(x_i - x)^2 + (y_i - y)^2}}$$



Figura 4.5.1. Escenario de los experimentos del apartado 4.5.1.

У

$$\frac{\partial d_i}{\partial y} = \frac{y - y_i}{\sqrt{(x_i - x)^2 + (y_i - y)^2}}$$

para *i* = 1,2,3.

Para finalizar, hemos de precisar que las medidas de distancia entre un móvil y los nodos fijos de referencia se obtienen mediante alguno de los algoritmos de localización vistos en 4.3 y la consiguiente aplicación de la distancia euclídea.

## 4.5 Experimentos y Resultados

En este capítulo hemos seguido un hilo conductor que nos ha permitido ir recorriendo en un orden lógico las distintas fases que conlleva la tarea de la localización y seguimiento en WSN. Así que una vez comentado el paso previo, la creación de una herramienta de simulación, entramos directamente a estudiar los métodos de localización y alguno de los algoritmos que más nos han interesado. De ahí que nuestro primer apartado en experimentos y resultados, lo dediquemos a la realización de pruebas con un único objeto, comprobar qué podemos esperar de cada uno de esos algoritmos. Seguidamente las pruebas estarán orientadas al uso de esos algoritmos en conjunción con el tipo de información disponible, en nuestro caso los niveles de potencia, concretamente RSSI. Con el conocimiento recogido en estos primeros apartados afrontaremos experimentos con algoritmos más elaborados, estos añaden el seguimiento de las fuentes de señal mediante



Figura 4.5.2. Distancias entre nodos fijos y posiciones del nodo móvil.

Filtrado de Kalman en el que las ecuaciones de medida están basadas en estimaciones de distancia a partir de un algoritmo de localización de nuestra elección.

## 4.5.1. Los Algoritmos de Localización mediante Distancias Conocidas

Como ya hemos comentado anteriormente en esta tesis, nuestro interés, cuando hablamos de localización en el contexto de la WSN, se centra en aquellas metodologías que hacen uso de las medidas de distancia, específicamente las realizadas a través de la medida de la potencia de señal, concretamente RSSI. Los algoritmos presentados en al apartado 4.3.2 usan todos la medida de la distancia para la tarea de localización. Esta medida se efectúa entre una serie de nodos fijos y el nodo móvil, nodo este último del que desconocemos la localización. Es por ello que nuestro primer experimento busca conocer el comportamiento de los algoritmos conocidas directamente las distancias.

En un primer experimento pondremos en juego las distancias exactas entre 4 nodos fijos y un nodo móvil, que adoptara distintas localizaciones. Nuestro escenario será una cuadrícula de  $20 \times 20$  metros cuadrados, en cuyos vértices se sitúan los nodos fijos (círculos de color azul en la Figura 4.5.1), el nodo móvil estará localizado en distintas posiciones todas dentro de la citada cuadrícula (cruces en la Figura 4.5.1) sin que la distancia a ningún nodo fijo sea inferior a un metro. Estas posiciones se han obtenido mediante localizaciones discretas a partir de retículas en XY de 25 x 25 cm. Desde cada uno de los nodos señalados en la Figura 4.5.1 a las distintas posiciones que adopta el nodo móvil, se dan las distancias que aparecen representadas en la Figura 4.5.2. Dada la distribución de las posiciones del nodo móvil, vemos que la dinámica de variación de estas es grande cuando hablamos de los nodos fijos 1 y 4, no así para los nodos 2 y 3.



Figura 4.5.3. Error en la localización para distintos algoritmos con ordenadas en escala lineal (a) y con ordenadas en escala logarítmica (b).

Así las cosas pasamos a indicar las condiciones de este primer experimento en términos de los métodos de localización y error de estimación. Los resultados aparecen en la Figura 4.5.3. Los algoritmos probados han sido los vistos en el apartado 4.3.2, es decir, Multilateralización (*TRI*), Baricentros (*BAR*), RVI y LASM, con estos dos últimos hemos contemplado dos versiones para cada uno. Como estos algoritmos necesitan una inicialización rotulamos mediante RVI+TRI la versión de RVI que se inicializa con Multilateralización y RVI+BAR la que se inicializa con Baricentro. Igualmente para el algoritmo LASM encontraremos LASM+TRI y LASM+BAR. En este primer experimento hemos proporcionado a los algoritmos las distancias exactas desde cada uno de los nodos fijos a las distintas posiciones del nodo móvil. Se trata de ver cuán buenos son localizando en condiciones ideales. El resultado lo podemos ver en la Figura 4.5.3.

La representación muestra el error cometido por cada algoritmo en función de la distancia. Para los valores de distancia se ha tomado como referencia al nodo fijo 1. El cálculo del error se ha realizado siguiendo lo expuesto en la expresión Ec.4.5.1.

$$error = \sqrt{(x - x_e)^2 + (y - y_e)^2}$$
 (Ec.4.5.1)

En dicha expresión (x,y) son las coordenadas reales del nodo móvil y  $(x_e, y_e)$  las estimadas a través del algoritmo de turno. Para una mayor claridad y mejor interpretación de los resultados, en la citada Figura 4.5.3 mostramos el mismo resultado dos veces, pero con una variante, en la Figura 4.5.3(a) los vemos con la



Figura 4.5.4. Error de localización en función de la distancia con variante en algoritmo LASM.

ordenada en escala lineal, mientras que en la Figura 4.5.3(b) los vemos en escala logarítmica. De entre todos los algoritmos el denominado TRI presenta los mejores resultados con un error prácticamente nulo, a continuación tenemos el LASM+TRI, luego RVI+TRI, BAR y LASM+BAR, y por último RVI+BAR. Una primera observación sobre el algoritmo LASM  $\mathbf{es}$ que presenta un comportamiento muy dependiente de la inicialización, no mejorando los datos iniciales. Sin embargo, RVI empeora los obtenidos en su inicialización. Excepto el algoritmo TRI los restantes muestran una tendencia a ser más exactos justo cuando los nodos fijos equidistan lo mismo al nodo móvil (posiciones centrales de la cuadrícula).

El algoritmo LASM contiene una serie de constantes que pueden ajustarse que cambian su comportamiento. Concretamente nos hemos centrado en dos de ellas, una es la constante K relativa a la "rigidez" de la "unión" entre dos nodos (en este caso entre cada uno de los fijos y la posición del nodo móvil). La otra constante, cc (en nuestros programas), regula la importancia que en las sucesivas iteraciones se le da a la aceleración y velocidad, esto es en las ecuaciones que permiten calcular iterativamente velocidad y posición del nodo móvil. Concretando más, los resultados de la Figura 4.5.3 se obtienen con un valor de la constante K = 1 y cc = 0,01, mientras que en los resultados que aparecen en la Figura 4.5.4 los valores de estas constantes fueron: K = 3 y cc = 0,01. Podemos observar los resultados de la Figura 4.5.4 y compararlos con los de la Figura 4.5.3, para ver que el algoritmo LASM+BAR mejora los resultados del algoritmo BAR, reduciendo significativamente el error en las zonas más problemáticas (los bordes). Además, mejora los resultados del algoritmo BAR. Sin embargo, cuando inicializamos con el algoritmo TRI, no mejora los ya inmejorables resultados de este, sino que los empeora significativamente. Hemos probado con otros valores de K obteniendo mejoras en LASM+BAR, a la vez que empeoraba con LASM+TRI, así por ejemplo



Figura 4.5.5. Error de localización para varios algoritmos con 5% de error en las distancias.

en la Figura 4.5.4 vemos los resultados con K = 3 y cc = 0,09.

Naturalmente, en condiciones reales no vamos a disponer de una medición exacta de las distancias, más si cabe en el caso en que estas se obtengan a partir de los valores de RSSI, cuestiones ya comentadas y referenciadas en apartados anteriores. Luego, las medidas de distancia que vayamos a utilizar tendrán un error en su estimación debido a las condiciones de propagación. El error será distinto con respecto a cada uno de los nodos fijos, es decir el error dista mucho de ser sistemático y será claramente de naturaleza aleatoria. En base a esto, el siguiente experimento ha consistido en introducir artificialmente un error aleatorio en la medida de la distancia. Recordamos que esos valores de distancia son los que proporciona la base de su operación a los algoritmos de localización. El error que se introduce estará en cada caso acotado a un porcentaje máximo de error. Podrá ser aditivo (incrementa la distancia medida sobre la real) o sustractivo (valor de distancia medida por debajo de la real). Para cada una de las posiciones que adopte el nodo móvil realizaremos 100 medidas, de los resultados de la totalidad obtendremos un error medio y una desviación estándar.

La Figura 4.5.5 recoge los resultados de este último experimento para un error del 5%. Si tenemos en cuenta que la distancia máxima en juego, Figura 4.5.2, es de unos 28 m, el error que como máximo vamos a introducir será de  $\pm$  1,4 m.

Las representaciones realizadas en Figura 4.5.6, 4.5.7 y 4.5.8 presentan los resultados del experimento, pero con cota de error en el 10%, 20% y 50% respectivamente. Entrando a comentar estos resultados en primer lugar destacan los obtenidos para los algoritmos RVI+TRI y RVI+TRI, que se ven muy afectados por los errores en la determinación de la distancia. Desviaciones que le provocan errores de gran magnitud. Además, estos errores precisamente aparecen con mayor claridad en las zonas donde los algoritmos se mostraban hasta ahora como más exactos y con más precisión. También para estos mismos algoritmos se observa una precisión inaceptable.

Si nos centramos en las gráficas correspondientes a los algoritmos BAR y TRI, destacan dos cosas: para errores por debajo del 20% tenemos mayor exactitud en TRI pero mayor precisión en BAR. Sin embargo, con errores del 50%, mientras BAR mantiene casi inalterada su exactitud y precisión, para el algoritmo TRI se



Figura 4.5.6. Error de localización para varios algoritmos con 10% de error en las distancias.



Figura 4.5.7. Error de localización para varios algoritmos con 20% de error en las distancias.



Figura 4.5.8. Error de localización para varios algoritmos con 50% de error en las distancias.

observa un claro empeoramiento de la exactitud y de la precisión. Luego, aquí el algoritmo BAR destaca por su robustez frente a los errores en la medida de la distancia con una cota de error por debajo de los 5 metros. Prácticamente su exactitud y precisión de mantienen constante en todos los experimentos, Figura 4.5.5 hasta 4.5.8.Por último, el conjunto de algoritmos LASM+TRI y LASM+BAR presentan comportamientos dispares. Claramente, resulta mejor el LASM+BAR. Este algoritmo aunque presenta una exactitud no muy buena, sí que es mejor que la del algoritmo BAR, su cota de error está bien por debajo de los 3 metros. En cuanto a precisión si bien no es superior a la del algoritmo BAR sí que es mejor que la de cualquiera de los otros. Se trata como podemos observar de una opción muy robusta en escenarios donde no conocemos el porcentaje de error en las distancias estimadas y que además puede ser muy variable. Los resultados para el algoritmo LASM+TRI presentan sobre todo una baja precisión y en cuanto a exactitud tampoco mejoran a su inicializador, el algoritmo TRI.

# 4.5.2. Estimación de la Constante de Atenuación

Uno de los pilares de nuestra investigación en lo relativo a los algoritmos de localización es justamente la estimación de esta constante de atenuación de la onda electromagnética (ver Ec.4.3.1), constante que sabemos es desconocida a priori y que es muy dependiente del entorno. Para ello se han ideado una serie de métodos (ver 4.4) con los que tratamos de alcanzar su estimación lo más cercana a su valor real. Hemos de precisar que no ha sido necesario en ningún experimento tener en cuenta las cotas inferior y superior de las constantes de atenuación.

Los experimentos que vamos a presentar seguidamente tratan de mostrar cuál de las metodologías expuestas en el apartado 4.3.3, se acerca más al valor real. Para ello hemos pensado en un escenario muy sencillo con un solo nodo fijo y otro móvil. Este último adoptará posiciones a lo largo de una línea recta que le separa del nodo fijo. Las distintas posiciones que adopta el móvil están separadas 25 cm entre sí. El receptor se encuentra a 2 metros de altura y el móvil a 1,2 metros de altura y las distancias simuladas llegan hasta 100 metros. El nodo móvil toma localizaciones que se aproximan al receptor justo hasta la distancia de 1 metro (en el plano XY) entre ambos. En estas condiciones somos capaces de calcular los valores "reales" que toma la constante de atenuación, seguidamente a partir de las medidas de potencia de señal, RSSI, tratamos de estimar los valores de esta constante de atenuación.

Vamos a seguir dos criterios a la hora de estudiar la calidad en las estimas de la constante de atenuación. En primer lugar, mediante el error de la constante respecto del valor real. Y en segundo lugar, aislando el efecto conjunto de la distancia y la constante. Para el segundo criterio vamos a reescribir la Ec.4.3.2 de la siguiente forma:

$$P_i = K_i + G_t + G_{ri} + L_{it} - 10 \cdot \alpha_i \cdot \log_{10} d_i = R_i - 10 \cdot \alpha_i \cdot \log_{10} d_i$$

donde hemos prescindido del ruido aditivo. Construimos ahora una función para intentar sustraer el término - $10\alpha_i log_{10}(d_i)$  de la siguiente forma:



**Figura 4.5.9.** Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Escenario de un solo rayo reflejado.



**Figura 4.5.10.** Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de primer orden. Escenario de un solo rayo reflejado.

$$P_i = R_i - 10 \cdot \alpha_i \cdot \log_{10} d_i + 10 \cdot \alpha_i^e \cdot \log_{10} d_i$$

con  $\alpha_i$  y  $\alpha^{e_i}$  como las constantes real y estimada, respectivamente. En adelante, las denominaremos 'alfas'. En el caso de propagación en condiciones de campo libre  $\alpha^{e_i}=\alpha_i=2$  y da lugar a  $P_i^F = R_i$  que resulta trivial del conocimiento de la constante. En estos experimentos las distancias  $d_i$  se conocen con exactitud. Por otro lado, en condiciones reales de propagación tenemos:

$$P_i = R_i - 10 \cdot \alpha_i \cdot \log_{10} d_i + 10 \cdot \alpha_i^e \cdot \log_{10} d_i = R_i + \Delta_i^{\alpha}$$

con un término,  $\Delta_i^{\alpha}$ , que denominamos desviación respecto del campo libre. Idealmente este error debe ser cero o, en su defecto, insignificante.

Una vez establecidos los parámetros por los que vamos a evaluar los métodos que hemos presentado en 4.3.3, pasamos a comentar los resultados obtenidos para cada uno de ellos. Haremos una presentación incremental en el sentido de considerar que el número de rayos que interaccionan con el directo va creciendo desde uno hasta tres. Veremos así el comportamiento del algoritmo de estimación de las constantes de atenuación en diferentes situaciones. Fundamentalmente lo que ocurrirá será que los valores reales de la constante de atenuación se volverán más fluctuantes y por tanto más cercanos a situaciones prácticas.

#### • Interacción del Rayo Directo con sólo uno Reflejado

En este caso se producen rayos reflejados en el suelo con un coeficiente de absorción de 0,2. Los resultados si aplicamos el "Método Iterativo de Segundo Orden" (ecuación de *Newton-Raphson*) aparecen en la Figura 4.5.9. Así tenemos en la Figura 4.5.9(a) que los valores estimados de la constante de atenuación,  $\alpha^{e_i}$ , prácticamente son iguales a los reales y sólo se observan levísimas diferencias que pueden resultar algo más destacadas a distancias muy cortas. La Figura 4.5.9(b) nos presenta más claramente el error en la estimación,  $\Delta_i^{\alpha}$  (dB), que presenta unos valores prácticamente nulos. Cualitativamente se aprecia una tendencia generalizada de los valores estimados a ser ligeramente inferiores a los reales.

En la Figura 4.5.10 se observan los resultados si aplicamos el "Método Iterativo de Primer Orden" (también conocido como *Steepest Descent*). Cuando comparamos los valores de la constante de atenuación, Figura 4.5.10(a), se observa que la estimación de los mismos es muy buena para distancias comprendidas entre 10 y 40 m. Sin embargo, tanto por debajo como por encima, las estimaciones dejan de ser buenas. En la Figura 4.5.10(b) podemos observar esto mismo con más claridad. En el susodicho rango de distancias el error en la estimación,  $\Delta_i^{\alpha}$ , alcanza a lo sumo el valor de 1 dB, siendo superior fuera de ese rango de distancias alcanzando valores de hasta 6 dB.

## • Interacción del Rayo Directo con dos Reflejados

Para conseguir esta condición, sólo dos rayos reflejados, hemos introducido un escenario que además del plano que contiene al nodo receptor y al móvil, tiene un plano perpendicular a este (paramento vertical de 10 m de altura). De esta manera y sólo contemplando las reflexiones de primer orden conseguimos lo deseado. Ambas superficies tienen la misma composición con coeficiente de reflexión (0,2). Respecto a las alturas del nodo fijo (receptor) y el nodo móvil, su separación, etc., serán las mismas que en el caso anterior.



Figura 4.5.11. Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Escenario de dos rayos reflejados.



**Figura 4.5.12.** Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de primer orden. Escenario de dos rayos reflejados.

Si observamos los resultados obtenidos para el método de segundo orden, Figura 4.5.11(a) y 4.5.11(b), se deduce que el comportamiento sigue prácticamente inalterado. Y aunque se observan leves oscilaciones de los valores reales de la constante de atenuación, el método de estimación es capaz de seguirlos igualmente. Incluso el error en la estimación  $\Delta_i^{\alpha}$  (dB), Figura 4.5.11(b), disminuye, aunque lo hace mínimamente.

Para el método de primer orden, Figura 4.5.12(a) y 4.5.12(b), los resultados no reflejan variaciones apreciables con respecto al caso anterior de un solo rayo reflejado, tanto el seguimiento en la estimación de los valores de la constante de atenuación, Figura 4.5.12(a), como el error en la estimación, Figura 4.5.12(b), conservan el mismo comportamiento y dinámica de variación. Por tanto, este método sigue presentando peores resultados que el método de segundo orden.



**Figura 4.5.13.** Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Escenario de tres rayos reflejados.



**Figura 4.5.14.** Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de primer orden. Escenario de tres rayos reflejados.

#### • Interacción del Rayo Directo con tres Reflejados

El escenario considerado en este caso consta de tres planos, uno horizontal y dos verticales, ambos de 10 metros de altura. Con esta configuración, especie de pasillo, y si seleccionamos sólo reflexiones de primer orden, podemos conseguir que al nodo fijo (receptor) lleguen tres rayos reflejados: dos rayos procedentes de las paredes laterales (uno de cada una) y otro de plano horizontal. El resto de las constantes del experimento son iguales a las empleadas en los casos anteriores.

En este caso la aportación de los tres rayos reflejados junto con la incidencia directa se manifiestan en el valor de la constante de atenuación real, trazo azul en las Figuras 4.5.13(a) y 4.5.14(a), a través de pequeñas fluctuaciones relativamente rápidas del valor de la misma. Podemos ver que no afectan al método de segundo orden, que es capaz de seguirlas perfectamente, pero si al de



Figura 4.5.15. Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Error del 5% en la distancia.



Figura 4.5.16. Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Error del 10% en la distancia.

primer orden. Esto sobre todo lo podemos ver en las magnitudes y la forma del trazo de las Figuras 4.5.13(b) y 4.5.14(b). Destaca también que el método iterativo de segundo orden presenta una desviación respecto del campo libre,  $\Delta_i^{\alpha}$  (dB), menor que en cualquiera de los otros casos.

# • Influencia del Error en la Distancia sobre la Estimación de la Constante de Atenuación

Sabemos que la estimación de la distancia en nuestro sistema se hará mediante el concurso de las medidas de potencia, RSSI. También hemos comentado y referenciado que estas medidas, por múltiples causas, suelen ser imprecisas. Así que la pregunta que nos hacemos es: ¿Cómo se verá afectada la estimación de la constante de atenuación ante errores en la medida de la distancia?



