

UNIVERSIDAD POLITÉCNICA DE VALENCIA
Escuela Técnica Superior de Ingenieros de Telecomunicación

**ALGORITMOS DE DETECCIÓN
DISTRIBUIDA EN SISTEMAS
MONOSENSOR**



TESIS DOCTORAL

Presentada por:

Ignacio Bosch Roig

Dirigida por:

Luis Vergara Domínguez

Valencia, Septiembre 2005

Quiero dedicar esta tesis a mi director y agradecer su amistad y trabajo en equipo.

Han pasado muchos años desde el PFC y hemos compartido diversos proyectos, siempre formativos en los que he aprendido mucho técnicamente y lo más importante, me han enseñado a ser mejor persona.

Luis, gracias por todo, sin ti esta tesis no hubiera sido posible.

Por otro lado, quiero compartir estos agradecimientos con la persona que me ha dado la fuerza necesaria para darle sentido a la vida.

Gracias Désam por mantener mi energía vital y permitir que lo nuestro sea eterno.
Te quiere, Nacho.

Quiero agradecer de manera especial, el apoyo incondicional de mi familia, de mi padre y de mi madre, que me han dado la sólida base necesaria para poder caminar por la vida con fuerza y alegría.

Os quiero mucho, gracias por ser como sois aunque no siempre sepa agradecerlo.

A mis compañeros de trabajo y en especial a los del laboratorio, simplemente deciros que sin vosotros nada de esto hubiese podido realizarse.

Finalmente, gracias a todos por haber permitido que este sueño se haya podido realizar y espero seguir contando con todos vosotros para el resto de mi vida.

Gracias, un saludo, Nacho.

RESUMEN

La presente tesis aborda la elaboración de algoritmos de detección distribuida en sistemas monosensor. Tradicionalmente, la detección distribuida se ha aplicado a la fusión de decisiones tomadas por sensores espacialmente dispersos. No obstante, puede ser de utilidad en la implementación de detectores que tratan de explotar diferentes tipos de información sobre las diferencias existentes entre las dos hipótesis sobre las que decidir. El objetivo es sustituir un único detector complejo, cuando no inabordable, por una combinación de detectores más sencillos, implementables a partir de la teoría de detección óptima.

Frente a la posibilidad de un enfoque general, se ha preferido focalizar la tesis en dos aplicaciones de especial interés para el grupo de investigación, en cuyo seno se ha desarrollado esta tesis: detección de incendios forestales a partir de señales infrarrojas y detección de ecos en ruido de fondo granular, en ensayos no destructivos por ultrasonidos.

En cuanto a la detección de incendios forestales se ha propuesto un esquema de detección que fusiona dos tipos de detectores que hemos denominado detector de persistencia y detector de crecimiento. La idea subyacente es tratar de explotar la misma información que utiliza el propio vigilante humano, al que se trata de reemplazar. El detector de persistencia se basa a su vez en la fusión de decisiones correspondientes a pequeños intervalos de observación consecutivos. En cada intervalo se implementa un detector de filtro adaptado en subespacio que trata de explotar el comportamiento de persistencia en tiempo a corto plazo de un fuego, frente a otros efectos de carácter impulsivo que también pueden producir incrementos de temperatura esporádicos en la celda bajo vigilancia (coches, personas, sol,...). Por su parte el detector de crecimiento trata de explotar mediante un filtro adaptado a un crecimiento de tipo lineal, el esperado crecimiento en temperatura que, a medio y largo plazo, debe producir un fuego descontrolado, en comparación con fuegos controlados que podrían disparar indebidamente el sistema. El esquema diseñado permite ajustar la probabilidad de falsa alarma, consiguiendo buenas prestaciones de probabilidad de detección, como hemos demostrado con señales simuladas y reales.

En relación con la detección de ecos ultrasónicos en ruido de fondo granular hemos desarrollado un esquema que combina la filosofía subyacente en las denominadas técnicas "split-spectrum", con la detección distribuida. Las técnicas "split-spectrum" explotan la diversidad frecuencial implícitamente, comparando las respuestas a diferentes frecuencias de un eco de señal, frente a las respuestas del ruido granular. Las primeras deben ser mucho más estables y las segundas mucho más irregulares. El esquema propuesto consiste en colocar un detector "sintonizado" a cada banda frecuencial y fusionar posteriormente todas las detecciones. La sintonía en cada detector se realiza mediante un filtro adaptado a un subespacio "paso-banda". Hemos desarrollado todo el análisis requerido para ajustar la probabilidad de falsa alarma deseada, garantizando la maximización de la probabilidad de detección. Los experimentos con señales simuladas se han completado con experiencias de laboratorio en piezas de aluminio. Asimismo se han aplicado las técnicas propuestas en la determinación de los perfiles de

interfaces entre capas correspondientes a la bóveda de la Basílica de la Virgen de los Desamparados de Valencia, como apoyo en su restauración.

ABSTRACT

This thesis approaches the development of distributed detection algorithms in monosensor systems. Traditionally, the distributed detection has been applied to the decision fusion taken by space dispersed sensors. Nevertheless, it can be useful for the implementation of detectors that try to take advantage of the different types of information on the existing differences among the two hypotheses for taking decision. The objective is to substitute a unique complex detector, fairly unapproachable, for a combination of simpler detectors, to be implemented from the optimal decision theory.