Figura 4.5.17. Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Error del 20% en la distancia.



**Figura 4.5.18.** Resultados de estimación de alfas (a) y la desviación respecto del campo libre (b) mediante Método iterativo de segundo orden. Error del 50% en la distancia.

Para tratar de calibrar sus consecuencias hemos implementado y llevado a cabo un experimento, consistente en introducir un porcentaje determinado de error sobre la magnitud conocida de la distancia. Para cada medida de distancia hemos repetido la prueba 100 veces, de manera que en cada una de ellas el error como máximo llega al porcentaje establecido. Esto lo hemos realizado para valores de error del 5%, 10%, 20% y 50%. Además, lo haremos sólo para el Método Iterativo de Segundo Orden, toda vez que los resultados obtenidos reflejan un mejor comportamiento del mismo. El escenario considerado ha sido el de tres rayos reflejados.

Los resultados quedan recogidos en Figura 4.5.15, para el 5%, Figura 4.5.16, para el 10%, Figura 4.5.17 para el 20% y Figura 4.5.18 para el 50%. En general, se puede apreciar que para la constante de atenuación, los errores en su estimación



Figura 4.5.19. Error en la localización con distancia estimada mediante medidas RSSI y estimación de la constante de atenuación.

para distancias cortas (por debajo de 10 metros) son mayores que para el resto, de la precisión de esta estimación podemos decir exactamente lo mismo.

Esto sucede así hasta con el 20% de error. Para el 50% las desviaciones son mayores. Así mismo para distancias cortas las desviaciones en los valores de la constante son a partir del 20% de error de gran magnitud. Esto mismo se refleja en los valores del error en la estimación  $\Delta_i^{\alpha}$  (dB) que a partir del 20% adquiere una dinámica de algo más de ± 1dB. Cuando el error considerado es del 20% esa misma magnitud  $\Delta_i^{\alpha}$  (dB) alcanza desviaciones de hasta 6 dB como máximo y por término medio está entre +4 y -2 dB.

# 4.5.3. Algoritmos de Localización Mediante Medidas de Potencia

En el apartado 4.5.1 a partir del conocimiento de la distancia exacta comprobamos el comportamiento de una serie de algoritmos. Seguidamente experimentamos su comportamiento cuando la distancia no era exacta, sino que había errores de distinto calibre que introducíamos artificialmente. Ahora, vamos a comprobar el comportamiento de los algoritmos de interés cuando disponemos sólo de las medidas de potencia, RSSI. Algoritmos donde vamos a incluir la estimación de la constante de atenuación, según se expuso en 4.3.3 y se experimento en 4.5.2.

El escenario considerado ha sido nuevamente el de una retícula de  $20 \times 20$  m<sup>2</sup>, en cuyos vértices se sitúan los nodos fijos, Figura 4.5.1. En cuanto al nodo móvil lo situamos en distintas ubicaciones a lo largo de una diagonal, entre los nodos fijos



**Figura 4.5.20.** Error en la localización para distribución aleatoria del nodo móvil para algoritmo BAR+Alfas (a) y LASM+BAR+Alfas (b).

1 y 4, Figura 4.5.1. Desde cada una las posiciones el nodo móvil transmite con una potencia de -10 dBm. En cada nodo fijo se miden los niveles de potencia recibidos, RSSI, información que junto a la de las posiciones de los nodos fijos se usa en los algoritmos para estimar la localización del nodo móvil.

A partir de los resultados que se muestran en las Figuras 4.5.5 a 4.5.8. Hemos elegido para este experimento los algoritmos Baricentro (BAR) y LASM inicializado con Baricentro (LASM+BAR) donde se incluye la estimación de la constante de atenuación.

Los resultados del experimento se han representado en la Figura 4.5.19. A primera vista se observa que el valor medio de los errores es ligeramente inferior para el algoritmo BAR+Alfa. Si analizamos los errores máximos y mínimos vemos que el mínimo corresponde al LASM+BAR+Alfa, 0,10m por 0,18 para el otro algoritmo. En cuanto a los máximos tenemos que ambos alcanzan los 3,7 m, si despreciamos las centésimas. Al observar cómo se reparten los errores en función de la distancia se puede ver con cierta claridad que estos son menores, por debajo de la media, para distancias cercanas a los 15 m y por encima. Esto último es particularmente cierto para el algoritmo BAR+Alfa. En distancias intermedias, digamos que entre 10 y 15 metros es donde se suceden los errores más significativos. Para distancias inferiores a los 10 metros, los errores se encuentran más agrupados, entorno a los valores medios de error. En esta zona el algoritmo LASM+BAR+Alfa presenta los errores más bajos de entre los dos algoritmos bajo prueba. Es interesante recordar al respecto de esta especie de "zonificación" del error, que las gráficas obtenidas en el apartado 4.5.2 al estudiar la estimación de la constante de atenuación, ya mostraban una mayor variabilidad en las distancias cortas. Sin embargo, para distancias mayores el comportamiento era mucho más estable y su variación bastante más suave.



**Figura 4.5.21.** Escenario de simulación en Versmé Sanatorium (a la izquierda), imagen extraída del simulador LoTrackS-WSN. Ampliación de la zona enmarcada (a la derecha).

Para comprobar el comportamiento con localizaciones distribuidas por distintas posiciones, a lo largo y ancho de la retícula, se ha procedido a realizar una distribución aleatoria de las posiciones, Figura 4.5.20. En la misma observamos las posiciones reales (círculos) y las estimadas (cruces) por el algoritmo considerado, unidas por un segmento cuya magnitud refleja el error cometido por la estimación. Una apreciación que podemos hacer tanto sobre la Figura 4.5.20(a) como sobre la Figura 4.5.20(b), es que los errores no obedecen a una zona o zonas determinadas, su distribución no sigue en este sentido patrón alguno. A simple vista es fácilmente observable que los segmentos de error en la Figura 4.5.20(a), para el algoritmo BAR+Alfa, son de inferior magnitud al compararlos con los de la Figura 4.5.20(b) que corresponden a las estimaciones realizadas con el algoritmo LASM+BAR+Alfa. Un aspecto a destacar es la tendencia o dirección del segmento de error. En este sentido se puede observar que siempre que tenemos un nodo cercano y dominante, el segmento de error toma dirección hacia ese nodo. Sin embargo, para las posiciones más centradas no parece existir una tendencia determinada. Este aspecto, aunque en distinta magnitud se manifiesta para ambos algoritmos.

### • Simulación de un Escenario Real para Localización mediante Medida de Niveles de Potencia (RSSI)

El siguiente paso en nuestros experimentos será abordar una situación más cercana a condiciones reales a través del uso de nuestro simulador, "*LoTrackS-WSN*". Para ello hemos cargado en el simulador el escenario correspondiente al exterior del Versmé Sanatorium situado en la localidad de Biřstonas (Lituania), lugar elegido para las pruebas de campo del proyecto de investigación FP6-2005-IST-034642.

En el citado escenario, Figura 4.5.21, y a lo largo de un paseo ajardinado se han distribuido un total de 13 nodos fijos (círculos de color azul verdoso, cian) y 9 nodos móviles (cruces blancas). La altura de los nodos fijos era de 2,5 m y la de los móviles de 0,5 m. Tal y como se puede ver en la Figura 4.5.21 la distancia que los separa es variable, lo que obedece a las posibilidades que nos ofrece el citado escenario, en lo que a la instalación se refiere. Estas distancias van desde 13 a 26 metros, para nodos fijos adyacentes. Las distancias entre nodos fijos enfrentados van desde 13 m a 41 metros. En la distribución se pueden observar dos zonas bien diferenciadas: una es la ubicada más a la izquierda, especie de rotonda (fuente), donde la geometría de la distribución y la separación entre los nodos fijos es más irregular. En la otra zona los nodos fijos se sitúan en los márgenes de un paseo, lo que resulta en una distribución algo más regular. En cualquier caso, se puede observar que no disponemos de ninguna retícula perfectamente rectangular para conjuntos de cuatro nodos, condiciones con las que habíamos experimentado hasta ahora.

Según los experimentos realizados a partir de aquí vamos a trabajar con un sólo algoritmo, BAR+Alfa. Un aspecto importante es que al igual que hemos venido haciendo hasta ahora en la estimación participan sólo cuatro nodos fijos. En este experimento la elección se hace tomando los cuatro nodos fijos de mayor nivel de potencia (RSSI) recibida. Los resultados de este primer experimento los podemos ver en la Figura 4.5.21, donde las posiciones estimadas aparecen señaladas mediante cuadrados de color amarillo. La mayoría de las estimaciones están muy cercanas a las localizaciones reales, aunque no son exactas. Con más detalle en la Figura 4.5.22, tenemos una copia de la ventana desde la que el simulador nos informa de los errores cometidos en la estimación. Hemos querido recoger en la misma los errores según la coordenada, X o Y, así como su valor RMSE.

Observamos que el valor RMSE con respecto a experimentos anteriores ha subido y que el valor de error más alto se obtiene para posición 8, "event" en la figura, (marco rojo en Figura 4.5.22). En general los errores según las coordenadas no tienen una relación recíproca, salvo para las posiciones 1 y 6. Esto entendemos se debe a la geometría variable de las distintas retículas que se van formando según la localización del nodo móvil considerada. La Figura 4.5.23 muestra otra ventana emergente de nuestro simulador, en esta además de información relativa a los niveles de potencia, se nos proporciona información acerca de los nodos fijos que intervienen en la estimación para cada localización. Esta última información resulta de bastante interés. Con ella podemos vislumbrar las posibles causas del incremento en los errores de la estimación. En el caso concreto de la posición 8 intervienen y por este orden los nodos fijos 11, 3, 10 y 2. Este conjunto de nodos forman un polígono irregular, donde el nodo 2 se encuentra bastante alejado de los otros, también en menor cuantía los está el nodo 11 respecto del 10 y el 3 que son los más cercanos entre sí.

En la Figura 4.5.24 tenemos una segunda parte del experimento presentado en Figura 4.5.21, 4.5.22 y 4.5.23. Ahora las localizaciones elegidas están alrededor de la fuente, aquí se observa una distribución de nodos distintas a la anteriores, polígono de 5 vértices. Si prestamos atención detenida a los resultados que aparecen ampliados en la imagen derecha de la Figura 4.5.24, vemos que excepto
Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores







Figura 4.5.23. Ventana emergente del simulador con información relativa a las potencias recibidas y a los grupos de sensores intervinientes en la estimación.

una de las localizaciones reales (cruces blancas) todas tienen más o menos cerca la estimación (cuadrado de color amarillo). Justamente para esa posición tenemos en la Figura 4.5.25 el mayor de los errores. Si atendemos a la Figura 4.5.26 12, 11, 3 y 10, en ese orden. La posición de esos sensores fijos vemos no conforman una retícula al uso, rectangular, cuadrada o similar, sino más bien triangular. Además, podemos decir que tres de los nodos fijos son colineales (12, 11 y 10). Para el resto de las posiciones los errores están por debajo del valor RMSE. Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



Figura 4.5.24. Escenario de simulación en Versmé Sanatorium (a la izquierda), imagen extraída del simualdor LoTrackS-WSN. Ampliación de la zona enmarcada (a la derecha). Experimento con nodos móviles alrededor de la fuente.



Figura 4.5.25. Errores en la estimación para el experimento de la Figura 4.5.24.



Figura 4.5.26. Nodos fijos que colaboran para cada evento Figura 4.5.24.



Figura 4.5.27. Geometría del despliegue de una WSN de 4 nodos fijos y un nodo móvil (vista real perspectiva).



Figura 4.5.28. Zona donde se realizo el despliegue de la Figura 4.5.27 con ubicación de nodos fijos y nodo móvil ubicado en trípode.

Aunque en menor magnitud también merece una mención especial lo que sucede con la posición 2 del nodo móvil. Aquí tenemos el segundo error en importancia para este experimento. El conjunto de nodos fijos que colaboran en su localización son 2, 1, 13 y 3. Nuevamente nos encontramos con que los nodos fijos 1,2 y 3 están claramente alineados, la forma de la retícula resultante prácticamente es un triángulo rectángulo. Además, la distancia que separa al nodo 3 del 13 alcanza los 41 m y desde el nodo 1 al nodo 3 tenemos 37 m. Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



(a)

(b)



**Figura 4.5.29.** Detalles de instalación del nodo móvil (a), nodos fijos en verjas de las ventanas (b) y (c), y nodo fijo sobre poste de alumbrado (d).

# • Localización mediante Medida de Niveles de Potencia (RSSI) en una WSN Desplegada en Ambiente Externo

Como último experimento en este apartado vamos a presentar uno en el que disponemos de niveles RSSI medidos en una situación real. Para ello en los exteriores del edificio del departamento de Señales y Comunicaciones de la Universidad de Las Palmas de Gran Canaria, Figura 4.5.27, realizamos el despliegue presentado en la Figura 4.5.28. Situamos cuatro nodos fijos, un nodo



Figura 4.5.30. Localizaciones elegidas para las posiciones del nodo móvil en el escenario de la Figura 4.5.28.

móvil, y un nodo que actúa de recolector de datos, "sink". Dos de los nodos fijos se sujetaron en las verjas de los ventanales del edificio, Figura 4.5.29(b) y 4.5.29(c) respectivamente. Los otros dos nodos fijos se instalaron en unos postes de alumbrado, Figura 4.5.29(d).Los nodos fijos se situaron a 2,5 metros de altura, mientras que el nodo móvil estaba a 0,5 m y montado sobre un trípode, Figura 4.5.29(a). El resto de la red se completaba con un quinto nodo que actuaba de "sink" dentro de la red. Esta mota iba directamente conectada a un ordenador personal que actuaba de Gateway de la red, vía puerto USB. A través de este PC se encaminaban los datos relativos a cada mota, nodos de la red, para ser tratados en el "Web server" de nuestra particular WSN.

Entre los distintos datos transmitidos estaban los de nuestro interés, valores RSSI. En la programación de la red se dispuso un servicio de grabación en archivo de los niveles que se iban recibiendo en cada uno de los nodos fijos, mientras el nodo móvil transmitía desde su localización.

Dentro del despliegue considerado en la Figura 4.5.30 tenemos la identificación (A, B, C y D) y la localización de cada nodo fijo. También se indican en la misma figura las localizaciones del nodo móvil. Así mismo, para complementar e incluso valorar con algo más de precisión los resultados que veremos seguidamente se ha reflejado en la Figura 4.5.30 el diagrama de directividad para cada nodo. Los nodos fijos B y C son los instalados en las farolas, Figura 4.5.29, mientras que los nodos A y D lo fueron en las verjas de las ventanas, Figura 4.5.30.



Figura 4.5.31. Resultados de las estimaciones para el escenario de la Figura 4.5.30.



Figura 4.5.32. Error y desviación en función de la separación entre posición real y estimada para el escenario de la Figura 4.5.30.

Como paso previo y final al despliegue se realizo una comprobación de las baterías incorporadas en cada nodo tanto fijo como móvil, encontrándose que todas se presentaban valores que hallaban dentro de la tolerancia. El proceso seguido ha sido situar el nodo móvil, Figura 4.5.29(a) en cada posición señalada desde la 1 a la 7 en la Figura 4.5.30. El móvil se mantenía allí durante unos 10 minutos. Cuando concluía el periodo de estancia en esa posición, previamente se paraba el sistema de adquisición de datos RSSI. Entonces, se cambiaba de posición y se volvía a arrancar el sistema de adquisición. Se realizaron 300 medidas por posición. Una vez terminado el proceso se extrajo la información de las RSSI junto con a su correspondencia con los nodos fijos. Con la información ordenada de esta manera se aplico nuestro algoritmo BAR+Alfa. El resultado lo podemos contemplar desde varios puntos de vista en la Figura 4.5.31 y 4.5.32.

La Figura 4.5.31 representa los resultados en el escenario previamente presentado en la Figura 4.5.30. En ella podemos ver los nodos fijos (cuadrados azules), las posiciones reales del nodo móvil a localizar (estrellas verdes) y la estimada como resultado de tomar el valor medio de cada una por cada coordenada (círculos rojos). Aclaramos esto último, la coordenada Y de esta localización se calcula como el valor medio de los valores que toma la coordenada Y en el total de estimaciones. Igualmente para la coordenada X de la posición estimada. Se completa la representación incluyendo para cada estimación los márgenes de excursión en X y Y (trazos y flechas de color negro) y un segmento azul que une posición estimada y posición real. En la Figura 4.5.32, presentamos otra visión de la exactitud y precisión de las estimaciones realizadas con nuestro algoritmo. Aquí vemos el error en función de la distancia que separa a cada una de las posiciones especificadas en la Figura 4.5.30.

Observando ambas figuras, Figura 4.5.31 y 4.5.32, vemos que el error en la estimación está por debajo del metro, por lo que el algoritmo sin ser exacto presenta unos resultados aceptables, mejorando incluso las expectativas en base a experimentos anteriores. En cuanto a las desviaciones cuantificadas por cada coordenada, se observa cierta desigualdad entre sus excursiones. Sobre todo destaca las ocurridas en posiciones como la 1, 6 y 7. Estas posiciones comparten el hecho de estar cerca de la frontera o en la misma frontera de la cuadrícula, presentando una excursión en los valores estimados para la coordenada Y muy superiores a los estimados para la dimensión X. Sin embargo, aquellas posiciones más centradas nos muestran dinámicas algo más parecidas, sin tanto sesgo. En cualquier caso los errores de exactitud se encuentran todos por debajo del metro. Figura 4.5.32, y la precisión también es aceptable. Para las localizaciones evaluadas la que presenta más exactitud es la 3, error por debajo de los 0,5 metros, las que menos son la 1 y la 6. Respecto a la precisión la observamos bastante buena en la posición 2 y peor para la posición 6. A grandes rasgos y considerando que las dimensiones de nuestra retícula son de  $22 \times 9.2$  m<sup>2</sup> y la diagonal alcanza los 24 m, los errores cuantificados en la Figura 4.5.32, están por debajo del 10% de cualquiera de las dimensiones mencionadas, en lo que a la exactitud concierne. También la dinámica de ese error, que nos da la precisión, se encuentra prácticamente por debajo de ese 10%.

## 4.5.4. Algoritmo de Seguimiento

En el apartado 4.4 de este capítulo, concretamente en 4.4.3 presentamos las líneas maestra de un algoritmo de seguimiento basado en EKF y alimentado por medidas periódicas de la distancia estimada entre el nodo móvil y los nodos tomados como referencia. En este apartado vamos a presentar la serie de experimentos realizados y los resultados obtenidos.



Figura 4.5.33. Móvil en trayectoria cuasi circular y estimaciones de la misma.



Figura 4.5.34. Error en función de la distancia a la localización real.

El primer experimento realizado ha sido un supuesto donde una fuente móvil (nodo móvil) se movía a una velocidad de 1 m/s, esta fuente sigue una trayectoria casi circular dentro de una cuadrícula de 30×30 m<sup>2</sup>. Los nodos fijos, al igual que en experimentos anteriores están situados en los vértices de la cuadrícula. El algoritmo de seguimiento tiene un paso previo de medidas de distancia realizado mediante el algoritmo BAR+Alfa (Baricentro en las figuras), luego estas medidas se tratan mediante un algoritmo EKF (Kalman en las figuras). Por último, indicar que en el escenario considerado no había más superficie que el suelo, es decir, sólo son posibles modos de propagación directo y una única reflexión en el suelo.



Figura 4.5.35. Escenario, trayectorias real y estimada, y distribución de nodos fijos, para el experimento de trayecto "corto".

El resultado de este primer experimento lo podemos contemplar de dos formas. Una primera en la Figura 4.5.33, donde es posible observar la trayectoria real del nodo móvil, la obtenida uniendo simplemente las localizaciones estimadas mediante BAR+Alfa (Baricentro) y otra más calculada mediante un algoritmo EKF (Kalman), esta última usa las estimas del algoritmo BAR+Alfa relativas a distancias entre nodos fijos y nodo móvil. A simple vista se puede ver que la trayectoria de color azul (Kalman) presenta una mejor aproximación a la trayectoria real. Además, en general se trata de una trayectoria más regular, sin tantas fluctuaciones, o cambios de dirección, como la trayectoria de color rojo (Baricentro). La segunda forma en que podemos ver estos resultados, Figura 4.5.34, nos muestra el error cometido por cada posición estimada mediante cada uno de los algoritmos usados. La tendencia en el trazo azul (Kalman) es a seguir al trazo rojo, amortiguando y corriendo a este en base a que el algoritmo va determinando el camino "más lógico". Esto lo hace en función de la estimación del desplazamiento y la velocidad según cada coordenada. De esta manera se ve que corrige sobre todo los errores cometidos en las posiciones donde se gira para cambiar de dirección o sentido.

#### • Simulación de un Escenario Real para Seguimiento mediante Medida de Niveles de Potencia (RSSI)

El escenario elegido para los dos experimentos que vamos a presentar a continuación es nuevamente el Versmé Sanatorium situado en la localidad de Biřstonas (Lituania). Ahora simulamos dos trayectorias discretas, una "corta" y otra "larga", ambas serían las seguidas por una persona a una velocidad aproximada de 1 m/s.

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



Figura 4.5.36. Errores en la estimación del trayecto "corto".



Figura 4.5.37. Distribución de niveles y grupos de 4 sensores que actúan para cada posición para el experimento del trayecto"corto".

La trayectoria "corta", trazo azul en la Figura 4.5.35, es casi una línea recta entre las dos primeras retículas de la derecha. La trayectoria "larga" (trazo azul de Figura 4.5.38), además de ser un recorrido de mayor longitud, tiene cambios de dirección e incluso cambios de sentido.

En estos experimentos, hemos supuesto que el nodo móvil va junto con la persona, p.ej. en su bolsillo o sujeto a la rodilla, a una altura de 0,5 m sobre él suelo. Los nodos fijos están a 2,5 m de altura. Las ubicaciones de estos nodos fijos

Cap.4 – Agrupaciones Distribuidas de Sensores. Nuevos algoritmos de Localización, Seguimiento e Identificación con Agrupaciones de Sensores



Figura 4.5.38. Escenario, trayectorias real y estimada, y distribución de nodos fijos, para el experimento de trayecto "largo".



Figura 4.5.39. Errores en la estimación del trayecto "corto".



Figura 4.5.40. Errores en la estimación del trayecto "corto".

(círculos de color cian), la trayectoria real (trazo azul), la trayectoria estimada (trazo amarillo) aparecen todos en la Figura 4.5.35 y 4.5.38, ambas son capturas de parte de la interface de nuestro simulador LoTrackS-WSN.

A simple vista la trayectoria estimada en la Figura 4.5.35 (trazo amarillo) parece seguir, aunque con ciertas desviaciones, la dirección y las posiciones del nodo

móvil. Por ejemplo, destaca claramente el trazo amarillo (trayectoria estimada) empieza algo desplazada respecto al trazo azul (trayectoria real).

En la Figura 4.5.36 tenemos el error cometido, de manera separada para cada una de las coordenadas y conjunta mediante valor RMSE. En promedio, valor RMSE (trazo negro en Figura 4.5.36) los errores están por debajo de los 2,5 m. Destaca que los errores no son iguales para la coordenada Y (menores) que la para la X,(mayores), ni en el trazo ni en la magnitud, no hay una correlación entre ellos. Además, sobresale que las posiciones por encima del índice "event" 40 y algo por debajo de 90 la aparición de unas transiciones algo abruptas. Un aumento súbito del error acompañando de una reducción también algo repentina del mismo. Si estudiamos con detenimiento la Figura 4.5.37 justo para esas posiciones observamos que ocurre ese incremento del error cuando entra un nuevo sensor en el grupo de 4. Esto conlleva a que la geometría resultante del polígono cuyos vértices son los cuatro nodos fijos, no sea un cuadrilátero, sino que se aproxima más a un triángulo.

Armados con lo visto en los resultados del experimento anterior podremos comprender y analizar mejor los que presentamos en Figura 4.5.38, 4.5.39 y 4.5.40, relativos al experimento del trayecto "largo".

La trayectoria estimada que podemos observar en la Figura 4.5.38 (trazo amarillo) aunque sigue bien a la trayectoria real, hemos de mencionar que en la zona de la fuente presenta bastantes irregularidades. Nuevamente los cambios en el grupo de sensores participantes en la estimación producen incrementos bruscos de los errores. Los errores de mayor magnitud aparecen justo en la zona de la fuente, donde las transiciones son mayores. En este último experimento el valor promedio del error está sobre los 2,6 metros. Error que está levemente por encima del alcanzado en el experimento anterior.

# CAPÍTULO 5

# **Conclusiones y Líneas Futuras**

Los experimentos llevados a cabo y expuestos en los capítulos 3 y 4 nos han proporcionado una serie de resultados, que a la vez que han permitido evaluar nuestras aportaciones, nos han proporcionado observaciones que enriquecen el conocimiento sobre los temas tratados y, por tanto, conllevan conclusiones de interés. Entendemos que estas conclusiones sirven de apoyo no sólo a nuestras aportaciones, sino también a futuros trabajos a desarrollar en este mismo ámbito, o en otros que necesiten de este conocimiento previo.

Así mismo, recogemos una serie de líneas futuras que quedan abiertas tras la consecución de esta tesis. Se abren así unos frentes que desde ya suponen para nosotros una tarea cuya planificación está fundamentada en las distintas herramientas algorítmicas a que ha dado lugar esta tesis.

# 5.1 Conclusiones

Para contextualizar adecuadamente cada una de las conclusiones que vamos a exponer, hemos estructurado las mismas en función del ámbito de cada uno de los experimentos realizados en el conjunto de la tesis.

## 5.1.1. Nuevos Algoritmos Aplicados en Agrupaciones Concentradas

#### • Modelado AR y ARMA de Clics de Cachalotes

Los resultados recogidos en 3.6.1 refrendan lo adecuado de aplicar modelado AR y ARMA a los clics de cachalotes. Además, el valor MSE alcanzado es bastante menor con modelado ARMA, polos y ceros de la función de transferencia, que sólo con modelado AR (polos de la función de transferencia). El método TSLS es el más adecuado (valores MSE un orden de magnitud por debajo de MYWE) para modelar clics de cachalotes. El citado método realiza el proceso en dos etapas: una primera donde estima la señal de excitación y una segunda donde se usa esta para generar el proceso al completo. Esta forma de hacer las cosas nos permite estimar como es el proceso que tiene lugar originariamente en la cabeza del cachalote. Algo muy semejante a uno donde a partir de un pulso de gran ancho de banda, que se transmite a través de un conjunto de elementos (función de transferencia) antes de su emisión al medio marino.

A continuación pasamos a listar algunas conclusiones más puntuales sobre los resultados expuestos en 3.6.1.

- 1. En el modelado ARMA el orden AR influye más drásticamente en la disminución del MSE, que el orden MA.
- 2. El método TSLS es con el que se obtienen mejores resultados con órdenes AR y MA parejos.
- 3. El método MYWE no modela adecuadamente la parte MA de los procesos ARMA.
- 4. El ajuste a las resonancias y valles presentes en el espectro de un clic se ajusta significativamente mejor cuando usamos el método TSLS. Destacando el ajuste de ese método a los valles del espectro.
- 5. No todos los clics de la base de datos se modelan con igual precisión, hay algunos que se prestan mejor que otros, pero en cualquier caso la magnitud del MSE siempre está más baja con TSLS que con MYWE

#### • Algoritmos de Estimación DOA Específico de Fuentes AR y ARMA

Aquí hemos de distinguir dos grupos de conclusiones: una primera relativa a un escenario con una sola fuente de señal y una segunda donde intervienen dos fuentes de señal.

#### <u>Una fuente</u>

Los resultados en los que nos vamos a apoyar para las conclusiones que vertemos a continuación, están reunidos en el apartado 3.6.2.

 Todos los métodos analizados presentan una clara perdida de exactitud y precisión a partir de direcciones de incidencia por encima de los 60°. También los algoritmos específicos de fuente con modelos AR(2) y ARMA(2,1). La excepción a este resultado está en el método STMV.

- 2. El incremento del orden de los modelos empleados revela que un algoritmo específico de fuente como es el ARMAExtFast prácticamente ajusta los resultados del STMV en exactitud, aunque no en precisión.
- 3. Frente a señales con baja SNR, la precisión y exactitud de los métodos específicos de fuente, como p.e. el ARMAExtFast, superan claramente a los obtenidos por el STMV.
- 4. La carga computacional del algoritmo ARMAExtFast es ligeramente superior a la necesaria con el algoritmo STMV. Este ligero incremento se mantiene sin un aumento significativo aún empleando órdenes elevados en modelado.

Como síntesis de estas conclusiones parciales, se puede aseverar que el algoritmo ARMAExtFast presenta mejores prestaciones que el STMV, cuando el tipo de fuente es específica, en nuestro caso clics de cachalotes. Su mejor comportamiento frente a valores SNR por debajo de 0 dB es definitivo toda vez que son algoritmos de aplicación en medios donde el ruido es bastante elevado. Recordamos que al ruido cambiante del medio, p.e. según condiciones de viento, hay que sumar el generado por las plataformas donde van instalados estos sistemas, en general barcos en movimiento.

#### **Dos Fuentes**

En el apartado 3.6.3 se desgranan una serie resultados correspondientes a otros tantos experimentos. Ahora nuestros escenarios incluyen dos fuentes. Una cuestión a recordar es que ya sólo hacemos comparaciones con los algoritmos STMV, ARMAPol, ARExtFast y ARMAExtFast. Además, las agrupaciones concentradas utilizadas son distintas, únicamente en el número de sensores empleados. Dos sensores para ARMAPol, ARExtFast y ARMAExtFast y ARMAExtFast y Cuatro para STMV.

Una primera conclusión directa del párrafo anterior es precisamente el que nuestros algoritmos ARExtFast y ARMAExtFast pueden trabajar con un reducido número de sensores, y en el caso del ARMAExtFast con prestaciones superiores, en su ámbito frente, al STMV.

Pasamos a continuación a enumerar aquellas conclusiones parciales que emanan de nuestros experimentos.

- 1. Los algoritmos ARMAPol y STMV no son capaces, por si solos, de identificar a cada una de las fuentes. Por tanto ninguno de ellos asigna correctamente las DOAs.
- 2. Nuestros algoritmos ARExtFast y ARMAExtFast, de manera intrínseca, si son capaces de asignar correctamente la DOA estimada a la fuente adecuada. Aunque su exactitud presenta un sesgo casi sistemático.
- 3. Los algoritmos ARExtFast y ARMAExtFast conservan la precisión y la exactitud hasta valores de SNR de 0 dB, sin que esto suponga una merma en su capacidad para asignar correctamente DOA estimada a la fuente.
- 4. La mayor o menor separación entre las fuentes, no mejora ni empeora la exactitud y precisión de los algoritmos ARExtFast y ARMAExtFast. No

ocurre lo mismo para los algoritmos STMV y ARMAPol, básicamente debido a la imposibilidad que tienen para asignar de manera intrínseca DOA y fuente, adecuadamente.

- 5. Al incrementar el orden del modelado AR y ARMA incluido en los algoritmos ARMAPol, ARExtFast y ARMAExtFast. Se producen leves mejoras en la exactitud de ARExtFast y ARMAExtFast, pero no para ARMAPol que se muestra insensible a ello.
- 6. Las prestaciones de los algoritmos ARExtFast y ARMAExtFast cuando las fuentes no son de igual amplitud no se ven afectadas, para diferencias de hasta 10 dB entre ellas.
- 7. El algoritmo ARMAPol presenta mejores resultados conforme se incrementa la diferencia entre las fuentes.

Las conclusiones parciales anteriores nos llevan a expresar que los algoritmos específicos de fuente, en concreto ARExtFast y ARMAExtFast, globalmente ofrecen mejores prestaciones en escenarios con dos fuentes, prácticamente para cualquier disposición de las fuentes en cuanto a separación, amplitudes relativas y DOA. Estos algoritmos una vez "enganchados" a la fuente deseada no necesitan de ningún proceso adicional para discernir entre una u otra fuente Además, compensan su no tan buena exactitud con una precisión que se mantiene incluso para niveles de SNR de hasta 0 dB.

#### • Algoritmo de Identificación

Este algoritmo presenta una serie de propiedades que lo hacen de gran utilidad para las tareas en el ámbito de esta tesis. La constatación de que esas expectativas se confirman se encuentra en el apartado 3.6.4, donde hemos expuesto los resultados de las pruebas a las que lo hemos sometido. Antes de pasar a exponer las conclusiones, hemos de recordar que la base de datos empleada tiene "dos versiones". Una donde los clics están agrupados y otra donde son considerados unidades individuales. Se trata del mismo conjunto de clics, lo que sucede es que en el caso del agrupamiento hemos formado conjuntos con aquellos clics que presentan entre si un parecido elevado, medido en términos del valor normalizado de la correlación cruzada.

- 1. En un escenario con una sola fuente, incidiendo ésta desde distintas direcciones, las probabilidades de acierto de nuestro algoritmo de identificación (admitiendo agrupamiento) están prácticamente por encima del 98% para DOAs por debajo de 60° y alcanzan el 95% para DOAs próximas al endfire. Sin agrupamiento los resultados bajan hasta el 92% para el endfire.
- 2. Para SNR bajas con agrupamiento se obtienen muy buenos resultados prácticamente todos por encima del 98% de aciertos para todas las direcciones. Sin agrupamiento los resultados bajan hasta niveles de acierto del 74% como valor más bajo.
- 3. Al considerar un escenario con dos fuentes en general los resultados son peores cuando las fuentes están muy próximas, angularmente hablando.

Siguen siendo mejores cuando se considera agrupamiento que cuando no. También se notan diferencias importantes cuando los niveles de SNR se encuentran entre 5 y 10 dB, circunstancias para las cuáles baja significativamente la probabilidad de acierto.

4. El algoritmo de identificación se presenta robusto frente a errores en la estimación de la DOA, mejor si se considera agrupamiento, sobre todo para señales de SNR por debajo de los 10 dB.

En resumen, nuestro algoritmo de identificación presenta sus mejores resultados siempre y cuando se realice un agrupamiento previo, de las señales de la base de datos utilizada para identificar. Es robusto frente a errores en la estimación de la DOA. Pierde prestaciones cuando las SNR caen por debajo de los 10 dB y mejora sus probabilidades de acierto cuanto mayor sea la separación entre fuentes.

#### • Algoritmo Conjunto de Localización, Identificación y Seguimiento

Como ya se ha expuesto en el apartado 3.5.5 y experimentado en 3.6.5 este algoritmo supone un compendio de los algoritmos estudiados previamente. Básicamente, integramos aquí los algoritmos de modelado, localización angular e identificación, a los que se une el Filtrado de Kalman convenientemente adaptado para la aplicación. Para estos experimentos ha sido imprescindible el concurso de Cetus3D, nuestra herramienta de simulación acústica submarina. Además, llegados a este punto y fundados en los resultados y conclusiones previas, de entre todos los algoritmos de DOA hemos usado sólo ARMAExtFast.

- 1. Sin una herramienta se simulación como Cetus3D o de iguales prestaciones, hubiera sido imposible realizar el estudio de un algoritmo de estas características.
- 2. Una agrupación de sensores desplegada en una única dirección es menos útil que cuando se usan varias direcciones. En cualquier caso siempre será preferible un despliegue vertical de la misma.
- 3. Sólo mediante el concurso de una agrupación, vertical (normal a la superficie) será posible diferenciar modo directo de modo superficial de propagación.
- 4. La aplicación del Filtrado de Kalman, en promedio mejora los resultados. Las mejoras las introduce sobre todo para ángulos de incidencia próximos al endfire pues en el broadside las localizaciones ya son buenas de por sí.
- 5. En el entorno elegido para nuestras simulaciones con agrupación vertical, el modo de propagación a través del fondo tendrá ángulos de incidencia entorno al endfire, si la superficie del fondo es paralela o cuasi paralela a la superficie. Sin embargo, cuando la superficie sea irregular o presente pendientes elevadas los ángulos de incidencia presentarán una gran variación. Esto se traduce en un incremento en el error cometido en la estimación DOA, error que se corrige con el Filtrado de Kalman, al menos para los valores más elevados del mismo. Este tipo de entorno es típico en el hábitat de los cachalotes, ya que varias de sus presas favoritas, p.e. el calamar gigante, gustan de vivir en fondos de este tipo.

Como conclusión general se puede decir que el algoritmo conjunto demuestra estimar con gran exactitud y precisión las trayectorias según los modos de propagación directo y por reflexión en la superficie, siempre y cuando los ángulos de incidencia estén comprendidos entre  $60^{\circ}$  y  $- 60^{\circ}$ . Cuando se añade Filtrado de Kalman este rango se extiende al rango que va de  $70^{\circ}$  a  $-70^{\circ}$ .

## 5.1.2. Nuevos Algoritmos de Aplicación en Agrupaciones Distribuidas

#### • Algoritmos de Localización y Distancias Conocidas

En el apartado 4.5.1 hemos comprobado las prestaciones de una serie de algoritmos que hacen localización mediante la medida de la distancia al objeto a localizar, estos son: Multilateralización (*TRI*), Baricentros (*BAR*), RVI y LASM. Directamente de los resultados que obtuvimos podemos establecer lo siguiente:

- 1. El algoritmo de Multilateralización en condiciones ideales, es decir distancia exacta conocida, es el que presenta mejores resultados, tanto en exactitud como en precisión. Este resultado se mantiene hasta con errores del 10% en lo que a la exactitud se refiere.
- 2. El algoritmo Baricentros si bien no es tan exacto como Multilateralización, si se le puede considerar más robusto que este, ya que su precisión y su grado de exactitud permanecen prácticamente inalterados hasta con valores de distancia erróneos en un 50%.
- 3. Los algoritmos LASM y RVI son altamente dependientes del algoritmo de inicialización. Sin embargo, el algoritmo LASM dispone de unos parámetros de ajuste, que en ciertas condiciones pueden mejorar los resultados de su algoritmo de inicialización, sólo si este es el algoritmo Baricentros.
- 4. El algoritmo RVI se nos muestra extremadamente sensible a errores en el valor de la distancia.

#### • Estimación de la Constante de Atenuación

En el modelo de propagación que hemos elegido uno de los parámetros del que a priori no se tiene un conocimiento lo suficientemente exacto es la constante de atenuación. En el apartado 4.4 hemos propuesto una serie de métodos para su estima, mientras que en el apartado 4.5.2 hemos experimentado con ellas, llegando a las siguientes conclusiones:

- 1. El método de estimación que hemos denominado Método Iterativo de Segundo Orden presenta error ínfimo en la estimación de la constante de atenuación. El error cometido al estimar mediante el Método Iterativo de Primer Orden es varios órdenes de magnitud superior.
- 2. El error cometido por el Método Iterativo de Segundo Orden, aunque ínfimo, presenta una mayor magnitud para distancias cortas,

mejorando ostensiblemente para distancias grandes por encima de los 50 metros.

- 3. Las estimaciones alcanzadas con el Método Iterativo de Segundo Orden no pierden ni exactitud ni precisión al someterlo a escenarios con más de un modo de propagación, es decir modo directo y modos por reflexión.
- 4. Cuando las distancias empleadas en la estimación de la constante de atenuación presentan desviaciones sobre las reales de hasta el 20%. Las estimaciones realizadas con el Método Iterativo de Segundo Orden alcanzan derivas de  $\pm$  1dB sobre los valores reales.