On the contrary of a general approach, the thesis has been focused in two applications especially interesting for the research group, the detection of forest fires by means of infrared signals and the detection of echoes in granular noise, in non destructive evaluation by ultrasounds.

For the detection of forest fires, a detection scheme that fuses two types of detectors that we have denominated persistence detector and growth detector has been proposed. The underlying idea is to try to obtain the same information used by the watchman supposed to be replaced. The persistence detector is based on the decision fusion of small consecutive observing intervals. In each interval an adapted filter detector in subspace is implemented which tries to exploit the time persistence behaviour of the fire in short term; opposed to other impulsive effects which also can produce sporadic increments of temperature in the surveillance cell (cars, people, sun,...). On the other hand the growth detector tries to take advantage, by an adapted filter to lineal growth, the expected growth in temperature, in a middle and long term, that should produce an uncontrolled fire, compared to controlled fires that could trigger the system wrongly. The outlined scheme allows adjusting the probability of false alarm, obtaining good achievement of the detection probability, as we have demonstrated with simulated and real signals.

Regarding with the detection of ultrasonic echoes in granular noise, we have developed a scheme that combines the underlying philosophy of the called "split-spectrum" with the distributed detection. The "split-spectrum" techniques exploit implicitly the frequency diversity, comparing the answers of a signal echo at different frequencies with the answers of the granular noise. The first ones should be much more stable and the seconds much more irregular. The proposed scheme consists on placing a detector "tuned" to each frequency band and then to fuse all the detections. The tuning in each detector is carried out by a filter adapted to a "band-pass" subspace. We have developed the whole analysis required to adjust the wanted false alarm probability, guaranteeing the detection probability maximization. Results from simulated signals and experiments with laboratory specimens of aluminium pieces have been obtained. In addition, we have applied the techniques proposed here, in the determination of the interface profiles between layers corresponding to the "*Cúpula de la Basílica de la Virgen de los Desamparados de Valencia*", as a support in their restoration.

RESÚM

La present tesi aborda l'elaboració d'algoritmes de detecció distribuïda en sistemes monosensor. Tradicionalment, la detecció distribuïda s'ha aplicat a la fusió de decisions preses per sensors espacialment dispersos. No obstant, pot ser d'utilitat en l'implementació de detectors que tracten d'explotar diferents tipus d'informació sobre les diferències existents entre les dues hipòtesis sobre les quals decidir. L'objectiu és substituir un únic detector complex, si no inabordable per una combinació de detectors més senzills, implementables a partir de la teoria de detecció òptima.

Dabant de la possibilitat d'un enfocament general, s'ha preferit focalitzar la tesi en dues aplicacions d'especial interès per al grup d'investigació, en el interior del qual s'ha desenvolupat aquesta tesi: detecció d'incendis forestals a partir de senyals infrarojos i detecció de ressons en soroll de fons granular, en assajos no destructius per ultrasons.

Quant a la detecció d'incendis forestals s'ha proposat un esquema de detecció que fusiona dos tipus de detectors que hem denominat detector de persistència i detector de creixement. La idea subjacent és tractar d'explotar la mateixa informació que utilitza el propi vigilant humà, a què es tracta de reemplaçar. El detector de persistència es basa al seu torn en la fusió de decisions corresponents a xicotets intervals d'observació consecutius. En cada interval s'implementa un detector de filtre adaptat en subespai que tracta d'aprofitar el comportament de persistència en temps a curt termini d'un foc, enfront d'altres efectes de caràcter impulsu que també poden produir increments de temperatura esporàdics en la cel·la baix vigilància (cotxes, persones, sol,...). Per la seua banda el detector de creixement tracta d'aprofitar mitjançant un filtre adaptat a un creixement de tipus lineal, l'esperat creixement en temperatura que, a mitjà i llarg termini, ha de produir un foc descontrolat, en comparació amb focs controlats que podrien disparar indegudament el sistema. L'esquema dissenyat permet ajustar la probabilitat de falsa alarma, aconseguint bones prestacions de probabilitat de detecció, com hem demostrat amb senyals simulats i reals.

En relació amb la detecció de ressons ultrasònics en soroll de fons granular hem desenvolupat un esquema que combina la filosofia subjacent en les denominades tècniques "split-spectrum", amb la detecció distribuïda. Les tècniques "split-spectrum" exploten la diversitat freqüencial implícitament, comparant la respostes a diferents freqüències d'un ressò de senyal, enfront de les respostes del soroll granular. Les primeres han de ser molt més estables i les segones molt més irregulars. L'esquema proposat consisteix a col·locar un detector "sintonitzat" a cada banda freqüencial i fusionar posteriorment totes les deteccions. La sintonia en cada detector es realitza mitjançant un filtre adaptat a un subespai "pas-banda". Hem desenvolupat tota l'anàlisi requerida per a ajustar la probabilitat de falsa alarma desitjada, garantint la maximització de la probabilitat de detecció. Els experiments amb senyals simulats s'han completat amb experiències de laboratori en peces d'alumini. Així mateix s'han aplicat les tècniques proposades en la determinació dels perfils d'interfases entre capes corresponents a la volta de la Basílica de la Mare de Déu dels Desemparats (València), com a suport en la seua restauració.