Compendiando las conclusiones puntuales anteriores el Método Iterativo de Segundo Orden no es sólo más exacto y preciso sino que además se presenta como muy robusto frente a errores en los datos de partida.

#### • Algoritmos de Localización Mediante Medidas de Potencia

En un escenario real en general no es factible disponer de una medida de la distancia, salvo que se utilice un sistema auxiliar, p.e., radar o sonar. En nuestro caso no disponemos de ninguno de esos sistemas incorporados en los nodos fijos de la WSN. Únicamente disponemos de la medida de potencia recibida, RSSI.

En el apartado 4.5.3 hemos probado las prestaciones de nuestros algoritmos de localización, teniendo en cuenta que ahora estimamos la distancia en base a las medidas RSSI disponibles en los nodos. Además, en estos algoritmos hemos incorporado la estimación de la constante de atenuación mediante el Método Iterativo de Segundo Orden. La lectura directa de los resultados nos conduce a las siguientes conclusiones:

- 1. El algoritmo Baricentros con estimación de las constantes de atenuación, que hemos denominado también como "alfas" (BAR+Alfas) presenta una cota media de error inferior al algoritmo LASM inicializado con Baricentros y con estimación de alfas (LASM+BAR+Alfa).
- 2. El reparto espacial de los errores en el algoritmo BAR+Alfas, si los nodos fijos forman un cuadrilátero, es desigual. Los errores son mayores en el centro del cuadrilátero. En aquellas localizaciones más alejadas del centro o incluso más cercanas a un nodo fijo determinado es menor.

Las conclusiones anteriores obedecen a un escenario muy básico, sólo cuatro nodos fijos formando un cuadrilátero y sólo un plano de reflexión, el suelo. En un escenario más realista, simulado también mediante nuestra herramienta de simulación LoTrackS-WSN, donde son posibles múltiples modos de propagación y existe un despliegue de sensores no totalmente regular, los resultados en buena lógica deben de cambiar y así sucede. Es en este contexto donde debemos situar las siguientes conclusiones, que además sólo se refieren al algoritmo BAR+Alfas.

- 1. Cuando los nodos fijos forman un polígono más o menos regular el error cometido se encuentra dentro unos valores razonables. Conforme más se aleje de la consideración de cuadrilátero mayor será el incremento del error.
- 2. El error esta fundamentalmente influido por las posiciones de los dos nodos más potentes (primero y segundo en nivel RSSI). La diferencia de

posiciones entre estos influye de tal forma que el error en cada dimensión del espacio depende de la diferencia de posiciones en esa dimensión. Cuanto mayor es la diferencia mayor es el error.

3. Cuando el polígono resultante al unir los cuatro nodos que más nivel RSSI reciben resulte con tres de ellos alineados (retícula de forma triangular), el error se dispara. La magnitud del error es tanto mayor cuanto más cerca este el móvil de los nodos colineales.

Respecto a las medidas en una situación real de campo las conclusiones parciales prácticamente son las mismas que se han desgranado previamente para escenarios simulados. Por ejemplo, se confirma en la práctica que el error siempre depende de la diferencia entre las coordenadas x y y, a mayor diferencia entre estas mayor es la magnitud del error.

La conclusión global en este apartado es que en un escenario real los errores en las medidas RSSI provocan un incremento del error, que gracias a la robustez de nuestro algoritmo de estimación de la constante de atenuación se ve bastante minorado, casi hasta los niveles de un escenario básico. Para reducir estos errores es sumamente importante el despliegue, ya que el error guarda relación directa con las distancias que separa a los nodos fijos, así como a la geometría de la retícula resultante para una localización determinada.

#### • Algoritmo de Seguimiento

Los resultados cotejados en el apartado 4.5.4 son producto de la conjunción de un algoritmo de localización y otro de seguimiento basado en EKF. El primero tomado como elemento de observación, por tanto, es el agente que nos procura las medidas necesarias para la parte EKF del algoritmo de seguimiento.

- 1. El algoritmo de seguimiento corrige muy bien los errores obtenidos en las medidas realizadas con el algoritmo Baricentro, llevándolo a valores bastante por debajo de los de este algoritmo.
- 2. El algoritmo de seguimiento presenta un problema y es que en los cambios de dirección sus errores superan a los resultantes de la media (algoritmo de Baricentros), pero esta situación se corrige rápidamente.
- 3. En un escenario cuasi-real el concurso del algoritmo de seguimiento reduce claramente el valor RMSE en algo más de 0,5 m en promedio, llegando a situaciones donde el error es prácticamente nulo.
- 4. Los mayores errores se alcanzan justo en las transiciones entre retículas, que es cuando entran nuevos nodos fijos, pero seguimos utilizando la historia pasada, es decir no inicializamos el algoritmo EKF.

En resumen el algoritmo de seguimiento consigue gracias a una buena de medida de la localización alcanzar un resultado más aproximado logrando reducciones significativas de los errores.

## 5.2 Líneas Futuras

El desarrollo de nuestros trabajos de investigación ha dado lugar a una serie de aportaciones que hemos presentado. En la evolución hasta alcanzar dichas aportaciones han quedado aspectos que se pueden abordar de diferente forma y nuevos desafíos que alcanzar. Exponemos aquí una relación que no pretende ser exhaustiva pero sí realista de por dónde se enfocarán nuestros trabajos. Hemos de precisar, que parte de las líneas que presentamos ya son objeto de trabajo en el momento de finalización de esta memoria como parte de nuestra actividad en el Instituto Universitario para el Desarrollo Tecnológico y la Innovación en Comunicaciones (IDeTIC) [IDeTIC 2010].

Presentamos las líneas futuras agrupadas en cuatro grandes áreas:

#### 1. Integración de agrupaciones concentradas y distribuidas

Es de interés usar agrupaciones concentradas que a su vez estén distribuidas por el escenario de aplicación.

- En ambientes submarinos y aéreos se pueden usar varias agrupaciones con las que realizar estimaciones de posición angular para llegar a estimar la posición cartesiana en el espacio.
- En nodos que miden niveles de potencia se puede usar una agrupación de ellos convenientemente espaciados que permita mitigar aún más el efecto de las reflexiones en los obstáculos.

#### 2. Obtención de información básica

Dentro de los tipos de información básica utilizados quedan aspectos por estudiar como:

- Desarrollo de nuevos algoritmos de estimación de las constantes de atenuación, por ejemplo, incluyendo las restricciones sobre los valores posibles de la constante en la formulación o trabajando a diferentes frecuencias.
- Extensión de los algoritmos de estimación de la constante de atenuación a escenarios interiores, así como a otras frecuencias de trabajo y tipos de onda (p.e. acústicas).
- Uso de los retardos entre sensores y su posible estimación aprovechando el conocimiento que tenemos de la fuente.
- Ampliación a otro tipo de señales más complejas empleando detección mediante HOS (High Order Statistic), p.e. mediante biespectro.

#### 3. Modelado de fuente

Si bien el modelado que hemos utilizado se adapta bien a un tipo de fuente como los cachalotes también podemos ampliar nuestro trabajo hacia:

- En el caso de los cachalotes podemos aprovechar que los clics con frecuencia son múltiples réplicas de uno básico con el que comparten características. Se abre así la posibilidad de utilizar una formulación de polos y ceros comunes en modelos ARMA. - Desarrollo de modelos para otros cetáceos como delfines, belugas, zifios, etc.

#### 4. Nuevos algoritmos para localización y seguimiento

Una vez comprobados los buenos resultados alcanzados en el seguimiento con la conjunción del algoritmo de localización, BAR+Alfas con el filtrado de Kalman, y estimación DOA (ARMAExtFast) también con filtrado de Kalman, creemos imprescindible tanto ahondar en esta propuesta como abrirnos a otras que amplíen este horizonte, por lo que proponemos:

- Ampliación del Filtrado de Kalman mediante un abanico de matrices de transición de estados con direcciones preferidas seleccionables probabilísticamente de manera que mejoren el comportamiento del Filtrado de Kalman en los cambios de dirección.
- Introducción de PF (Particle Filtering) al problema del seguimiento de fuentes tanto en espacios abiertos (exteriores) como cerrados (interiores).
- Introducción de técnicas HMM (Hidden Markov Model) para la localización en espacios cerrados.
- Estimación de la distancia a un emisor submarino mediante la identificación de tres modos básicos de propagación para una misma señal: modo directo, modo por reflexión en la superficie y modo por reflexión en el fondo.

#### 5. Nuevos algoritmos de Identificación

En este ámbito y en la parcela que le hemos dedicado en esta tesis, resulta atractivo y casi obligada la extensión a otros ámbitos y contextos, como:

- Estudio de sensores y técnicas de procesado para identificación de tipos de fuentes e individuos con agrupaciones distribuidas.

# Bibliografía

Las referencias que hemos indicado a lo largo de este documento se listan a continuación separados en cinco apartados y por orden alfabético del primer autor.

# 1. Libros y Capítulos de Libros

[André 2000]	André, M.;"El Cachalote, Physeter macrocephalus, en
	las Islas Canarias," Servicio de Publicaciones de la
	Universidad de Las Palmas de Gran Canaria, 2000.
[Au 2000]	Au, W. W. L.; Popper, A. N.; Fay, R. R.; "Hearing by
	whales and dolphins," Springer-Verlag, cop.,New
	York, 2000.
[Au 1993]	Au, W. W. L.;"The sonar of dolphins," Springer-
	Verlag, cop.,New York, 1993.
[Balanis 1989]	Balanis, C.A. ; "Advanced Engineering
	Electromagnetics," 1ª Ed., John Wiley & Sons, 1989.
[Blackman 1999]	Blackman, S.; Popoli, R.; "Design and Analysis of
	Modern Tracking Systems," Artech House, Norwood,
	1999.
[Boukerche 2009]	Boukerche, A.;"Algorithms and Protocols for Wireless
	Sensor Networks," John Wiles & Sons, Inc., New
	Jersey, 2009.

[Brandstein 2001]	Brandstein, M.; Ward, D.(Eds);" <i>Microphone arrays:</i> signal processing techniques and applications," Srpinger-Verlag, Berlin, 2001.
[Burdic 1991]	Burdic,W.S. ; "Underwater Acoustic System Analysis," 2 <sup>a</sup> ed., Prentice Hall Signal Processing Series, Englewood Cliffs, 1991.
[Buttner 1946]	Buttner,H.H. ;Kohlhaas, H.T. y Mann,F.J.; " <i>Reference Data for Radio Engineers</i> ", 2 <sup>a</sup> Ed.,Federal Telephone and Radio Corporation, New York, 1946
[Carlson 2002]	Carlson, A.B.;Crilly, P.B.;Rutledge, J.C.; "Coomunications Systems: An Introduction to Signals and Noise in Electrical Communication," McGraw-Hill, 2002.
[Dennis 1996]	Dennis, J.E.; Schnabel, R.B.; "Numerical methods for unconstrained optimization and nonlinear equations." SIAM, Philadelphia, 1996.
[Etter 1991]	Etter, P.C. ; "Underwater Acoustic Modeling: Principles, Techniques and Applications," 1 <sup>a</sup> ed., Elsevier Applied Science, New York, 1991.
[Haykin 1991]	Hayken, S. (Editor);"Advances in Spectrum Analysis and Array Processing,", Vol. II, Prentice Hall Advanced Reference Series, Englewood Cliffs, 1991.
[Hippenstiel 2002]	Hippenstiel, R.D.;"Detection Theory. Applications and Digital Signal Processing," CRC Press LLC, 2002.
[Holger 2005]	Holger, K. y Andreas, W.; "Protocols and Architectures for Wireless Sensor Networks," John Wiley & Sons, Ltd, 2005.
[IEEE 2006]	IEEE Computer Society ; "IEEE Std 802.15.4 <sup>™</sup> -2006 (Revision of IEEE Std 802.15.4-2003).Part 15.4: Wireless Medium Access Control (MAC) and Physical Layer (PHY) Specifications for Low-Rate Wireless Personal Area Networks (WPANs)," The Institute of Electrical and Electronics Engineers, Inc., New York, 2006.
[Ilyas 2005]	Ilyas, M.; Mahgoub, I.; "Handbook of sensor networks : compact wireless and wired sensing systems." CRC Press LLC, 2005.
[Jensen 2000]	Jensen, F.B. ; "Computational ocean acoustics," 1 <sup>a</sup> ed., Springer-Verlag, New York, 2000.
[Johnson 1993]	Johnson, D.H. y Dudgeon, D.E. ; "Array Signal Processing: Concepts and Techniques," 1 <sup>a</sup> ed., Prentice Hall, Englewood Cliffs, New Jersey, 1993
[Kay 1988]	Kay, S.M.; "Modern Spectral Estimation: Theory and Application," Prentice Hall, Englewood Cliffs, 1988.

[Kinsler 1992]	Kinsler,L.E.; " <i>Fundamentos de Acústica</i> ," 2 <sup>a</sup> ed., Limusa, México, 1992.
[Lurton 2002]	Lurton, X. ; "An Introduction to Underwater Acoustics: Principles and Applications," 1 <sup>a</sup> ed., Springer Verlag, Berlin Heidelberg New York, 2002.
[Manolakis 2005]	Manolakis, D.G.; Ingle, V.K.; Kogon, S.M.; "Statistical and Adaptive Signal Processing." Artech House, London, 2005.
[McPherson 1979]	McPherson,W.L. et al; "Reference Data for Radio Engineers," 6 <sup>a</sup> ed., Howard W. Sams, Indianapolis, 1979.
[Naidu 2001]	Naidu,P.S.;"Sensor Array Signal Processing," C.R.C. Inc., 2001.
[O'Shaughnessy 1987]	O'Shaughnessy,D.;"Speech Communication," Addison-Wesley, 1987.
[Pahlavan 2002]	Pahlavan, K. y Krishnamurthy, P.;"Principles of Wireless Networks," Prentice-Hall, New Jersey, 2002.
[Papadias 2006]	Papadias, C.B.;Gesbert,D.;Bölcskei,H.;Van Der Veen, A. J.;"Space-time wireless system: from array processing to MIMO communications."Cambridge University Press, 1 <sup>a</sup> Ed., New York, 2006.
[Peña-Sánchez 1988]	Peña-Sánchez, D.;" <i>Estadística Modelos y Métodos</i> ." Alianza Editorial, 2 <sup>a</sup> edición, Madrid, 1986.
[Salhieh 2005]	Salhieh, A.; Schwiebert, L.; " <i>Power-Efficient</i> <i>Topologies for Wireless Sensor Networks</i> ", in "Handbook of Sensor Networks Compact Wireless and Wired Sensing Systems", Mohammad Ilyas and Imad Mahgoub, CRC Press, 2005.
[Suthers 1988]	Suthers, R.A.;" <i>The production of echolocation signals by bats and birds.</i> " Pag. 23-45 en Animal Sonar: Processes and Performance. Nachtigall, P.E. and Moore P.W.B. (Eds), Plenum Press, NewYork, 1988.
[Tyack 2002]	Tyack,P.;Miller,E.H.;" <i>Vocal Anatomy Acoustic</i> <i>Communication and Echolocation.</i> " Pag. 142-184 en Marine Mammal Biology: An Evolutionary Approach. Hoelzel, A.R., editor, Blackwell Science, Oxford, 2002.
[Urick1983]	Urick, R.J. ; " <i>Principles of underwater sound</i> ," 3 <sup>rd</sup> ed., McGraw-Hill, New York, 1983.
[Van Der Heijden 2005]	Van Der Heijden,F.;Duin,R.P.W.;de Ridder, D.; Tax, D.M.J.;" <i>Classification, Parameter Estimation and</i> <i>State Estimation: an engineering approach using</i> <i>MATLAB.</i> " John Wiley & Sons Ltd., 2005.

[Van Trees 2002]	Van Trees, H.L.;"Optimum Array Processing. Part IV of Detection, Estimation, and Modulation Theory." John Wiley & Sons, Inc.,1 <sup>a</sup> Ed.,New York, 2002.
[Vaughan 2003]	Vaughan, R. y Andersen, J.B.;"Channels, Propagation and Antennas for Mobile Communications,"IEE Electromagnetic Waves Series; no. 50. The Institution of Electrical Engineers London 2003
[Wilson 1988]	Wilson, O.B.;"Introduction to theory and design of sonar transducers," Peninsula Publishing, Los Altos, 1988.
[Woerner 1995]	Woerner, B.D. ;Rappaport, T.S. y Reed,J.H.; "Wireless Personal Communications Research Developments," Kluwer Academic Publishers, Massachusetts, 1995.
[Wood 1980]	<ul> <li>Wood, F.G.; Evans, W.E.; "Adaptiveness and ecology of echolocation in toothed whales." Pag. 381-425.</li> <li>G.Busnel and J.F.Fish, eds. Animal Sonar Systems, Plenum Press, New York, 1980.</li> </ul>
[Zhao 2004]	Zhao, F. y Guibas, L.J.;" <i>Wireless Sensor Networks: An Information Processing Approach</i> ,"Elsevier Inc., San Francisco, 2004.
[Ziomek 1995]	Ziomek, L.J.;"Fundamentals of Acoustic Field Theory and Sapce-Time Signal Processing," C.R.C. Press, Inc., 1995.
2. Artículos	
[Adler-Fenchel 1980]	Adler-Fenchel, H.S.; "Acoustically Derived Estimate of the Size Distribution for a Sample of Sperm Whales (Physeter catodon) in the Western North Atlantic", Can.J.Fish.Aquat.SCL, p.p. 2358-2361, vol. 39, 1980
[Affes 1996]	Affes, S.; Gazor, S.; Grenier, Y.;"An algorithm for

Affes, S.; Gazor, S.; Grenier, Y.;"An algorithm for multisource beamforming and multitarget tracking," IEEE Transactions on Signal Processing, , vol.44, no.6, pp.1512-1522, Jun 1996.

Akyildiz, I. F.; Pompili, D.; T. Melodia, T.; "Challenges for Efficient Communication in Underwater Acoustic Sensor Networks", ACM Sigbed Review, vol. 1, no. 2, July 2004.

[Al-Ali 2005] Al-Ali, A.R.; Aji, Y.R.; Othman, H.F.; Fakhreddin, F.T.;"Wireless smart sensors networks overview," Wireless and Optical Communications Networks, 2005. Second IFIP International Conference, Page(s):536 - 540, on 6-8 March 2005

[Akyildiz 2004]

[Amiri 2007]	Amiri,H.;Amindavar,H.;Kamarei,M.;"Underwater noise modeling and direction-finding based on heteroscedastic time series." EURASIP Journal on Applied Signal Processing, v.2007 n.1, p.41-41, 1
[Andersen 1995]	January 2007. Andersen, J. B.; Rappaport, T.S. and Yoshida,S.; "Propagation Measurements and Models for Wireless Communications Channel", IEEE Communications Magazine January 1995
[André 2004]	André, M.;Delory,E.;van der Schaar,M.; "A Passive Acoustic Solution to 3D Whale Monitoring." 7th French Workshop on Underwater Acoustics, Sea- Tech Week Brest France 2004
[Arampatzis 2005]	Arampatzis, Th.; Lygeros,J.; "A Survey of Wireless Sensors and Wireless Sensor Networks", Proceedings of 13th Mediterranean Conference on Control and Automation Limagool Cuprus, June 27 29, 2005
[Arulampalam 2002]	Arulampalam, M.S.; Maskell, S.; Gordon, N.; Clapp, T.; "A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking," IEEE Transactions on Signal Processing,vol.50, no.2,
[Awad 2007]	pp.174-188, Feb 2002. Awad, A.; Frunzke, T.; Dressler, F.; "Adaptive Distance Estimation and Localization in WSN using RSSI Measures," 10th Euromicro Conference on Digital System Design Architectures, Methods and Tacla DSD 2007, pp.471-478, 20-21, Aug. 2007.
[Bar-Shalom 1978]	Bar-Shalom, Y.;" <i>Tracking methods in a multitarget environment</i> ." IEEE Transactions on Automatic Control, Volume 23, Issue 4, Page(s):618 - 626, August 1978
[Beedholm 2006]	Beedholm, K.; Møhl,B.; "Directionality of Sperm Whale Sonar Clicks and its Relation to Piston Radiation Theory," J.Acoust.Soc.Am., Vol. 119, issue 2. February 2006
[Bienvenu 1989]	Bienvenu, G.; Fuerxer, P.; Vezzosi, G.; Kopp, L.; Florin, F.;" <i>Coherent wide band high resolution processing for linear array</i> ". International Conference on Acoustics, Speech, and Signal Processing, ICASSP-89,vol.4,Page(s):2799-2802, 23-26 May 1989.
[Blazevic 2002]	Blazevic,L.; Giordano,S.; Le Boudec,J.Y.; "Anchored Path Discovery in Terminode Routing", in Proc. of NETWORKING 2002 2002
[Böhme 1984]	Böhme, J.;" <i>Estimation of source parameters by</i> <i>maximum likelihood and nonlinear regression</i> ." IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP '84.Volume 9, Part 1, Page(s):271 - 274, March 1984.

[Böhme 1985]	Böhme, J.;"Source-parameter estimation by approximate maximum likelihood and nonlinear regression." IEEE Journal of Oceanic Engineering,
[Capon 1969]	Volume: 10, Issue: 3, page(s): 206- 212, July 1985. Capon, J.;" <i>High-resolution frequency-wavenumber</i> <i>spectrum analysis</i> ,"Proceedings of the IEEE Volume
[Capon 1970]	Capon, J.;" <i>Applications of detection and estimation theory to large array seismology</i> ". Proceedings of the IEEE, Volume 58, Issue 5, Page(s):760 - 770, May 1970
[Carley 2004]	Carley, T.W.;" <i>Sidh: A Wireless Sensor Network</i> <i>Simulator</i> ". Institute for Software Research Technical Reports, 2004.
[Cevher 2007]	Cevher,V.;Velmurugan,R.; McClellan, J.H.;"Acoustic Multitarget Tracking Using Direction-of-Arrival Batches." IEEE Transactions on Signal Processing,Vol. 55, Issue: 6, Part 2, page(s): 2810- 2825.June 2007.
[Chen 2005]	Chen,Y.; Chuan,C.; Zhao, Q.; "Sensor Placement for Maximizing Lifetime per Unit Cost in Wireless Sensor Networks", In Proc. of IEEE Military Communication Conference (MILCOM), October, 2005.
[Chen 2008]	Chen,W.;Mei,T.;Meng,M.Q.H.;Liang,H.;Liu,Y.;Li,Y.;L i,S.;"Localization Algorithm Based on a Spring Model (LASM) for Large Scale Wireless Sensor Networks." Sensors 8 no 3: pp 1797-1818 2008
[Chiu 2004]	Chiu,P.L.; Lin,F.Y.S.; "A simulated annealing algorithm to support the sensor placement for target location", Canadian Conference on Electrical and Computer Engineering 2004, vol. 2, p.p. 867- 870, May 2004.
[Culler 2004]	Culler, D., Estrin, D. and Srivastava, M., "Overview of Sensor Networks," Special Issue in Sensor Networks, IEEE Computer 37(8): 41-49, Aug 2004.
[Delfino 2006]	Delfino, F.; Girdinio, P.; Minervini, L. and Nervi, M.; "Electromagnetic plane wave scattering from building surfaces," COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering Vol. 25 No. 4, 2006 pp. 1007- 1018
[Delory 2007]	Delory, E.; André, M.; Navarro-Mesa, J.L.; van der Schaar, M.; " <i>On the possibility of detecting surfacing</i> <i>sperm whales at risk of collision using others'</i> <i>foraging clicks.</i> " Journal of the Marine Biological Association of the United Kingdom, vol 87, issue 1, p.47-58, Feb 2007.

[Di Rocco 2007]	Di Rocco, M.; Pascucci, F.; "Sensor network localisation using distributed extended Kalman filter," ieee/asme international conference on Advanced intelligent mechatronics, pp.1-6, 4-7 Sept.
[Downard 2004]	Downard, I.; "Simulating Sensor Networks in NS-2," NRL Formal Report 5522-04-10, May 2004.
[Erceg 1999]	Erceg, V.; Greenstein, L. J.; Tjandra, Sony Y.; Parkoff, S. R.; Gupta, A.; Kulic, B.; Julius, A. A. and Bianchi, R.; "An Empirically Based Path Loss Model for Wireless Channels in Suburban Environments," IEEE Journal On Selected Areas In Communications Vol. 17 No. 7 July 1999
[Fargues 1993]	Fargues, M.P.; Cristi, R.; Vanderkamp, M.M.; "Modeling and classification of biological signals using leastsquares Prony-SVD AR modeling [underwater acoustics]." Proceedings of the 36th Midwest Symposium on Circuits and Systems, Volume 1 Page(s):445 - 448 16-18 Aug 1993
[Fargues 1995]	Fargues, M.P.; Bennett, R.;"Comparing wavelet transforms and AR modeling as feature extractiontools for underwater signal classification." Conference Record of the Twenty-Ninth Asilomar Conference on Signals, Systems and Computers, Volume 2, Issue 30, Page(s):915 - 919, Oct-1 Nov
[Ficker 1989]	Ficker, A.J.; Bresler, Y.; "Sensor-efficient wideband source location," Circuits and Systems, 1989., Proceedings of the 32nd Midwest Symposium on , vol. no. pp 586-589 vol 1, 14-16 Aug 1989
[Franceschetti 2004]	Franceschetti, M.; Bruck, J.; Schulman, L.J.,"A random walk model of wave propagation," IEEE Transactions on Antennas and Propagation, Volume 52. Issue 5. Page(s):1304 – 1317 May 2004
[Friedlander 1984]	Friedlander, B.; Porat, B., "The Modified Yule-Walker Method of ARMA Spectral Estimation," IEEE Transactions on Aerospace and Electronic Systems vol AES-20 no 2 np 158-173 March 1984
[Gaetz 1993]	Gaetz, W. Jantzen, K. Weinberg, H. Spong, P. Symonds, H.;"A neural network method for recognition of individual Orcinus orcabased on their acoustic behaviour: phase 1." Proceedings OCEANS '93, vol.1, On page(s): I455-I457, 18-21 Oct 1993.
[Gentry 2003]	Gentry, R.L.;"Mitigation Measures for Use with Military Sonar." Proceedings of the workshop on Active sonar and cetaceans," 17th ECS Conference, March 2003.

[Ghosh 1992]	Ghosh, J. Deuser, L. Beck, S.D.;"A neural network based hybrid system for detection, characterization, and classification of short-duration oceanic signals."
	IEEE Journal of Oceanic Engineering, Volume: 17,
	Issue: 4,On page(s): 351-363, Oct 1992.
[Goold 1996]	Goold, J.C.;"Signal processing techniques for acoustic
	measurement of sperm whale body lengths," J Acoust Soc Am 100 (5), pp. 3431–3441, 1996.
[Gordon 1991]	Gordon, J.C.D.;"Evaluation of a method for
	determining the length of sperm whales (Physeter
	catodon) from their vocalizations," Journal Zoology,
	no. 224, pp. 301-314, 1991.
[Gustafsson 2002]	Gustafsson, F.; Gunnarsson, F.; Bergman, N.;
	Forssell, U.; Jansson, J.; Karlsson, K.; Nordlund, P
	J.; , "Particle fillers for positioning, navigation, and traching" IFFF Transactions on Signal Processing
	vol 50 no 2 nn 425-437 Fob 2002
[Hata 1980]	Hata M : "Empirical formula for propagation loss in
	land mobile radio services." IEEE Transactions on
	Vehicular Technology. Volume 29. Issue
	3,Page(s):317 - 325, Aug 1980.
[Hernández 2002a]	Hernández, E.; Delory, E.; André, M.; Navarro, J.
	L.;"Incorporación de un Modelo de Fuente a la
	Localización de Cachalotes". Actas del XVII
	Simposium Nacional de la Union Científica
	Internacional de Radio, URSI 2002, Sesión IV, pags.
	41-42. Madrid-Alcalà de Henares, 11 al 13
[Hornándoz 2002b]	Septiembre 2002. Hornándoz E : Podráznoz – P.: Noverno – I – I.
[Hernandez 2002b]	"Modelado de la Eunción de Transferencia del
	Sistema de Producción de Clics en Cachalotes" Actas
	del XVII Simposium Nacional de la Union Científica
	Internacional de Radio, URSI 2002, Sesión V, pags.
	41-42. Madrid-Alcalá de Henares, 11 al 13
	Septiembre 2002.
[Hernández-Pérez 2003]	Hernández-Pérez, E.; Navarro-Mesa, J.L.; Delory, E.;
	Degollada, E.; André, M." ARMA Model of the Sperm
	Whale Sound Production System," 17 <sup>th</sup> Conference of
	the European Cetacean Society, Las Palmas de Gran
	Canaria, España, 9-13 march, 2003.
[Hernandez-Perez 2004]	Hernandez-Perez, E.; Navarro-Mesa, J.L.; Millan-
	identification of autoregressive marine marmal
	sources by passive sonar" Proceedings IEEE
	International Geoscience and Remote Sensing
	Symposium, 2004. IGARSS 2004.Volume 2. Page(s):
	1435 - 1438, 20-24 Sept. 2004.

[Hou 1986]	Hou, T.C.; Li, V.; "Transmission Range Control in Multihop Packet Radio Networks", IEEE Trans. on
[Hu 2007]	Communications, 34(1): pp. 38—44, 1986. L.Q. Hu, H. Yu and Y. Chen," <i>Path loss models based on stochastic rays</i> ," IET Microw. Antennas Propag.,
[Hussain 2005]	1, (3), pp. 602–608, 2007. Hussain, M. G. M. ;" <i>Theory and analysis of adaptive cylindrical array antenna for ultrawideband wireless communications</i> ", IEEE Trans. Wireless Communications, vol. 4, no. 6, pp. 3075-3083, Nov. 2005
[Huynh 1998]	Huynh, Q.Q.; Cooper, L.N.; Intrator, N.; Shouval, H.;" <i>Classification of underwater mammals using</i> <i>feature extraction based on time-frequency analysis</i> <i>and BCM theory.</i> " IEEE Trans. on Signal Processing, Volume 46, Issue 5, Page(s):1202-1207, May 1998.
[Ioannides 2005]	Ioannides, P. and Balanis, C. A. ; "Uniform Circular Arrays for Smart Antennas," IEEE Antennas & Propagation Magazine, Vol. 47, No. 4, pp. 192-206, August 2005.
[Konvalinka 1979]	Konvalinka, I.; Matausek, M., "Simultaneous estimation of poles and zeros in speech analysis and <i>ITIF-iterative inverse filtering algorithm</i> ," IEEE Transactions on Acoustics, Speech and Signal Processing vol 27 no 5 np 485-492 Oct 1979
[Korkalainen 2009]	Korkalainen, M.; Sallinen, M.; Karkkainen, N.; Tukeva, P.;" <i>Survey of Wireless Sensor Networks</i> <i>Simulation Tools for Demanding Applications</i> ," Fifth International Conference on Networking and Services ICNS '09 pp 102-106 20-25 April 2009
[Krim 1996]	Krim, H.; Viberg, M.," <i>Two Decades of Array Signal</i> <i>Processing Research</i> ," IEEE Signal Processing Magazine, Volume 13, Issue 4,Page(s):67 - 94 July 1996
[Krolik 1989]	Krolik, J.; Swingler, D.;" <i>Multiple broad-band source</i> <i>location using steered covariance matrices</i> ". IEEE Trans. on Acoustics, Speech and Signal Processing, Volume 37, Issue 10, Page(s):1481 - 1494, Oct. 1989.
[Krolik 1990a]	Krolik, J.; Swingler, D.;"Focused wide-band array processing by spatial resampling". IEEE Transactions on Acoustics, Speech and Signal Processing, Volume 38, Issue 2, Page(s):356 - 360, Feb. 1990
[Krolik 1990b]	Krolik, J.; Swingler, D.;" <i>The detection performance of coherent wideband focusing for a spatially resampled array</i> ". International Conference on Acoustics, Speech, and Signal Processing,ICASSP-90,vol.5, Page(s):2827 - 2830, 3-6 April 1990.

[Lacoss 1971]	Lacoss, R.T.;"Data adaptive Spectral Analysis Methods," Geophysics 36, 661, August 1971.
[Lamel 1981]	Lamel,L. et al.;"An improved endpoint detector for isolated word recognition," IEEE Transactions on Acoustics, Speech and Signal Processing, Volume: 29, Issue: 4 On page(s): 777-785 August 1981
[Leaper 1992]	R.Leaper,O.Chappell y J.Gordon," <i>The development of practical techniques for surveying sperm whale populations acoustically</i> ," REPORTS OF THE INTERNATIONAL WHALING COMMISSION, vol. 42 pp 549-560 1992
[Lee 2006]	Lee, J.; Cho, K.; Lee, S.; Kwon, T.; Choi, Y.; "Distributed and energy-efficient target localization and tracking in wireless sensor networks.", Computer Communications vol 29 pp 2494–2505 2006
[Levis 2003]	Levis, P.;Lee, N.; et al.; "TOSSIM: Accurate and scalable simulation of entire TinyOS applications," in Proceedings of the First ACM Conference on Embedded Networked Sensor Systems, pp. 126–
[Li 2005]	<ul> <li>137,Los Angeles, CA, November 2003.</li> <li>Li, X.; Shi, H.; Shang, Y.;"A sorted RSSI quantization based algorithm for sensor network localization," Proceedings 11th International Conference on Parallel and Distributed Systems, vol.1, pp. 557-563, 20-22 July 2005.</li> </ul>
[Lucifredi 2005]	Lucifredi, I.; Stein, P.J.; Alix, K.L.; Herman, J.C.; Frankel, A.S.; Ellison, W.T.; Egnor, D.E.; Clark, C.W.; DeProspo, D.; , "Integrated Marine Mammal Monitoring and Protection System (IMAPS)," OCEANS, 2005. Proceedings of MTS/IEEE, vol., no., pp. 2624, 2641 Vol. 2, 2005
[Lucifredi 2006]	Lucifredi, I.; Stein, P.J.; , "Integrated Marine Mammal Monitoring and Protection System (IMAPS): Gray Whale Target Strength Measurements and the Analysis of the Back-Scattered Response," OCEANS 2006, vol., no., pp.1-6, 18-21 Sept. 2006.
[Lymberopoulos 2006]	Lymberopoulos, D.; Lindsey, Q.; Savvides, A.;"An Empirical Characterization of Radio Signal Strength Variability in 3-D IEEE 802.15.4 Networks Using Monopole Antennas." European Workshop on Wireless Sensor Networks 2006, Zurich
[Manolakis 2005]	(Switzerland), February 13-15, 2006. Manolakis,D.G.; Ingle, V. K. and Kogon, S. M.;"Statistical and Adaptive Signal Processing: Spectral Estimation, Signal Modeling, Adaptive Filtering and Array Processing," Artech House, Inc., Norwood, 2005.

[Mayne 1977]	Mayne,D. Q.; Firoozan,F. "An efficient, multi stage, linear identification method for ARMA processes," IEEE Conference on Decision and Control including the 16th Symposium on Adaptive Processes and A Special Symposium on Fuzzy Set Theory and
[Mechitov 2003]	Applications, vol. no. 16, pp.435-438, Dec. 1977. Mechitov,K.; Sundresh,S.;Kwon, Y.; "Cooperative Tracking with Binary-Detection Sensor Networks", at SenSys'03, Los Angeles, California, USA, November
[Møhl 2000]	B. Møhl, M. Wahlberg, and P. T. Madsen, "Sperm whale clicks: Directionality and source level revisited,"J. Acoust. Soc. Am. Volume 107, Issue 1,
[Møhl 2001]	pp. 638-648, January 2000. Møhl,B.;"Sound Transmission in the nose of the Sperm Whale Physeter Catodon. A Post Mortem Study." I Comp Physil (A) 187:225-240, 2001
[Møhl 2002]	Møhl, B.; Madsen, P. T.; Wahlberg, M.; Au, W. W. L.; Nachtigall, P. E.; Ridgway, S.; "Sound transmission in the spermaceti complex of a recently expired sperm whole calf" APLO 4, 10, 24, 2002
[Møhl 2003]	Bertel Møhl, Magnus Wahlberg, and Peter T. Madsen, "The monopulsed nature of sperm whale clicks," J. Acoust. Soc. Am. Volume 114, Issue 2, pp.
[Moran 1991]	Moran, J.A.; De la Torre, F.; Santamaria, E.;"An efficient algorithm for detecting and tracking moving targets." 13th International Conference on Digital Signal Processing Proceedings, DSP 97,Volume 2 Page(s):931-934, 2-4 July 1997
[Navarro-Mesa 1999]	<ul> <li>Navarro-Mesa, J.; Moreno-Bilbao, A.; Lleida-Solano,</li> <li>E.;"An improved speech endpoint detection system in noisy environments by means of third-order spectra".</li> <li>IEEE Signal Processing Letters, Volume 6, Issue 9,</li> <li>Page(a):224, 226, Sont 1000</li> </ul>
[Navarro-Mesa 2004]	Navarro-Mesa, J.L.; Millan-Munoz, M.J.; Hernandez- Perez, E.;" <i>An approach to DOA estimation of wide-</i> <i>band sources based on AR signal modeling.</i> " 3rd IEEE Sensor Array and Multichannel Signal Processing Workshop (SAM 2004), Page(s): 323-326,
[Niculescu 2003a]	Sitges (Spain), July 18-21, 2004. Niculescu,D.;Nath, B.;"Ad hoc positioning system (APS) using AOA," INFOCOM 2003. Twenty-Second Annual Joint Conference of the IEEE Computer and Communications. IEEE Societies, vol.3, no., pp. 1734- 1743 vol.3, 30 March-3 April 2003.

[Niculescu 2003b]	Niculescu, D.; Nath, B.; "DV Based Positioning in Ad
	hoc Networks", Kluwer Journal of
	Telecommunication Systems, 2003.
[Nielsen 2006]	Nielsen,B.K.;Mohl,B.," <i>Hull-mounted hydrophones</i>
	for passive acoustic detection and tracking of sperm
	whales (Physeter macrocephalus)." Applied Acoustics
	67: 1175-1186, 2006.
[Nishi 2008]	Nishi, Y.: Ohtsuki, T.: , "A distributed localization
	with unknown attenuation coefficient in wireless
	sensor networks " 14th Asia-Pacific Conference on
	Communications APCC 2008 nn 1-5 14-16 Oct
	2008
[Norris 1972]	Norris K S · Harvey G W · "A theory for the
	function of thespermaceti organ of the sperm whale
	(Physter catodon L)" in Orientation and Navigation
	adited by S B Galler K Schmidt-Koonig G J
	Jacobs and R E Belleville SP-262 NASA
	Washington DC np $397-417$ 1972
[Nosal 2006]	Nosal E.M.: Frazora I.N. "Trach of a sparm whale
	from dolays between direct and surface-reflected
	clicke " Applied Acoustics Volumo 67 Issues 11-19
	Pages 1187 1201 Nevember December 2006
$[O]_{con}$ 1078]	$\Omega$ ages 1107-1201, November-December 2000.
[Olsen 1976]	the calculation of nain attenuation "Antennes and
	Drepagation IEEE Transactions on Volume 20
	I ropagation, IEEE Transactions on volume 26,
[Dambalia 2007]	Derivation E.C. Decrease L. Ourorese I.C.
[Papkens 2007]	Marchanitic O.O. Kambatalan K.T. Varanos, I.C.;
	Moschovillis, U.G.; Karakatselos, K.I.; Vagenas, E.;
	Anastassiu, H.I.; Frangos, P.V.; , <i>A radio-coverage</i>
	prediction model in wireless communication systems
	differentian (Windows Commul) Antoneous d
	augraction [wireless Corner]," Antennas and
	Propagation Magazine, IEEE, vol.49, no.2, pp.156-
	165, April 2007. $\mathbf{M} \mathbf{D}$ "G $\mathbf{G}$ "
[Park 2000]	Park,S; Savvides, A.; Srivastava, M.B; SensorSim: A
	Simulation Framework for Sensor Networks. In
	Proc.ACM Modeling, Analysis and Simulation of
	Wireles and Mobile Systems (MSWiM 2000), pp.
	104–111, Boston, MA, August 2000.
[Pavan 2003]	Pavan, G.; Fossati, C.; Manghi, M.; Priano, M.;
	"Passive acoustics tools for the implementation of
	Acoustic Risk Mitigation Policies." Proceedings of the
	workshop on Active sonar and cetaceans, 17th ECS
	Conference, March 2003.
[Pisarenko 1973]	Pisarenko, V. F.;"The retrieval of harmonics from a
	covariance function." Geophysics, J. Roy. Astron.
	Soc., vol. 33, pp. 347-366, 1973.