Índice General:

Capítulo 1: Introducción.....	3
1.1 Detección distribuida monosensor.....	3
1.2 Contexto de la tesis.....	5
1.3 Fusión de decisiones.....	6
1.4 Plan de la tesis.....	7
Capítulo 2: Fusión de decisiones.....	13
2.1 Introducción.....	13
2.2 El modelo general de la fusión de datos.....	15
2.2.1 Aplicaciones de la fusión de datos.....	18
2.2.2 Arquitecturas de la fusión de datos.....	18
2.2.2.1 Fusión de información local.....	19
2.2.2.2 Fusión de datos paramétricos o de identidad.....	21
2.3 Fundamentos de detección distribuida con sensores múltiples.....	23
2.3.1 Introducción.....	23
2.3.2 Formulación de Neyman-Pearson.....	23
2.3.2.1 Configuración en Paralelo.....	24
2.3.2.2 Configuración en Serie.....	25
2.3.3 Formulación Bayesiana.....	26
2.3.3.1 Configuración en Paralelo.....	26
2.3.3.2 Configuración en Serie.....	28
2.3.3.3 Configuraciones más generales.....	29
2.3.4 Temas avanzados en la detección distribuida con sensores múltiples.....	30
2.3.4.1 Introducción.....	30
2.3.4.2 Detección localmente óptima de señales distribuidas.....	31
2.3.4.3 Detección distribuida no paramétrica y con ratio de falsa alarma constante.....	32
2.3.4.4 Esquemas no paramétricos de detección distribuida.....	32
2.3.4.5 Detección distribuida robusta.....	33
2.3.4.6 Métodos secuenciales en detección distribuida.....	34
2.4 Detección distribuida y fusión de decisiones óptima.....	38
2.4.1 Fusión óptima en sistemas de detección con múltiples sensores incorrelados.....	38
2.4.2 Detección distribuida con decisiones correladas.....	40
2.4.2.1 Caso general y estrategias de fusión.....	40
2.4.2.2 Fusión óptima conocidas las reglas de decisión y las correlaciones locales, según el criterio de Neyman- Pearson.....	42
2.4.2.3 Generalización de la detección óptima incorrelada en función de los coeficientes de correlación condicional, bajo el criterio Bayesiano.....	47

2.4.2.4	Funcionamiento asintótico de los sistemas de detección distribuida bajo ruido gaussiano correlado, bajo el criterio Bayesiano.	49
2.4.2.5	Detección distribuida óptima bajo el criterio de Neyman-Pearson en sistemas correlados.	53
2.4.2.6	Cuantización binaria óptima bayesiana bajo ruido gaussiano correlado.	59
2.4.2.7	Acercamiento Bayesiano a la fusión de decisiones utilizando modelos jerárquicos.	65
2.5	Conclusiones	70
2.5.1	Síntesis del capítulo	70
2.5.2	Conclusiones finales	72
Capítulo 3: Aplicación a Sistemas de detección de Incendios.		77
3.1	Contexto	77
3.2	Antecedentes	78
3.3	Investigaciones	79
3.4	Sistema global	80
3.5	Subsistema de tratamiento de señal	82
3.6	Estudios previos	85
3.7	Aplicación de la fusión de decisiones monosensor a sistemas de detección de incendios.	88
3.7.1	Detectores de persistencia y crecimiento	88
3.7.2	Esquema general del sistema de procesado con fusión de decisiones	91
3.7.3	Fusión de decisiones aplicada al detector de persistencia	92
3.7.4	Fusión de decisiones aplicada a la decisión final	96
3.8	Comprobación de resultados mediante simulaciones	100
3.8.1	Generación de curvas de PFA_p y PD_p del detector fusionado de persistencia	100
3.8.1.1	Obtención de curvas de PFA_p en función de los parámetros: nu , L y PFA_0	100
3.8.1.2	Obtención de curvas de PD_p en función de los parámetros: nu , L , PFA_0 , SNR y $crec$	102
3.8.2	Generación de curvas de PFA_i y PD_i del detector de crecimiento	105
3.8.2.1	Obtención de curvas de PFA_i en función de los parámetros: L y PFA_t	105
3.8.2.2	Obtención de curvas de PD_i en función de los parámetros: L , PFA_t , SNR y $crec$	106
3.8.3	Generación de curvas de PFA_T y PD_T globales como fusión del detector fusionado de persistencia y del detector de crecimiento	108
3.8.3.1	Obtención de curvas de PFA_T en función de los parámetros: L y PFA_0 ó PFA_t	108
3.8.3.2	Obtención de curvas de PD_i en función de los parámetros: L , PFA , SNR y $crec$	111