[Polastre 2005 ]	Polastre, J.; Szewczyk, R.; Culler, D.;" <i>Telos: enabling</i> ultra-low power wireless research," Information
	Processing in Sensor Networks, 2005. IPSN 2005. Fourth International Symposium,Page(s):364 - 369,
[Pollev 2004]	on 15 April 2005. Polley, J.: Blazakis, D.: McGee, J.: Rusk, D.: Baras.
	J.S.; "ATEMU: a fine-grained sensor
	network simulator," First Annual IEEE
	Communications Society Conference on Sensor and
	SECON 2004 pp 145-152 4-7 Oct 2004
[Priyantha 2000]	Privantha, N.B.: Chakraborty.A. :Balakrishnan.H.:
	"The Cricket Location-Support System," Proc. of the
	Sixth Annual ACM International Conference on
	Mobile Computing and Networking (MOBICOM),
	August 2000.
[Priyantha 2001]	Priyantha,N.; Miu,A.;Balakrishnan,H.;Teller,S.; "The
	cricket compass for context-aware mobile
	July 2001
[Puccinelli 2005]	Puccinelli, D. and Haenggi, M., "Wireless Sensor
	Networks-Applications and Challenges of Ubiquitous
	Sensing," IEEE Circuits and Systems Magazine, vol.
	5, pp. 19-29, Aug. 2005.
[Quintana-Morales 2003]	Quintana-Morales,P. ;Navarro-Mesa,J. L.; "An
	approach to common acoustical pole and zero
	Proc EUROSPEECH Geneva Switzerland Sen 1-
	4, 2003.
[Rabiner 1975]	Rabiner,L.;Sambur, M.;"An Algorithm for Determinig
	the Endpoints of Isolated Utterances," The Bell
	Technical Journal, vol. 54. Nº 2, pag. 297-315, 1975.
[Rao 1992]	Rao, B.D.; Arun, K.S.;"Model based processing of
	signals: a state space approach", Proceedings of the
	1992
[Rao 1994]	Rao.C.:Zhang, L.: Zhao, L.C.:"Multitarget angle
	tracking an algorithm for data association." IEEE
	Transactions on Signal Processing, Volume 42, Issue
	2, Page(s):459 - 462, February 1994.
[Rhinelander 2004]	Rhinelander, M.Q.; Dawson, S.M.; "Measuring sperm
	whales from their clicks: Stability of interpulse
	length " I Acoust Soc Am 115 (4) April 2004
[Sastry 1991]	Sastry, C.R.; Kamen, E.W.: Simaan, M.:"An efficient
	algorithm for tracking the angles of arrival of moving
	targets." IEEE Transactions on Signal Processing,
	Volume 39, Issue 1, Page(s):242 - 246, January 1991.

[Satish 1994]	Satish, A.; Kashyap, R.L.;" <i>Wideband multiple target tracking.</i> " IEEE International Conference on Acoustics, Speech, and Signal Processing, 1994. ICASSP-94., 1994, Volume iv, Page(s):IV/517 -
[Satish 1995]	<ul> <li>IV/520, 19-22 April 1994.</li> <li>Satish, A.; Kashyap, R.L.;"Multiple target tracking using maximum likelihood principle." IEEE Transactions on Signal Processing, Volume 43, Issue 7 Page(s):1677-1695 July 1995</li> </ul>
[Savvides 2001]	Savvides, A.; Han, C.; Srivastava, M.B." <i>Dynamic fine- grained localization in ad-hoc networks of sensors.</i> " In Proceedings of the 7th Annual International Conference on Mobile Computing and Networking (MobiCom 2001), pages 166–179, Rome, Italy, July 2001.
[Sharman 1986]	Sharman, K.C.; Durrani, T.S.;"A comparative study of modern eigenstructure methods for bearing estimation-A new high performance approach".IEEE 25th Conference on Decision and Control 1986 ,Volume 25, Part 1, page(s):1737 - 1742, 10-12 December 1986.
[Simon 2003]	G. Simon, P. Völgyesi, M. Maróti and Á. Lédeczi "Simulation-based optimization of communication protocols for large-scale wireless sensor networks", IEEE Aerospace Conference, 2003.
[Singer 1970]	Singer, R.A.;"Estimating Optimal Tracking Filter Performance for Manned Maneuvering Targets," IEEE Transactions on Aerospace and Electronic Systems, Vol.AES-6, no.4, pp.473-483, July 1970.
[Singh 2008]	Singh, C.P.; Vyas, O.P.; Tiwari, M.K.; "A Survey of Simulation in Sensor Networks," International Conference on Computational Intelligence for Modelling Control & Automation, pp.867-872, 10-12 Dec. 2008.
[Sklar-I 1997]	Bernard Sklar,"Rayleigh Fading Channels in Mobile Digital Communication Systems Part I: Characterization," IEEE Communications Magazine, July 1997
[Sklar-II 1997]	Bernard Sklar,"Rayleigh Fading Channels in Mobile Digital Communication Systems Part II: Mitigation,"IEEE Communications Magazine, July 1997
[Sobeih 2006]	Sobeih, A.; Hou, J.C.; Lu-Chuan Kung; Ning Li; Honghai Zhang; Wei-Peng Chen; Hung-Ying Tyan; Hyuk Lim; " <i>J-Sim: a simulation and emulation</i> <i>environment for wireless sensor networks</i> ," Wireless Communications, IEEE, vol.13, no.4, pp.104-119, Aug. 2006.
[Sobeih 2007]	Sobeih, A.; Mahesh Viswanathan; Marinov, D.; Hou, J.C.; , "J-Sim: An Integrated Environment for Simulation and Model Checking of Network Protocols," Parallel and Distributed Processing
-------------------	---
	Symposium, 2007. IPDPS 2007. IEEE International
[Srinivasan 2006]	, pp.1-6, 26-30 March 2007. Srinivasan,K.; Levis, P.; "RSSI is Under Appreciated," Proc. of the. Third Workshop on Embedded Networked Sensors, EmNets'06,.
[Stoica 1990a]	<ul> <li>Boston, MA, May. 2006.</li> <li>Stoica, P.; Nehorai, A.;"MUSIC, maximum likelihood, and Cramer-Rao bound: further results and comparison". IEEE Transactions on Acoustics, Speech and Signal Processing, Volume 38, Issue 12,</li> </ul>
[Stoica 1990b]	<ul> <li>Page(s):2140 - 2150, December 1990</li> <li>Stoica, P.; Sharman, K.C.;"Maximum likelihood methods for direction-of-arrival estimation". IEEE Transactions on Acoustics, Speech and Signal Processing, Volume 38, Issue 7, Page(s):1132 - 1143,</li> </ul>
[Stoyanova 2007]	Tsenka Stoyanova, Fotis Kerasiotis, Aggeliki S. Prayati, George D. Papadopoulos," <i>Evaluation of impact factors on RSS accuracy for localization and tracking applications</i> ," Proceedings of the 5th ACM international workshop on Mobility management and
[Su 1983]	<ul> <li>wireless access, MOBIWAC 2007.</li> <li>Su, G.; Morf, M; "The signal subspace approach for multiple wide-band emitter location," IEEE Transactions on Acoustics, Speech and Signal Processing, Volume: 31, Issue: 6,page(s): 1502-1522, December 1082</li> </ul>
[Sundresh 2004]	Sundresh,S.;WooYoung, K.;Gul,A.; "SENS: A Sensor, Environment and Network Simulator," The 37th Annual Simulation Symposium (ANSS37), Arlington,
[Sword 1990]	<ul> <li>VA, April 21, 2004.</li> <li>Sword, C.K.; Simaan, M.; Kamen, E.W.;"Multiple target angle tracking using sensor array outputs," IEEE Transactions on Aerospace and Electronic Systems, Vol 26, no 2, no 267, 272, March 1990.</li> </ul>
[Tateishi 2008]	Tateishi, K.; Ikegami, T.; "Decision Experiment of Attenuation Constant During Location Estimation in RSSI," Ninth International Conference on Parallel and Distributed Computing, Applications and Technologies. PDCAT 2008, pp.431-436, 1-4 Dec. 2008.

[Teloni 2003]	Teloni,V.; Zimmer, V.M.X.;Johnson, M.P.;Tyack,P.L.; "Inter Click Interval Variation of Deep-Diving Sperm
	Whales in the Mediterranean Sea," 17 <sup>th</sup> Conference of the European Cetacean Society, Las Palmas de Gran
	Canaria, España, 9-13 March, 2003.
[Thode 2004]	Aaron Thode,"Tracking sperm whale (Physeter
	macrocephalus) dive profiles using a towed passive
	acoustic array," J. Acoust. Soc. Am. Volume 116,
	Issue 1, pp. 245-253, July 2004.
[Thomas 1986a]	Thomas, J.A.; Fisher, S.R.; Ferm, L.M.;"Acoustic
	Detection of Cetaceans Using a Towed Array of
	Hvdrophones." REPORTS OF THE
	INTERNATIONAL WHALING COMMISSION.
	Special issue 8: Behaviour of Whales in Relation to
	Management nn 139-148 1986
[Thomas 1986b]	Thomas JA: Fisher SR: Awbrev FA: "Use of
	Acoustic Techniques in Studying Whale Behavior"
	REPORTS OF THE INTERNATIONAL WHALING
	COMMISSION Special issue 8: Behaviour of Whales
	in Relation to Management, np. 121-138, 1986
[Tilak 2002]	Tilak S · Abu-Ghazaleh N · Heinzelman W ·
	"Infrastructure Tradeoffs for Sensor Networks" ACM
	1st International Workshop on Sensor Networks and
	Applications (WSNA '02) Sont 2002
$[T_{song}, 2003]$	The productions (WORK 02), Sept. 2002. The productions (WORK 02), Sept. 2002.
[Iseng 2005]	Location traching in a wireless sensor natwork by
	mobile agents and its data fusion strategies" In Int
	Workshop Inf Process Sonson Networks (IPSN)
	workshop III. 110cess. Sensor Networks (115N), $2624$ , $625$ , $641$ , $2002$
[Van Voon 1088]	Von Voon BD: Bucklow KM: "Bagmforming: a
	variable approach to englial filtering "IFFF ASSP
	Magazino Volumo 5 Jasuo 2 Paga(s): 4 24 April
	1988.
[Varga 2008]	Varga, A.; Hornig, R.;"An overview of the OMNeT++
	<i>simulation environment</i> ", Simutools '08: Proceedings
	of the 1st International Conference on Simulation
	Tools and Techniques for Communications, Networks
	and Systems & Workshops: 1-10. Marseille, France,
	2008.
[Wahlberg 2002]	Wahlberg. M.:"The acoustic behaviour of diving
	sperm whales observed with a hydrophone array."
	Journal of Experimental Marine Biology and
	Ecology, 281, pp. 53-62, 2002
[Watkins 1977]	William A. Watkins and William E. Schevill."Sperm
r ]	whale codas," J. Acoust. Soc. Am. Volume 62. Issue 6.
	pp. 1485-1490. December 1977.
	rr. 1100 1100, 2000moor 10111

[Wax 1984]	Wax, M.; Kailath, T.;"Determining the number of signals by information theoretic criteria." IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP '84. Volume 9, Part 1, Page(s):232 - 235 March 1984
[Wax 1989]	Wax, M.; Ziskind, I.;"Detection of the number of coherent signals by the MDL principle." IEEE Transactions on Acoustics, Speech and Signal Processing, Volume 37, Issue 8, Page(s):1190 - 1196, August 1989.
[Wax 1992]	Wax, M.;"Detection and localization of multiple sources in noise with unknown covariance." IEEE Transactions on Signal Processing, Volume 40, Issue 1, Page(s):245 - 249, January 1992.
[Weisburn 1993]	Weisburn, B.A. Mitchell, S.G. Clark, C.W. Parks, T.W.;" <i>Isolating biological acoustic transient signals.</i> " IEEE International Conference on Acoustics, Speech, and Signal Processing, 1993. ICASSP-93. Volume: 1, On page(s): 269-272, 27-30 Apr 1993.
[Whitehead 1990]	Whitehead,H.;Weilgart,L.;" <i>Click rates from sperm</i> <i>whales</i> ," Journal Acoustic Society of America, 87(4), pp.1798-1806. Abril 1990.
[Whitehouse 2007]	Whitehouse,K.;Karlof,C.;Culler, D.; " <i>A practical evaluation of radio signal strength for ranging-based localization.</i> " SIGMOBILE Mob. Comput. Commun. Rev. 11, 1, pp.41-52, Jan. 2007
[Willis 2005]	Willis, S.L.; Kikkert, C.J; " <i>Radio propagation model</i> for long-range ad hoc wireless sensor network," in International Conference on Wireless Networks, Communications and Mobile Computing, On page(s): 826-832 vol.1, 13-16 June 2005.
[Xu 2006]	Xu,K.; Takahara,G.; Hassanein,H; "On the robustness of grid-based deployment in wireless sensor networks", Proceeding of the 2006 international conference on Communications and mobile computing, Vancouver, British Columbia, Canada , July 03-06, 2006.
[Yang 2003]	Yang,H.;Sikdar, B.; "A Protocol for Tracking Mobile Targets using Sensor Networks", in Proceedings of the First IEEE International Workshop on Sensor Network Protocols and Applications, May 2003.
[Zatman 1998]	Zatman, M.;" <i>How narrow is narrowband?</i> " IEE Proceedings on Radar, Sonar and Navigation,Volume 145, Issue 2,Page(s):85-91, April 1998
[Zhou 1995]	Zhou,Y.; Yip,P. C.;" <i>DOA estimation by ARMA modelling and pole decomposition</i> ," IEE Proceedings: Radar, Sonar and Navigation, vol. 142, no. 3, pp. 115-122, 1995.

[Zhou 1999]	Zhou, Y.; Yip, P. C.; H. Leung; "Tracking the direction- of-arrival of multiple moving targets by passive arrays: Algorithm," IEEE Trans. Signal Process., vol. 47 pp 2655 Oct 1999
[Zhu 2006]	Zhu, Y.;Shareef, A.;"Comparisons of three Kalman filter tracking algorithms in sensor network," International Workshop on Networking, Architecture and Starsage IWNAS 106 2006
[Zimmer 2005a]	Architecture, and Storages. TWNAS '06., 2006. Zimmer, W. M. X.; Tyack,P. L. et al.; "Three- dimensional beam pattern of regular sperm whale clicks confirms bent-horn hypothesis." The Journal of the Acoustical Society of America 117(3, Pt 1): 1473- 1485, 2005.
[Zimmer 2005b]	Zimmer, .M.X.; Madsen,P.T.; Teloni,V.; Johnson, M.P.; Tyack,P.L.; "Off-axis effects on the multipulse structure of sperm whale usual clicks with implications for sound production."
[Ziskind 1988]	J. Acoust. Soc. Am. 118(5), November 2005. Ziskind, I.; Wax, M.;" <i>Maximum likelihood localization of multiple sources by alternating projection.</i> " IEEE Transactions on Acoustics, Speech and Signal Processing, Volume 36, Issue 10,
[Ziskind 1990]	Page(s):1553 - 1560, October 1988. Ziskind, I.; Bar-Ness, Y.;" <i>Direction finding of narrowband autoregressive sources by antenna arrays.</i> " Symposium International Society Antennas and Propagation. AP-S. 'Merging Technologies for the 90's'. Digest.vol.4.Page(s):1454 - 1457, 7-11 May
[Ziskind 1992]	1990. Ziskind,I.;Bar-Ness,Y.;"Localization of Narrow-Band Autoregresive Sources by Passive Sensor Arrays," IEEE Trans. Signal Processing, vol.40, pp. 484-487, February 1992.

### 3. Tesis y Proyectos Fin de Carrera

[André 1997]	André, M.; "Distribución y Conservación del Cachalote
	(Physeter Macrocephalus) en las Islas Canarias,"
	Director: López Jurado, L-F. Tesis doctoral inédita,
	Universidad de Las Palmas de Gran Canaria,
	Departamento de Biología, Las Palmas de G.C.,
	Marzo 1997.
[Beutel 2005]	Beutel,J.; "Design and Deployment of Wireless
	Networked Embedded Systems", PhD. Thesis, ETH
	Zurich, 2005.

[Hernández 2002]	Hernández-Pérez, E. y Navarro-Mesa, J.L., "Procesado de Agrupaciones de Sensores Aplicado a la Localización de Cachalotes," Proyecto Fin de Carrera, Escuela Técnica Superior de Ingenieros de Telecomunicación de la Universidad de Las Palmas de Gran Canaria, Enore 2002
[Lee 2006]	Lim Tat Lee, "Cross-Layer Design and Optimization for Wireless Sensor Networks," Naval Postgraduate School Monterey, CA 93943-5000 Master's Thesis of Science in Electrical Engineering, March 2006.
[Lessing 2004]	Peter Lessing, Robert Höldrich y Juan Luis Navarro- Mesa," <i>A Binaural 3D Sound System Applied to</i> <i>Moving Sources,</i> "Master Thesis, Institute of Electronic Music and Acoustics (IEM) University of Music and Dramatic Arts of Graz y Escuela Universitaria de Ingeniería Técnica de Telecomunicación Universidad de Las Palmas de Gran Canaria Agosto 2008
[Millán 2005]	Millán-Muñoz, M.J., Navarro-Mesa, J.L. y Hernández-Pérez, E., " <i>Procesado de Agrupaciones de</i> <i>Sensores Aplicado a la Localización de Cachalotes,</i> " Proyecto Fin de Carrera, Escuela Técnica Superior de Ingenieros de Telecomunicación de la Universidad de Las Palmas de Gran Canaria, abril 2005
[Navarro-Mesa 1997]	Navarro-Mesa, J.L.;" <i>Representaciones Tiempo</i> <i>Frecuencia No Paramétricas de Voz y Aplicaciones.</i> " Director: Lleida Solano, E. Tesis doctoral inédita. Universitat Politècnica de Catalunya, Departament de Teoria del Senyal i Comunicacions, Davaslana, 2 de Disignifica de 1007
[Nosal 2007]	Barcelona, 3 de Diciembre de 1997. Nosal,E.M.;" <i>Tracking Marine Mammals Using Passive Acoustics.</i> " Director: Frazer, L.N., Tesis para el grado de doctor en Filosofía (Geología y Geofísica). University of Hawai at Mānoa. Department of Ocean and Resources Engineering Diciembre de 2007
[Tsakalides 1995]	Tsakalides, P.;" Arrray Signal Processing with Alpha- Stable Distributions," Faculty of the Graduate School University of Southern California, Thesis for the Degree Doctor of Philosophy (Electrical Engineering), december 1995.
[Villares-Piera 1997]	Villares-Piera,J.;"Sample Covariance Based Parameter Estimatin For Digital Communications." Director: Vázquez Grau, G. Tesis doctoral inédita. Universitat Politécnia de Catalunya, Departament de Teoría de la Senyal i Comunications, Barcelona, 1de Octubre de 2005.

### 4. Informes de Proyectos

[Navarro-Mesa 2009a]	Navarro-Mesa, J.L.; Hernández-Pérez, E.; "Final
	$\mu SWN$ prototype for deployment in real
	scenario(Annex C. Multi-Tracking In-Mote Agents V3:
	Description And Implications)". Proyecto de
	Investigación Solving Major Problems in
	MicroSensorial Wireless Networks -uSWN. ).
	Specific targeted research project.
	FP6/2005/IST/5/034642. Unión Europea. VI
	Programa Marco. Consorcio participado por la
	ULPGC y otros nueve socios de España, Lituania,
	Francia v Grecia. Documento confidencial del
	provecto, Ágosto, 2009.
[Navarro-Mesa 2009b]	Navarro-Mesa, J.L.: Hernández-Pérez.E.: Sánchez-
	Rodríguez D.: "Material Delivery for Multitracking
	Demonstrator(Multitarcking Application –
	Installation and configuration guide)" Provecto de
	Investigación Solving Major Problems in
	MicroSensorial Wireless Networks –uSWN. ).
	Specific targeted research project.
	FP6/2005/IST/5/034642. Unión Europea. VI
	Programa Marco. Consorcio participado por la
	ULPGC y otros nueve socios de España. Lituania.
	Francia v Grecia. Documento confidencial del
	provecto Agosto 2009
[uSWN D8 2008]	uSWN D8 :" Analysis of WSN Deployment
[]	Methodologies ()." Solving Major Problems in
	MicroSensorial Wireless Networks (uSWN) Specific
	targeted research project FP6/2005/IST/5/034642
	Unión Europea VI Programa Marco Consorcio
	narticinado nor la ULPGC y otros nueve socios de
	Esnaña Lituania Francia y Grecia Este documento
	es accesible núblicamente a través del enlace (fecha
	del <u>viltimo</u> acceso $03/05/2010$ ):
	https://www.uswn.eu/i/component/ontion.com_remosi
	tory/Itemid 28/func select/id 5/lang en/ Enero 2008
	101 yr trennu, 20/1010, select/10, 0/1011g, ell/. Eller0, 2000.

#### 5. Documentos Electrónicos en Internet

[AMI 2007] AMI Project (Augmented Multi-party Interaction with Distance Access);"2007 Technical report:State-of-the-art overview-Localization and Tracking of Multiple Interlocutors with Multiple Sensors." http://www.amiproject.org /ami-scientific-portal/documentation, actualizada 2 de mayo de 2008, consultada en diciembre de 2010.

[Basaran 2006]	Basaran, C.; " <i>Critical evaluation of platforms commonly used in embedded wisents research</i> ", http://www.embedded-wisents.org/studies/wisents/download/survey.pdf,
[Benthos 2008]	Junio 2006, consultada el 3 de Enero de 2010. Teledyne Benthos Inc.," <i>Hydrophones_PC.pdf,</i> "http://www.benthos.com/pdf/Hydrophones_PC.pdf,
[CeTIC 2009]	CeTIC ; "Centro Tecnológico para la Innovación en Comunicaciones." http://www.cetic.eu, actualizada 2009, conquitada al. 01.02.2010
[Col 2009]	J. Col, "Zoom Whales", http://www.enchantedlearning.com/subjects/whales/species/S permwhale.shtml, actualizada en 2009, consultada el 9/09/2009
[Crossbow 2009]	Crossbow Technology," <i>TelosB_Datasheet</i> ," http://www.xbow.com/Products/Product_pdf_files/Wireless_p df/TelosB_Datasheet.pdf, actualizada 2009, consultada el 27
[IDeTIC 2010]	de octubre de 2009. IDeTIC ; "Instituto Universitario para el Desarrollo Tecnológico y la Innovación en Comunicaciones" http://www.idetic.eu, actualizada 2010, consultada el 01-04-
[Jefferson 2006]	2010. Jefferson,T.A.;Leatherwood,S.;Webber,M.A.;" <i>Marines</i> <i>Mammals of the World.World Biodiversity Database.</i> " http://nlbif.eti.uva.nl/bis/marine_mammals.php World Biodiversity Database_creada el 26 de Junio 2006
[Krim 1995]	consultada el 10 de enero de 2010. Krim, H.;Viberg, M.;" <i>Sensor Array Signal Processing: Two</i> <i>Decades Later.</i> " http://dspace.mit.edu/bitstream/handle/1721.1/3398/P-2282-
[LAB 2009]	31904/53.pdf?sequence=1, actualizada en enero de 1995, consultada en diciembre de 2010. Laboratory d'Aplicacions Bioacústiques, "Sons de Mar. Cetacis Destacats: Catxalot;" http://www.sonsdemar.eu/sonsdemar.php, consultada 20 de
[Madsen 2001]	octubre de 2009. Madsen,P.T.;Johnson,G.;" <i>How Do Sperm Whales Produce</i> <i>Sound?</i> " http://www.pbs.org/odyssey/odyssey /20010809_log_transcript.html, August 9, 2001, consultada
[Nuevo 2004]	12 diciembre de 2009. Nuevo, J.;" <i>A Comprehensible GloMoSim Tutorial.pdf</i> ", http://www.comp.nus.edu.sg/~tanhweex/research/Guide%20t o%20GloMoSim.pdf,
[OPNET 2010]	March 4, 2004, consultada 8 de Enero de 2010. OPNET Technologies, Inc.;" <i>Application and Network</i> <i>Performance</i> ",http://www.opnet.com/index.html, 2010, consultada 8 de Enero de 2010.

[Pedersen 2008]	Petersen, K.B.; Pedersen, M.S.;" <i>The Matrix Cookbook</i> ." www2.imm.dtu.dk/pubdb/views/edoc_download/imm3274.p
	df, revisión 14 de noviembre de 2008, consultada en octubre de 2009.
[Reid 2003]	Reid, J.B.; Evans, P.G.H.; Northridge, S.P.; "Atlas of
L J	Cetacean distribution in north-west European waters",
	http://www.jncc.gov.uk/page-2713, actualizada 2003,
	consulta 01-01-2010.
[Simon 2009]	Simon,D.; "Kalman Filtering,"
	http://www.innovatia.com/software/papers/kalman.htm,
	última revisión 2 de abril de 2009, consultada en Julio 2009.
[Texas 2007]	Texas Instruments Incorporated, "2.4 GHz IEEE 802.15.4 /
	ZigBee-Ready RF Transceiver (Rev. B)",
	http://focus.ti.com/docs/prod/folders/print/cc2420.html,
	actualizada 30 de marzo de 2007, consultada el 20 de octubre de 2009.
[Welch 2001]	Welch, G.: Bishop, G.: "An Introduction to the Kalman
	Filter."
	http://www.cs.unc.edu/~tracker/media/pdf/SIGGRAPH2001
	CoursePack 08.pdf. Thu, Aug 30, 2001, consultada 7 de
	enero de 2010.
[Wikimedia 2009]	Wikimedia Commons:"Cetacean distribution maps."
[]	http://commons.wikimedia.org/wiki/Category:Cetacean_distr
	ibution_maps, last modified on 31 August 2009, consulta 01- 01-2010

# Índice de Figuras

Figura	1.0.1	Diagrama de Bloques de un Sistema de Detección,	
		Localización, Identificación y Seguimiento.	2
Figura	1.1.1	Modelo de un Sistema para ASP.	6
Figura	1.1.2	Modelo de un sistema distribuido.	$\overline{7}$
Figura	1.1.3	Secuencia de Procesos en un Algoritmo de Seguimiento	0
Figura	1.1.4	generico. Flujo de proceso de detección, clasificación e	9
		identificación.	11
Figura	2.1.1	Pérdidas en el Trayecto para la propagación de una	
		onda esférica de 1kHz (a) y 10 kHz (b).	22
Figura	2.1.2	Perfil de Velocidad encontrado en Latitud 28°4' Norte y Longitud 15° 16' Oeste, zona situada a unas 34 millas	
		al norte de Gran Canaria (Islas Canarias, España).	24
Figura	2.1.3	Diagramas de rayos para un perfil de velocidad como el de la Figura 2.1.2 con fuente emisora de ondas	
		acústicas a profundidades de 100 metros (a) v 700	
		metros (b).	25
Figura	2.1.4	Diagramas de rayos para un perfil de velocidad como el de la Figura 2.1.2, con fuente emisora de ondas acústicas a profundidades de 1200 metros (a) y 2000	0.0
<b>T</b> :	015	metros (0). Distribución concertant del Davide de Frande	26
rigura	2.1.0	Permanente en el medio marino (adaptado de [Urick 1983]).	28

Figura	2.1.6	Efecto de los niveles reverberantes y nivel de ruido en la propagación de señales submarinas	30
Figura	2.1.7	Escenario para el estudio de la reflexión superficial (a)	50
Figura	2.1.8	Interferencia [Urick 1983] para dicho escenario (b). Ejemplo de propagación multitrayecto donde observamos los trayectos principales considerando reflexiones de hasta segundo orden. Observamos Trayecto Directo (TD), Trayecto Superficie (TS),	31
		Trayecto Fondo(TF), Trayecto Superficie Fondo (TSF) y Trayecto Fondo Superficie (TFS).	33
Figura	2.1.9	Escenario considerado para los resultados expuestos en las figuras 2.10 y 2.11.	33
Figura	2.1.10	Señales emitidas y recibidas en el escenario de la	94
Figura	2.1.11	Señales emitidas y recibidas en el escenario de la	54
Figura	2.1.12	Figura 2.1.9 para pulso de 2 ms de duración. Escenario Doppler considerado para la derivación de las expresiones Ec.2.1.19. Ec.2.1.20 v Ec.2.1.21.	35 36
Figura	2.2.1	Ondas que van desde emisor a receptor por reflexión,	00
Figura	2.2.2	difraccion y dispersion. Reflexión de una onda electromagnética de polarización circular.	38 40
Figura	2.2.3	Coeficiente de reflexión en función del material que integra al reflector, ángulo de incidencia y polarización de la onda respecto del plano de la superficie reflectante	40
Figura	2.2.4	Base esquemática del modelo "knife-edge" para estimar la atenuación por difracción en situaciones asimilables al esquema representado. T representa al punto de emisión y R al de recepción.	41
Figura	2.2.5	Figura de ruido en función de la frecuencia y origen para T0=290°K (adaptada de [McPherson 1979])	13
Figura	2.2.6	Absorción atmosférica en función de la frecuencia debida a la molécula de oxígeno y al vapor de agua (adaptada da [MaPharaon 1970])	10
Figuro	997		40
Figura	4.4.1 0 0 0	Modelo generico de canal inalambrico.	40
rigura	2.2.8	Parametros geometricos del modelo de dos rayos. En	
Figura	2.2.9	receptor montado en la verja de la ventana. Resultado de las medidas de pérdidas por propagación en función de la distancia en un área suburbana con antena emisora a 25 m e altura y receptora móvil a 2	47
Figura	2.2.10	de regresión de los datos (adaptado de [Erceg 1999]). Variación de la constante de atenuación en función de la altura de la antena emisora y el tipo de terreno	51
		(adaptado de [Erceg 1999]).	53

Figura	2.2.11	Diagrama de bloques de las funciones de ensanchado y modulación de la capa física del IEEE 802.15.4 para la	
Figura	2.2.12	Frecuencias centrales, ancho de banda y canales en el estándar IEEE 802.15.4 en la banda de 2.450 MHz	00 55
Figura	2.2.13	Diagrama de bloques simplificado del CC2420 (adaptado de [Texas 2007])	56
Figura	2.2.14	Espectro modulado del CC2420 [Texas 2007].	56
Figura	2.3.1	Hidrófono AQ-4 (a) y módulo preamplificador AQ-302 (b) [Benthos 2008].	60
Figura	2.3.2	Array lineal de dos hidrófonos. El array está dotado de una fuente sonora para calibración del sistema.	60
Figura	2.3.3	Diagrama de bloques general de un nodo inalámbrico.	61
Figura	2.3.4	Identificación física de los dispositivos integrados en la cara frontal del Módulo Inalámbrico Telos B.	62
Figura	2.3.5	Identificación física de los dispositivos integrados en la cara trasera del Módulo Inalámbrico Telos B.	62
Figura	2.3.6	Diagrama de bloques simplificado del demodulador del CC2420, adaptado de [Texas 2007].	64
Figura	2.3.7	Valores RSSI típicos en función de la potencia de entrada, adaptado de [Texas 2007].	64
Figura	2.3.8	Diagramas de radiación del Telos B con montaje horizontal (a) y vertical (b), adaptado de [Texas 2007].	65
Figura	2.4.1	Agrupación Lineal Uniforme (ULA, Uniform Lineal Array) de M sensores, fuente de ondas esféricas a distancia  r  incidiendo desde la dirección (f,q) y ecuaciones para traslación de coordenadas esféricas a	
-	2 4 2	rectangulares.	68
Figura	2.4.2	Ancho de haz en función de la dirección de apuntamiento (yo) y del número de sensores en una agrupación lineal (a). Relación entre lóbulo principal y secundario, agrupación de 2 sensores (trazo continuo) y de 4 sensores (trazo discontinuo) separación de media	
		longitud de onda (b).	70
Figura	2.4.3	Agrupación lineal sobre la que inciden tres fuentes, las fuentes a y c son distinguibles, mientras que las a y b son indistinguibles al igual que todas aquellas otras	
Figura	2.4.4	que estén sobre la superficie del cono. Agrupación plana rectangular (UPA, Uniform Planar Array) (a) y plana circular (UCA, Uniform Circular	72
		Array) (b).	75
Figura	2.4.5	Ilustración Espacial del Diagrama de Directividad de una UPA.	76
Figura	2.4.6	Ancho de haz y atenuación de lóbulos secundarios en	= 0
Figure	917	una agrupacion plana rectangular.	'76
гigura	2.4.1	Ejemplo de agrupación cilindrica.	80

Figura	2.4.8	Ejemplo de agrupación esférica.	81
Figura	2.5.1	Ejemplo de localización basada en medidas de	
		distancia.	86
Figura	2.5.2	Ejemplo de seguimiento con agentes móviles.	87
Figura	2.5.3	Ejemplo de topología Plana o en Malla.	90
Figura	2.5.4	Ejemplo de Organización Jerárquica o en Árbol.	90
Figura	2.5.5	Ejemplo de Organización Jerárquica en Columna	
_		Vertebral.	91
Figura	2.5.6	Topología Grupos Jerarquizados.	91
Figura	2.5.7	Topología de Grupos o Cluster.	92
Figura	3.2.1	Diagrama de bloques del Sistema de Propagación	
		Submarina Cetus3D.	98
Figura	3.2.2	Formas de operación: Fuente Activa a Boya con	
		Agrupación (a) y Fuente Activa a Fuente Pasiva y desde	
		ahí a Boya con Agrupación (b).	99
Figura	3.3.1	Esquema de un algoritmo de detección por umbrales.	103
Figura	3.3.2	Comportamiento de la función de energía y de los	
		umbrales.	106
Figura	3.3.3	Agrupación lineal de M sensores frente a una onda	100
т.	0.0.4	plana incidente desde la dirección $\theta$ .	109
Figura	3.3.4	Ilustracion de una hipotetica distribucion de niveles de	
		los autovalores para un escenario con 3 fuentes	111
Figure	995	inmersas en ruido y una agrupación de 8 sensores.	111
rigura	9.9.9	Expression grafica del concepio de centrado o	
		espacio con la dirección original de cada fuente, aunque	
		todas a una misma frecuencia central $\omega_{c}$	120
Figura	3.3.6	Interpretación gráfica del término agrupación	120
9		extendida.	130
Figura	3.4.1	Escenario con parámetros del seguimiento para la	
0		fuente k-ésima.	135
Figura	3.5.1	Estructura simplificada de la cabeza de un cachalote	
		(a), hipótesis del recorrido de la excitación sonora en la	
		cabeza del cachalote (b) y modelo de tubos para	
		explicar el espectro clásico de un clic (c) propuestos en	
		[Hernández-Pérez 2003].	146
Figura	3.5.2	Espectro de un clic de cachalote.	148
Figura	3.5.3	Modelado espectral de un clic de cachalote empleando	
		las metodologías MYWE TSLS (a) y reconstrucción de $\tilde{a}$	1.40
Б.	0 <b>F</b> 4	la senal mediante MYWE (b).	149
Figura	3.5.4	Esquema de Bloques de un Sistema de Detección,	1 = 0
<b>T</b> : .	9 <b>F F</b>	Localizacion, Identificacion y Seguimiento de Señales.	170
rıgura	3.9.9	Diagrama de Flujo del Algoritmo conjunto de	
Б.	0 <b>F</b> 0	localizacion, identificación y seguimiento en Modo 1.	173
Figura	3.5.6	Diagrama de Flujo del Algoritmo conjunto de	- <b>-</b> -
		localización, identificación y seguimiento en Modo 2.	173

Figura	3.5.7	Diagrama de Flujo detallado de la etapa de Seguimiento	175
Figura	3.6.1	Seguimiento. Error cuadrático medio de reconstrucción, MSE, para	179
		los metodos MYWE, basado en las ecuaciones	100
Figure	969	modificadas de Yule Wlaker, y ISLS.	177
гigura	3.0.2	Influencia de los ordenes AR y MA soore el error	170
Figure	969	Órdenes AB y MA para el valor mínimo entre 20 y 25	170
rigura	3.0.3	dB de mse para un conjunto de clics modelados con el	170
Figure	964	Melodo MIYWE. Órdenes AB y MA nang el valer mínime entre 25 y 40	179
rigura	3.0.4	dB de mse para un conjunto de clics modelados con el método TSLS	179
Figura	365	Representación de los tres primeros picos espectrales v	110
IIguiu	0.0.0	los polos de las funciones de transferencia obtenidas	
		mediante los métodos MYWE v TSLS para un conjunto	
		de clics	179
Figura	3.6.6	Representación de los tres primeros valles espectrales v	110
8		los ceros de las funciones de transferencia obtenidas	
		mediante los métodos MYWE v TSLS para un coniunto	
		de clics.	179
Figura	3.6.7	Diferencia entre la señal original y la sintética para un	
0		clic obtenida mediante el modelado por los métodos	
		MYWE y TSLS.	181
Figura	3.6.8	Modelado de creaks mediante los métodos MYWE y	
		TSLS. Presentación espectral y funciones de	
		transferencia (a), reconstrucción temporal de la señal	
		(b), ampliación de la reconstrucción de la señal (c) y	
		error de reconstrucción muestra a muestra (d).	181
Figura	3.6.9	Representación temporal del sonido denominado clang	
		o gunshot.	183
Figura	3.6.10	Modelado de gunshot mediante los métodos MYWE y TSLS. Presentación espectral y funciones de	
		transferencia (a), reconstrucción temporal de la señal	
		(b), ampliación de la reconstrucción de la señal (c) y	100
т.	0 0 1 1	error de reconstrucción muestra a muestra (d).	183
Figura	3.6.11	Estudio del error de reconstruccion para un conjunto de	
		circs modelados con $ARMA(p,q)$ para amoos metodos TELE MYNE ADMA(20.2) ( $\pi$ ) ADMA(20.20) ( $h$ )	
		I SLS Y I I W L. ARWA(20,2) (0), ARWA(20,20) (0), ADMA(10,10) (a) ADMA(2,2) (d) $ADMA(2,20) (a)$	105
Figure	2619	AMMA(10,10) (c), AMMA(2,2) (d) y AMMA(2,20) (e). Regultados para anda algoritmo en función de la DOA	100
Figura	5.0.12	AR(2) on (a) v $ARMA(2, 1)$ on (b)	186
Figure	3613	Comparativa de los mejores algoritmos en función de la	100
iguia	3.0.10	DOA.	187
Figura	3.6.14	Influencia del orden de los procesos AR v ARMA en la	-01
0 X		Exactitud y la Precisión. Dirección de incidencia fiia en	
		$10^{\circ}(a), 60^{\circ}(b) y 80^{\circ}(c).$	188