3.9	Comprobación de resultados con experiencias reales	118
3.9.1	El sistema DISTER.....	118
3.9.2	Experiencias destacables del funcionamiento del sistema DISTER.....	122
3.9.2.1	Pruebas con fuegos reales	123
3.9.2.2	Ejemplos de detección. Casos reales con intervención.....	126
3.9.2.3	Evaluación de datos de funcionamiento del sistema	127
3.10	Conclusiones.....	134
3.10.1	Síntesis del capítulo.....	134
3.10.2	Conclusiones finales.....	136
Capítulo 4: Aplicación a sistemas de inspección ultrasónica		143
4.1	Contexto.....	143
4.2	Introducción	143
4.3	Modelo vectorial de ruido de grano.....	148
4.4	Algoritmos de split-spectrum basados en detección distribuida	154
4.4.1	Esquema propuesto.....	154
4.4.2	La regla de decisión.....	157
4.4.3	Competiendo con el detector trivial.	163
4.5	Experimentos con señales simuladas	167
4.5.1	Control de la <i>PFA</i>	167
4.5.2	Análisis de la detección.....	171
4.5.3	DetECCIÓN con señales simuladas.....	172
4.5.3.1	DetECCIÓN con señales simuladas y pulso buscado con sinc simulada	172
4.5.3.2	DetECCIÓN con señales simuladas y pulso buscado real ultrasónico.....	176
4.5.3.3	Prueba de detección del <i>NSSDD</i> con pulso sinc.	180
4.5.3.4	Verificación de la Probabilidad de Detección con señales simuladas y pulso buscado sinc, para distintas <i>SNR</i>	185
4.5.3.5	Verificación de la Probabilidad de Detección con señales simuladas y pulso buscado real ultrasónico, para distintas <i>SNR</i>	190
4.6	Aplicación a señales ultrasónicas reales bajo control de laboratorio	196
4.6.1	Resultados obtenidos en el duraluminio con el algoritmo trivial.....	199
4.6.2	Resultados obtenidos en el duraluminio con el algoritmo <i>SSDD</i>	201
4.6.3	Resultados obtenidos en el duraluminio con el algoritmo <i>NSSDD</i>	202
4.7	Aplicación de los ensayos no destructivos de materiales con ultrasonidos a la restauración de edificios históricos.....	204
4.7.1	Descripción del entorno de trabajo en la Real Basílica de la Virgen de los Desamparados de Valencia.	204

4.7.2 Resultados obtenidos en la Real Basílica de la Virgen de los Desamparados.	210
4.7.2.1 Utilizando el algoritmo trivial	211
4.7.2.2 Utilizando el algoritmo <i>SSDD</i>	213
4.7.2.3 Utilizando el algoritmo <i>NSSDD</i>	214
4.7.3 Resultados obtenidos en el modelo a escala de la Real Basílica de la Virgen de los Desamparados.	216
4.7.3.1 Resultados utilizando el algoritmo trivial.....	219
4.7.3.2 Resultados utilizando el algoritmo <i>SSDD</i>	220
4.7.3.3 Resultados utilizando el algoritmo <i>NSSDD</i>	221
4.8 Conclusiones	224
4.8.1 Síntesis del capítulo	224
4.8.2 Conclusiones finales.....	227
Apéndices.....	229
Apéndice A.....	229
Apéndice B.....	230
Apéndice C	231
Capítulo 5: Conclusiones y líneas futuras de investigación.....	237
5.1 Conclusiones por capítulos.....	237
5.1.1 Fusión de decisiones	237
Conclusiones finales.....	238
5.1.2 Aplicación de incendios.....	238
Conclusiones finales.....	239
5.1.3 Aplicación a detección ultrasónica.....	241
Conclusiones finales.....	243
5.2 Conclusión general	244
5.3 Líneas futuras	245
Bibliografía	251
Publicaciones y patentes relacionadas	256
Publicaciones en revistas	256
Publicaciones en congresos	256
Internacionales.....	256
Nacionales	257
Patentes.....	258
Índice de Figuras:	259
Índice de Tablas.....	264

CAPÍTULO 1: INTRODUCCIÓN



Capítulo 1: Introducción

1.1 Detección distribuida monosensor

La detección automática es un ámbito clásico en el tratamiento estadístico de señales [1],[2],[3],[4], existiendo soluciones óptimas para una amplia gama de situaciones. Los algoritmos de detección automática son requeridos frecuentemente en numerosas aplicaciones como radar, sonar, comunicaciones, ultrasonidos,...

Una extensión de la detección automática es la detección automática distribuida, o equivalentemente, la fusión de decisiones [5], [6], [7], [8]. La detección distribuida aparece normalmente en sistemas multisensor, en los que los sensores se encuentran separados espacialmente, debiendo cada uno de ellos generar una decisión sobre el fenómeno observado, que debe ser transmitida a un procesador central que procederá a fusionar las decisiones recibidas para generar la decisión final (Figura 1). La detección distribuida permite el ahorro de recursos de comunicación entre cada sensor y el procesador central, al transmitirse únicamente la decisión local y no las medidas u observaciones que han llevado a ésta.

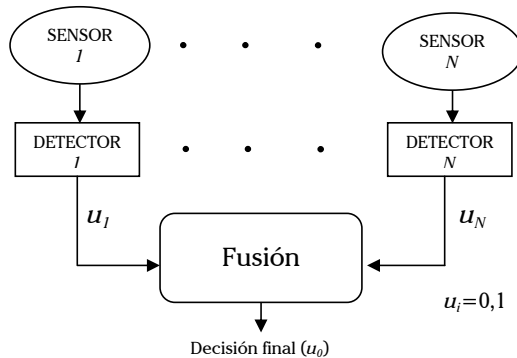


Figura 1. Arquitectura básica de detección distribuida multisensor.

Menos explorada está la posibilidad de aplicar detección distribuida en sistemas con un único sensor, si bien está implícita en numerosas aplicaciones tales como la detección automática a partir de información tiempo-frecuencia [9], o el tratamiento de imágenes binarizadas [10].

La detección distribuida en sistemas monosensor consiste en aplicar diferentes detectores a las observaciones captadas en un sensor, sobre las que tenemos que tomar una decisión, y fusionar las decisiones correspondientes para tomar la decisión final (Figura 2). En general, cada detector actúa sobre un vector \mathbf{z}_i , obtenido mediante el preprocesado adecuado, a partir del vector de observaciones \mathbf{x} . La justificación subyacente en la arquitectura distribuida de la Figura 2, es la

posible sencillez del diseño optimizado de cada uno de los detectores, y de la regla de fusión, frente a la complejidad o imposibilidad de acometer el diseño optimizado de un detector único.

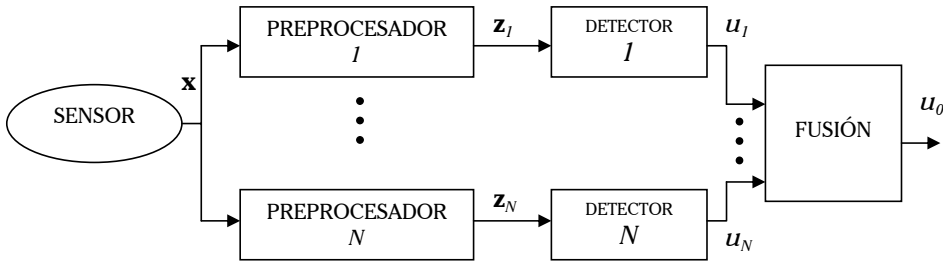


Figura 2. Arquitectura básica de detección distribuida monosensor.

En términos más concretos, diseñar el detector óptimo implica implementar la regla de decisión:

$$R(\mathbf{x}) = \begin{cases} 1 & \text{si } L(\mathbf{x}) > \lambda \\ 0 & \text{si } L(\mathbf{x}) < \lambda \end{cases} \quad L(\mathbf{x}) = \frac{f(\mathbf{x}/H_1)}{f(\mathbf{x}/H_0)} \quad (1)$$

donde \mathbf{x} es el vector de observaciones y $f(\mathbf{x}/H_j)$ es la función densidad de probabilidad (*fdp*) de las observaciones, condicionada a que sea H_j ($j=0$ ó $j=1$) la hipótesis correcta. La función $L(\mathbf{x})$ se denomina razón de verosimilitud y λ es un umbral que se ajusta para cumplir cierto requisito de diseño.

Por ejemplo, si ajustamos λ para conseguir cierta probabilidad de falsa alarma ($PFA = \text{Probabilidad}(R(\mathbf{x})=1/H_0)$), la regla anterior garantiza que la probabilidad de detección ($PD = \text{Probabilidad}(R(\mathbf{x})=1/H_1)$) es máxima. Es el denominado detector de Neyman-Pearson (NP), que será el tipo de detector que asumiremos en lo que sigue.

La razón de verosimilitud puede ser en general complicada de obtener, salvo que asumamos ciertos modelos estadísticos de las observaciones condicionados a cada una de las hipótesis. La detección distribuida en sistemas monosensor tiene su razón de ser en abordar el diseño del detector global, a partir de un conjunto de detectores de diseño más simple (es decir detectores donde es razonable aplicar modelos estadísticos sencillos), para después fusionar todas las decisiones particulares y adoptar la decisión final.

Un planteamiento tan general como el anterior puede ser aplicable a numerosas situaciones, en este trabajo nos centraremos en el clásico problema de detectar la presencia de señal en un fondo de ruido.

$$\begin{aligned} H_0 & \quad \mathbf{x} = \mathbf{w} \\ H_1 & \quad \mathbf{x} = \mathbf{s} + \mathbf{w} \end{aligned} \quad (2)$$

Donde \mathbf{w} es un vector de ruido, y \mathbf{s} es asociable a la presencia de una señal desconocida, de la que tenemos diversas informaciones. Las dificultades del diseño de un único detector óptimo provienen, en este caso, de las dificultades de calcular una única razón de verosimilitud a partir de toda la información disponible sobre \mathbf{s} , debido a su variedad (sabemos diferentes cosas pero es complicado integrarlas en una única información).

En ese caso podemos realizar diferentes detectores, aprovechando cada uno de ellos, la correspondiente parte de información, para finalmente fusionar las decisiones. En cierto sentido, es el planteamiento clásico de detección distribuida, pero aquí la diversidad de información se obtiene en un mismo sensor, en vez de en sensores diferentes.

1.2 Contexto de la tesis

Esta tesis se inserta dentro de las investigaciones del Grupo de Tratamiento de Señal (GTS) de la Universidad Politécnica de Valencia y se enfoca hacia dos ámbitos distintos:

- El primero, la detección automática de incremento de temperatura mediante análisis de la emisión infrarroja.
- El segundo de ellos es la detección automática de pulsos ultrasónicos en sistemas pulso-eco.