Figura	3.6.15	Comparativa en función de la DOA con órdenes	100
Figura	3.6.16	Influencia de la SNR en la exactitud y la precisión de	190
		los algoritmos. Dirección de incidencia fija en 10º.	
		Algoritmos AR y referentes (a) y algoritmos ARMA y	
		referentes (b).	191
Figura	3.6.17	Influencia de la SNR en la exactitud y la precisión de	
		los algoritmos. Dirección de incidencia fija en 60°.	
		Algoritmos AR y referentes (a) y algoritmos ARMA y	
		referentes (b).	192
Figura	3.6.18	Influencia de la SNR en la exactitud y la precisión de	
		los algoritmos. Dirección de incidencia fija en 80°.	
		Algoritmos AR y referentes (a) y algoritmos ARMA y	
		referentes (b).	193
Figura	3.6.19	Comparativa del tiempo de computación promedio para	
		un único clic.	193
Figura	3.6.20	Comparativa del tiempo de computación promedio en	
		función del orden del proceso respecto al algoritmo	
		STMV.	194
Figura	3.6.21	Comparativa de algoritmos DOA en función del número	
		de sensores.	195
Figura	3.6.22	Comportamiento en un escenario con 2 fuentes del	
		algoritmo STMV (a) y ARExtFast (b).	196
Figura	3.6.23	Comportamiento en un escenario con 2 fuentes del	
		algoritmo ARMAExtFast (a) y ARMAPol (b).	198
Figura	3.6.24	Comportamiento en un escenario con 2 fuentes del	
		algoritmo ARExtFast (a) y ARMAExtFast (b) para	
		$SNR \ de \ 10 \ dB.$	199
Figura	3.6.25	Comportamiento en un escenario con 2 fuentes del	
		algoritmo ARExtFast (a) y ARMAExtFast (b) para	
		$SNR \ de \ 5 \ dB.$	200
Figura	3.6.26	Comportamiento en un escenario con 2 fuentes del	
		algoritmo ARExtFast (a) y ARMAExtFast (b) para	
		$SNR \ de \ 0 \ \ dB.$	201
Figura	3.6.27	Comparativa para dos fuentes con distinta separación.	
		Medida de la Exactitud y la Precisión (a) y estimación	
		de la dirección de incidencia (b).	202
Figura	3.6.28	Comparativa para dos fuentes con distinta separación.	
		Medida de la Exactitud y la Precisión (a) y de la	
		dirección de incidencia (b).	203
Figura	3.6.29	Resultados para diferencia de niveles entre fuentes	
		igual a 10 dB. Algoritmos específicos de fuente	
т.	0.0.00	AKExtFast (a), ARMAExtFast (b) y ARMAPol (c).	205
Figura	3.6.30	Kesultados para diferencia de niveles entre fuentes	~~ <b>-</b>
<b>T</b> : .	0 0 01	iguai a 10 dB para el Algoritmo STMV.	207
rıgura	3.6.31	Esquema aei procesamiento realizado sobre las senales	
		ae las aos bases ae senales empleadas en los	000
		experimentos.	208

Figura	3.6.32	Resultados del agrupamiento entre clics de la base de señales de alta SNR, bloque S1 (a) y baja SNR bloque	200
Figura	3633	S2 (0). Popultado de la simulación del tenero emperimento	209
Figura	3.6.34	Resultado de la simulación del tercer experimento. Resultado del experimento con parejas seleccionadas aleatoriamente dentro del bloque de señales S2 sin	212
Figura	3.6.35	agrupamiento (a) y con agrupamiento (b). Trayectoria seguida por la fuente acústica (trazo rojo) y perfil del fondo marino (trazo azul).	213 214
Figura	3.6.36	Detalle del escenario simulado donde aparecen las dos agrupaciones contempladas y los modos de	015
Figura	3.6.37	propagación. Direcciones de incidencia para cada modo de propagación y posición de la fuente con la agrupación	215
Figura	3.6.38	desplegada horizontalmente. Resultados de Error y RMSE segmentado para cada modo de propagación. Agrupación con despliegue	215
		horizontal.	217
Figura	3.6.39	Direcciones de incidencia para cada modo de	
		propagación y posición de la fuente con la agrupación	
		desplegada verticalmente.	218
Figura	3.6.40	Resultados de Error y RMSE segmentado para cada	
		modo de propagación. Agrupación con despliegue vertical.	219
Figura	4.1.1	Vista esquemática del sistema de simulación LoTrackS- WSN.	224
Figura	4.1.2	Interfaz de usuario del simulador LoTrackS-WSN.	226
Figura	4.1.3	Escenario tal y como lo ve el usuario en la imagen de la izquierda e información esquemática para los algoritmos del modulo geométrico en el dibuio de la	
		derecha.	227
Figura	4.1.4	Niveles RSSI en cada nodo fijo, gráfica superior, y grupos de los cuatros primeros nodos activos	221
Figura	4.1.5	clasificados de mayor a menor nivel, gráfica inferior. Niveles reales recibidos en espacio libre en función de la distancia desde un nodo transmisor para una potencia de 0 dBm [Stovanova 2007] (a) y resultados obtenidos	228
Figura	4.1.6	en el simulador para la misma experiencia (b). Ejemplo de localización de nodo móvil. En (a) posiciones que ocupa y en (b) estimación de esas	229
Figura	4.1.7	posiciones mediante algoritmos de localización. Ejemplo de Seguimiento de nodo móvil. En (a) travectoria seguida y en (b) estimación de esa	231
		trayectoria mediante un algoritmo de seguimiento.	231
Figura	4.3.1	Ilustración del algoritmo RVI [Lee 2006].	240
Figura	4.3.2	Modelo esquemático del algoritmo LASM [Chen 2008].	241
Figura	4.4.1	Algoritmo del filtrado de Kalman.	250

Figura	4.4.2	Algoritmo del filtrado extendido de Kalman (EKF).	254
Figura	4.5.1	Escenario de los experimentos del apartado 4.5.1.	259
Figura	4.5.2	Distancias entre nodos fijos y posiciones del nodo móvil.	260
Figura	4.5.3	Error en la localización para distintos algoritmos con	
		ordenadas en escala lineal (a) y con ordenadas en	
		escala logarítmica (b).	261
Figura	4.5.4	Error de localización en función de la distancia con	
		variante en algoritmo LASM.	262
Figura	4.5.5	Error de localización para varios algoritmos con 5% de	
		error en las distancias.	263
Figura	4.5.6	Error de localización para varios algoritmos con 10% de	
<b>T</b> .		error en las distancias.	264
Figura	4.5.7	Error de localización para varios algoritmos con $20\%$ de	004
Figures	4 5 9	error en las alstancias.	264
Figura	4.9.8	Error de localización para varios algoritmos con 50% de	964
Figura	159	Pror en las distancias. Resultados de estimación de alfas (a) y la desviación	204
Figura	4.0.0	respecto del campo libre (b) mediante Método iterativo	
		de segundo orden. Escenario de un solo ravo reflejado	266
Figura	4.5.10	Resultados de estimación de alfas (a) y la desviación	-00
8		respecto del campo libre (b) mediante Método iterativo	
		de primer orden. Escenario de un solo rayo reflejado.	266
Figura	4.5.11	Resultados de estimación de alfas (a) y la desviación	
		respecto del campo libre (b) mediante Método iterativo	
		de primer orden. Escenario de dos rayos reflejados.	268
Figura	4.5.12	Resultados de estimación de alfas (a) y la desviación	
		respecto del campo libre (b) mediante Método iterativo	
		de segundo orden. Escenario de tres rayos reflejados.	268
Figura	4.5.13	Resultados de estimación de alfas (a) y la desviación	
		respecto del campo libre (b) mediante Método iterativo	200
<b>F</b> :	4 2 1 4	de segundo orden. Escenario de tres rayos reflejados.	269
Figura	4.0.14	Resultados de estimación de alfas (d) y la desolación	
		de primer orden Escenario de tres ravos reflejados	269
Figura	4 5 15	Resultados de estimación de alfas (a) y la desviación	200
I Iguiu	1.0.10	respecto del campo libre (b) mediante Método iterativo	
		de segundo orden. Error del 5% en la distancia.	270
Figura	4.5.16	Resultados de estimación de alfas (a) y la desviación	
U		respecto del campo libre (b) mediante Método iterativo	
		de segundo orden. Error del 10% en la distancia.	270
Figura	4.5.17	Resultados de estimación de alfas (a) y la desviación	
		respecto del campo libre (b) mediante Método iterativo	
		de segundo orden. Error del 20% en la distancia.	271
Figura	4.5.18	Resultados de estimación de alfas (a) y la desviación	
		respecto del campo libre (b) mediante Método iterativo	~
		de segundo orden. Error del 50% en la distancia.	271

Figura	4.5.19	Error en la localización con distancia estimada mediante medidas RSSI y estimación de la constante de	
		atenuación.	272
Figura	4.5.20	Error en la localización para distribución aleatoria del	
		nodo móvil para algoritmo BAR+Alfas (a) y	
<b>D</b> •		LASM+BAR+Alfas (b).	273
Figura	4.5.21	Escenario de simulacion en Versme Sanatorium (a la	
		uzquieraa), imagen extraiaa del simulador LorrackS- WSN Ampliación de la zona enmanada (a la devecha)	974
Figuro	1 5 99	WSN. Ampliación de la zona enmarcada (a la derecha). Errorea de la estima del errorimento de la Figura	214
rigura	4.0.44	A 5 91	276
Figura	4 5 23	Ventana emergente del simulador con información	210
inguiu	1.0.20	relativa a las potencias recibidas y a los grupos de	
		sensores intervinientes en la estimación.	276
Figura	4.5.24	Escenario de simulación en Versmé Sanatorium (a la	
U		izquierda), imagen extraída del simulador LoTrackS-	
		WSN. Ampliación de la zona enmarcada (a la derecha).	
		Experimento con nodos móviles alrededor de la fuente.	277
Figura	4.5.25	Errores de la estima del experimento de la Figura	
		4.5.24.	277
Figura	4.5.26	Nodos fijos que colaboran para cada evento Figura	
		4.5.24.	277
Figura	4.5.27	Geometria del despliegue de una WSN de 4 nodos fijos	~=~
Б.	4 5 90	y un nodo movil (vista real perspectiva).	278
Figura	4.5.28	Zona donae se realizo el despliegue de la Figura 4.5.27	
		con unicación de nodos fijos y nodo movil unicado en	979
Figuro	1 5 90	Datallas de instalación del nodo móvil (a) nodos fijos en	210
riguia	4.0.40	verias de las ventanas (h) v (c) v nodo fijo sobre poste de	
		alumbrado (d)	279
Figura	4.5.30	Localizaciones elegidas para las posiciones del nodo	2.0
8		móvil en el escenario de la Figura 4 5 28	280
Figura	4.5.31	Resultados de las estimaciones para el escenario de la	200
8		Figura 4.5.30.	281
Figura	4.5.32	Error y desviación en función de la separación entre	
		posición real y estimada para el escenario de la Figura	
		4.5.30.	281
Figura	4.5.33	Móvil en trayectoria cuasi circular y estimaciones de la	
		misma.	283
Figura	4.5.34	Error en función de la distancia a la localización real.	283
Figura	4.5.35	Escenario, trayectorias real y estimada, y distribución	
		de nodos fijos, para el experimento de trayecto "corto".	284
Figura	4.5.36	Errores en la estimación del trayecto "corto".	285
Figura	4.5.37	Distribución de niveles y grupos de 4 sensores que	
		actúan para cada posición para el experimento del	
		trayecto "corto".	285

Figura	4.5.38	Escenario, trayectorias real y estimada, y distribución	
		de nodos fijos, para el experimento de trayecto "largo".	286
Figura	4.5.39	Errores en la estimación del trayecto "corto".	286
Figura	4.5.40	Errores en la estimación del trayecto "corto".	286

## Índice de Tablas

Tabla	2.2.1	Bandas de frecuencia, modulaciones y tasas binarias del estándar IEEE 802.15.4 [IEEE 2006].	38
Tabla	2.2.2	Variación en dB del coeficiente de reflexión para rugosidad	49
Tabla	2.2.3	Relación de medidas técnicas para combatir el	42
Tabla	2.2.4	desvanecimiento segun el tipo de degradacion. Valores de la constante de atenuación (a) y la desviación estándar (s) para distintos entornos y frecuencias,	49
		adaptada de [Woerner 1995] y [Andersen 1995].	51
Tabla	2.3.1	Características del hidrófono AQ-4 [Benthos 2008].	60
Tabla	3.6.1	Probabilidades de acierto para el bloque de señales S1.	
Tabla	3.6.2	Probabilidades de acierto para el bloque de señales S2.	210 210
Tabla	3.6.3	Probabilidades de acierto con parejas de señales para el bloque de señales S1.	210
Tabla	3.6.4	Probabilidades de acierto con parejas de señales para el bloque de señales S2.	211
Tabla	3.6.5	Probabilidades de acierto con parejas de señales ambos bloques de señales.	211
Tabla	3.6.6	Probabilidades de acierto en la identificación con parejas de señales y ángulos de incidencia se asignación aleatoriamente, y error aleatorio en la estimación DOA de +5°	<b>2</b> 11 919
		±0.	414

Tabla	3.6.7	Valor RMSE en función del modo de propagación y el	
		algoritmo considerado. Agrupación con despliegue	
		horizontal.	218
Tabla	3.6.8	Valor RMSE en función del modo de propagación y el	
		algoritmo considerado. Agrupación con despliegue vertical.	220
Tabla	4.2.1	Tabla comparativa de métodos de estimación de distancia y	
		direcciones entre nodos para WSN.	234

## Lista de Acrónimos

ACI	- Adjacent-Channe Interference
ADC	- Analog Digital Converter
AEA	- Agrupación Extendida Autorregresiva
ANN	- Artificial Neural Network
AOA	- Angle Of Arrival
AR	- AutoRegressive
ARExt	- algorithm: AutoRegressive Extended
ARExtFast	- algorithm: AutoRegressive Extended Fast version
ARMA	- AutoRegressive Moving Average
ARMAExt	- algorithm: AutoRegressive Moving Average Extended
ARMAExtFast	- algorithm: AutoRegressive Moving Average Extended
	Fast version
ARMAPol	- algorithm: AutoRegressive Moving Average Pole
	descomposition
ASP	- Array Signal Processing
AWGN	- Additive White Gaussian Noise
BAR	- Algoritmo de Baricentros
CCI	- Co-Channel Interference
CCIR	- Comité Consultivo Internacinal de Radiocomunicaciones
CIBRA	- Centro Interdisciplinare di Bioacustica e Ricerche
	Ambientali

CPU	-	Central Processing Unit
CSDM	-	Cross Spectral Densisty Matrix
DAC	-	Digital Analog Converter
DEP	-	Densidad Espectral de Potencia
DFT	-	Discrete Fourier Transform
DML	-	Deterministic Maximum Likelihood
DOA	-	Direction Of Arrival
DSSS	-	Direct Sequence Spread Spectrum
DV-HOP	-	Distance Vector HOP
EKF	-	Extended Kalman Filtering
EM	-	ElectroMagnetic
FAPD	-	Friend Assisted Path Discovery
FFT	-	Fast Fourier Transform
FTDI	-	Future Technolgy Devices International
GIS	-	Geographic Information System
GPS	-	Global Positioning System
HMM	-	Hidden Markov Model
HOS	-	High Order Statistic
HW	-	HardWare
ICMV	-	InCoherent Minimum Variance
IEEE	-	Institute of Electrical and Electronics Engineers
IMAPS	-	Integrated Marine Mammal Monitoring and Protection
		System
ISI	-	InterSymbol Interference
ISM	-	Industrial Scientific and Medical
ITU	-	International Telecomunication Union
ITU-R	-	International Telecomunication Union-
		Radiocommunication sector
	-	Kalman Filter
	-	Localization Algorithm based on Spring Model
LASM+BAR	-	Algoritmo LASM comibinado con Baricentros
LASM+TRI	-	Algoritmo LASM comibinado con Multilateralizacion
	-	Left Circular Polarization
LUS	-	Line Of Sight
LOITACKS-WSN	-	Location and Tracking Simulator based on wireless
IOI	_	Link Quality Indicator
LQI LR-WPANs	-	Low Rate Wireless Personal Area Networks
LS	-	Low-Mate Wheless reisonal Area Networks
	_	Modia Access Control Lavor
MAP	-	Maximum A Posteriori
MATLAR	-	MATrixLABoratory
MCU	-	MicroController Unit
MFR	-	Most Forward with fixed Radius
		THOSE TO THAT A THILL HAVE THATAD

ML	-	Maximum Likelihood
ML/EM	-	Maximum Likelihood/Expectation Maximization
MLS	-	Minimum Least Square
MSE	-	Meam Squared Error
MUSIC	-	MUltiple SIgnal Classification
MV	-	Minimum Variance
MVR	-	Most forward with Variable Radius
MYWE	-	Modified Yule-Walker Equations
NFP	-	Nearest with Forward Progress
NL	-	Noise Level
NLOS	-	Non-Line Of Sight
OA	-	Optimization Agent
OEM	-	Onda ElectroMagnética
OQPSK	-	Offset Quadrature Phase Shift Keying
OSI	-	Open System Interconnection
PC	-	Personal Computer
PF	-	Particle Filtering
PHY	-	Physical Layer
PIFA	-	Planar Inverted-F Antenna
POS	-	Personal Operating Space
psu	-	Partical Salinity Unit
RAM	-	Random Access Memory
RCP	-	Right Circular Polarization
RF	-	Radio Frecuencia
RISC	-	Reduced Instruction Set Computer
RMSE	-	Root Mean Squared Error
RSSI	-	Receive Signal Strength Indication
RVI	-	Ratiometric Vector Iteration
RVI+BAR	-	Algoritmo RVI comibinado con Baricentros
RVI+TRI	-	Algoritmo RVI combinado con Multilateralización
RXFIFO	-	<b>Reception Firts Input Firts Output</b>
SFD	-	Start of Frame Delimiter
SIR	-	Signal-to-Interference Ratio
SIRENA	-	Service Infrastructure for Real time Embedded
<b><i><u>OBE</u></i></b>		Applications
SMA	-	SubMiniature version A
SML	-	Stochastic Maximum Likelihood
SNNR	-	Signal Plus Noise to Noise Ratio
SNR	-	Signal to Noise Ratio
SOLMAR	-	Sound, Oceanography and Living Marine Resources
SPI	-	Synchronous Peripheral Interface
SKMV	-	Spatially Resampled Minimum Variance
STCM	-	STeered Covariance Matrix
STMV	-	Steered Minimum Variance

SVD	-	Singular Value Decomposition
SW	-	SoftWare
TDMA	-	Time Division Multiple Access
TDOA	-	Time Difference Of Arrival
TL	-	Transmission Loss
ТОА	-	Time Of Arrival
TRI	-	Algoritmo de Multilateralización
TSLS	-	Two-Stage Least Squares
TXFIFO	-	Transmission Firts Input Firts Output
UCA	-	Uniform Circular Array
ULA	-	Uniform Lineal Array
UPA	-	Uniform Planar Array
USART	-	Universal Asynchronous Receiver-Transmitter
USB	-	Universal Serial Bus
WACS	-	Whale Anti-Collision System
WLAN	-	Wireless Local Area Network
WPANs	-	Wireless Personal Area Networks
WSN	-	Wireless Sensor Network