En cuanto a la primera línea se han desarrollado diversos sistemas de detección de incendios mediante análisis de imágenes infrarrojas [11], [12], [13], los cuales están en funcionamiento en la actualidad con un considerable éxito tanto de detección como de baja probabilidad de falsa alarma.

En cuanto a la segunda línea se está trabajando en la detección de grietas en bloques de mármol [14], en la determinación del estado de las capas internas en bóvedas como ayuda a su restauración [15] y, más recientemente, en la detección de objetos extraños en mermeladas y confituras [16].

Todos estos problemas comparten la dificultad de establecer modelos para la señal a detectar. En la aplicación de detección automática de incendios, la señal generada por la presencia de un posible fuego, obtenida a partir de la evolución temporal del nivel de infrarrojo en un cierto píxel, es totalmente impredecible, muy dependiente de cada inicio de incendio en particular. Además, en esta aplicación, el problema no es sólo contrastar la presencia de un posible fuego (a través de la aparición de una cierta señal \mathbf{s}) frente al ruido de fondo infrarrojo, sino rechazar alarmas muy variadas debidas a todo tipo de efectos puntuales (coches, personas, viento,...) que generarán otros vectores \mathbf{s} , difíciles de modelar estadísticamente, que no deberían producir detecciones. Un diseño óptimo, tipo filtro adaptado, incluso con perfecto conocimiento de la \mathbf{s} que deseamos detectar, podría generar en la práctica numerosas alarmas indeseadas, elevando mucho la *PFA* realmente obtenida, con respecto a la ajustada para un ruido de fondo blanco y Gaussiano.

En las aplicaciones pulso-eco por ultrasonidos, el pulso emitido es conocido y podría pensarse en utilizar un simple filtro adaptado, sin embargo en numerosas situaciones las características del medio de propagación dificultan el uso de un detector tan simple. Por un lado el pulso puede experimentar efectos dispersivos (diferentes componentes frecuenciales sufren diferentes atenuaciones a medida que el pulso se propaga), lo que provoca una continua deformación del pulso. Para aplicar el filtro adaptado sería necesario estimar el pulso a cada profundidad, lo cual es en general complicado, en especial si se requiere estimar la información de fase [17]. Además, el pulso se deforma al reflejarse en un defecto o interfase. Por otro lado, si la longitud de onda del pulso ultrasónico es comparable al tamaño medio de grano del medio en el que se propaga, la propia microestructura de dicho medio genera múltiples ecos produciendo el denominado ruido granular. Este ruido es coherente con el pulso ultrasónico, en el sentido de que su densidad espectral de potencia, coincide con la densidad espectral de energía del pulso. Un filtro adaptado al pulso, precisa un preblanqueo que como veremos, convierte al detector en una simple comparación con un umbral de la señal preblanqueada.

1.3 Fusión de decisiones

Un aspecto fundamental de la detección distribuida, y eje central de esta tesis es la fusión de decisiones [5], [6], [7], [8]. Existen soluciones óptimas para el caso de que las decisiones a fusionar puedan considerarse independientes [18]. También se ha abordado el problema de decisiones correladas [19], [20], [21], [22], [23], [24], [25], [26]. De especial interés son las soluciones generales propuestas en [20] y [21], que son equivalentes y que introducen en el diseño de la regla de fusión los diversos coeficientes de correlación de todo orden, entre las decisiones a fusionar. Las ecuaciones obtenidas son complicadas de aplicar en general, ya que el conocimiento de todos los coeficientes de correlación (que en los casos anteriores implica conocer las correlaciones entre energías en subespacios) es poco realista. No obstante en [20] se plantea un caso particularmente interesante que los autores denominan de “decisiones maximalmente dependientes”, para el que sí existe solución cerrada.

Por otra parte, se ha propuesto en [23] un algoritmo iterativo para diseñar reglas de fusión, basado en inferencia Bayesiana y modelos jerárquicos, que permite la inclusión de correlación entre decisiones. En [23] se asumen diseñados los detectores individuales y se intenta diseñar la regla de decisión óptima. Otra alternativa son los algoritmos también iterativos propuestos en [24] y [25]. Ambos son sustancialmente iguales, aunque en el primero, se reajustan uno a uno los umbrales de decisión de cada detector individual para maximizar la PD suponiendo una regla de fusión de decisiones fija, y en el segundo se permite un factor de aleatorización en la regla de fusión de decisiones, seleccionando aquel factor que maximiza la PD .

En las dos aplicaciones abordadas en esta tesis, trataremos el problema de la correlación de decisiones. En principio consideraremos si es posible asumir decisiones incorreladas, dada la gran simplificación que esto supone. Cuando no

sea posible, buscaremos la forma más simple de incorporar dicha correlación. De hecho, esto solo ocurrirá en la aplicación de detección de ecos ultrasónicos, ya que veremos que la hipótesis de incorrelación entre decisiones se cumple, razonablemente en la aplicación de detección de incendios.

1.4 Plan de la tesis

Como ya se ha mencionado, esta tesis profundiza en la idea de utilizar los conceptos ampliamente desarrollados en la teoría de detección distribuida, al caso de un único sensor. El objetivo es simplificar el diseño óptimo de un único detector, por el de muchos detectores sencillos, cuyas decisiones finalmente se fusionan.

Dado que un problema de esta índole es difícil de plantear de forma general, lo abordaremos en el contexto de aplicaciones específicas. Debe tenerse en cuenta que un interés básico de la investigación es resolver problemas concretos acometidos en los diversos proyectos que se desarrollan en el seno del GTS.

No obstante la tesis comienza (Capítulo 2) por un capítulo de revisión de las técnicas y problemas existentes en detección distribuida. Este capítulo incluye algunas técnicas, que posteriormente no ha sido necesario aplicar en la tesis, pero se consideraba de interés una revisión lo más completa posible, como un objetivo intrínseco de la tesis. La lectura detallada de este capítulo 2 no resulta imprescindible para abordar los capítulos siguientes. Adicionalmente la revisión realizada ha permitido seleccionar y analizar los algoritmos de fusión más adecuados para las aplicaciones consideradas.

El Capítulo 3 está dedicado a la aplicación de la fusión de decisiones en la detección de incendios forestales. Esencialmente fusionaremos decisiones tomadas en pequeños intervalos de observación contiguos pero no solapados (para minimizar la correlación entre decisiones), buscando la existencia o no de incrementos “persistentes” de temperatura, y no incrementos impulsivos o esporádicos. El resultado de la fusión de decisiones anterior se fusionará a su vez con la decisión de un detector de crecimiento, que actúa sobre el intervalo total de análisis.

El Capítulo 4 está dedicado a la aplicación de la fusión de decisiones en la detección de ecos ultrasónicos en ruido de fondo granular. Plantearemos un enfoque de detección distribuida sobre la filosofía subyacente en los algoritmos denominados “split-spectrum”. Estos algoritmos explotan implícitamente la diversidad en frecuencia, ya que asumen que el eco buscado es sensible a todas las frecuencias y, el ruido granular lo es sólo a algunas de ellas. Aplicaremos los algoritmos propuestos a la caracterización de interfaces entre capas internas como apoyo en la restauración y conservación de monumentos históricos.

CAPÍTULO 2:

Fusión de Decisiones



Capítulo 2: Fusión de decisiones.

2.1 Introducción

La fusión de datos con múltiples sensores se refiere a la adquisición, procesamiento y combinación sinérgica de la información recogida por diversas fuentes y sensores conocidos para suministrar un mejor conocimiento del fenómeno a considerar. Este concepto de fusión de datos puede parecer simple pero el diseño y la implementación de sistemas de fusión de datos es una tarea extremadamente compleja.

El modelado, procesamiento, fusión y la interpretación de diversos datos de diferentes sensores para la asimilación de conocimientos y su posterior inferencia plantea problemas desafiantes especialmente cuando la información disponible es incompleta, inconsistente y/o imprecisa.

Las técnicas de fusión de datos tratan de combinar datos de múltiples sensores relacionando información de bases de datos asociadas para mejorar la exactitud y muchas otras cualidades que no sería posible conseguir con el uso de un solo sensor.

En principio la fusión de datos de diversos sensores implica una serie de ventajas significativas sobre los datos tomados de un único sensor. Además de las ventajas estadísticas que se obtienen por la combinación de datos de un mismo sensor (consiguiendo una mejora sustancial de la estima de un fenómeno físico vía la redundancia en las observaciones), el uso de múltiples tipos de sensores puede mejorar la exactitud con la que una cantidad de datos puede ser observada y caracterizada.

Los datos observados pueden combinarse o fusionarse a varios niveles o capas, desde en una capa con los datos recién adquiridos, hasta en una capa de vector de características o en una capa de decisiones:

- Los datos en la entrada pueden combinarse directamente si los datos del sensor son “proporcionales” (por ejemplo si los sensores miden los mismos fenómenos físicos como dos sensores de imágenes o dos sensores acústicos). Las técnicas para este tipo de fusión de datos normalmente involucran el uso de métodos de detección o de estimación clásicos.
- Inversamente, si los datos de los sensores no son proporcionales, entonces los datos deberán ser fusionados a nivel de vector de características o a nivel de decisiones.
- En la fusión a nivel de las características, éstas se extraen de diversas observaciones de cada sensor, y se combinan en un único vector de características concatenadas, el cual pasa a ser la entrada de los métodos de clasificación.

- Finalmente, la fusión a nivel de decisiones implica la fusión de la información de los sensores, después de que cada sensor haya hecho una determinación preliminar de la ubicación, atributos e identidad de la entidad.

Los temas o cuestiones fundamentales que se han de tener en cuenta a la hora de construir un sistema con fusión de datos en una aplicación particular son las siguientes:

1. Qué algoritmos o técnicas son apropiados y óptimos para la aplicación particular.
2. Qué arquitectura se debe utilizar.
3. Cómo se deben procesar los datos de cada sensor, individualmente, para extraer la máxima cantidad de información.
4. Qué mejoras se pueden conseguir realmente con los procesos de fusión de datos.
5. Cómo pueden los procesos de fusión ser optimizados en un sentido dinámico.
6. Cómo pueden las condiciones del registro de datos afectar al procesado.
7. Bajo qué condiciones la fusión de datos con múltiples sensores mejora el funcionamiento del sistema.

2.2 El modelo general de la fusión de datos

Una de las principales barreras en la transferencia de tecnología en el campo de la fusión de datos era la falta de uniformidad de los términos entre los investigadores civiles y militares, por esta razón el grupo de trabajo de fusión de decisiones, formado por el colectivo de los directores de los laboratorios (JDL), establecidos en 1986, comenzaron un esfuerzo por codificar los términos relativos a la fusión de datos. El resultado fue la creación de un modelo general de la fusión de datos y un léxico de la fusión de datos.

El modelo resultante se puede observar en la Figura 3, el cual puede describirse como un modelo orientado a la funcionalidad de la fusión de datos, pretendiendo ser genérico y utilizable a lo largo de múltiples áreas de aplicación.

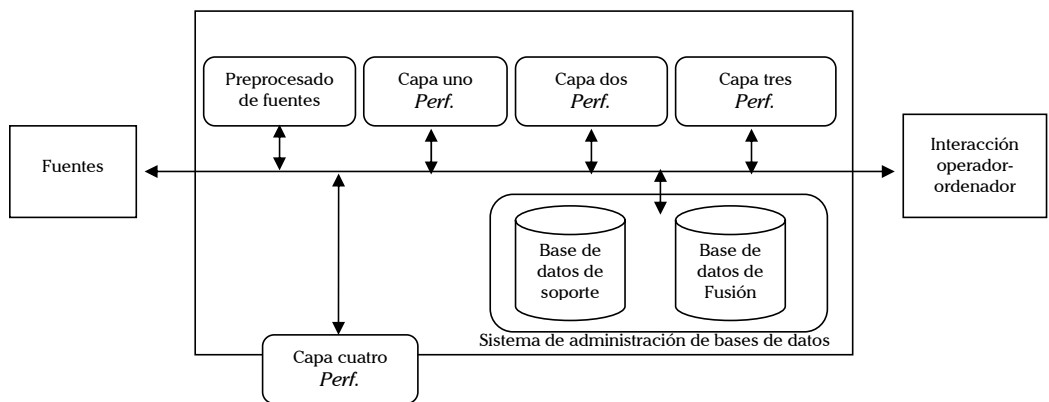


Figura 3. Modelo general de procesos de la fusión de datos.

El modelo general de procesos de la fusión de datos (JDL) es un modelo conceptual que identifica los procesos, funciones, categorías de técnicas, y las técnicas específicas aplicables a la fusión de datos. El modelo tiene una jerarquía de capas, que podemos ver en la Figura 3. El proceso de la fusión de datos está formado por fuentes de información, interacción entre los ordenadores y las personas, preprocesado de las fuentes (asignación de procesos), preprocesado de capa uno (perfeccionamiento de objetos), preprocesado de capa dos (perfeccionamiento de la situación), preprocesado de capa tres (perfeccionamiento de las amenazas), preprocesado de capa cuatro (perfeccionamiento del procesado) y sistema de administración de bases de datos.

- *Fuentes de información:* indica la cantidad de fuentes de información que se encuentran disponibles como entrada al sistema, incluyendo:
 - Sensores locales asociados al sistema de fusión de datos (por ejemplo, sensores físicamente asociados con el sistema de fusión de datos o sensores orgánicos físicamente integrados con el sistema de fusión de datos).

- Sensores distribuidos comunicados electrónicamente al sistema de fusión de datos.
 - Otros datos, como información de referencia, información geográfica,...
- *Interacción entre los ordenadores y las personas “Human Computer interaction” (HCI):* permite la introducción de datos por los usuarios, tales como comandos, solicitud de información, evaluación de conclusiones, informes de operadores, ... Además, el HCI es el mecanismo mediante el cual el sistema de fusión de datos muestra resultados mediante indicadores luminosos de alerta, pantallas de visualización, o mediante indicaciones dinámicas del posicionamiento y la identidad de la información con referencias geográficas. En general, HCI incorpora no sólo métodos multimedia para la interacción humana (gráficos, sonido, interfaz táctil,...), sino también métodos para ayudar a las personas a centrar su atención y superar sus limitaciones cognitivas (por ejemplo, personas con dificultades al procesar la información negativa).
 - *Preprocesado de las fuentes (asignación de procesos):* los procesos iniciales preparan los datos para asignar los procesos y hacer un prefiltrado. El preprocesado de las fuentes reduce la carga del sistema de fusión de datos mediante la reubicación de estos y la asignación de procesos. El preprocesado de las entradas además fuerza a los procesos de fusión de datos a concentrarse en aquellos datos más oportunos para cada situación.
 - *Preprocesado de capa uno (perfeccionamiento de objetos):* este proceso combina información local, paramétrica y de identidad para conseguir unas representaciones refinadas de los objetos individuales. Este preprocesado se compone de cuatro funciones principales:
 - Transforma los datos de los sensores en un conjunto consistente de unidades y coordenadas.
 - Refina y extiende las estimaciones en el tiempo de la posición, movimiento y atributos de los objetos.
 - Asigna datos a los objetos para permitir la aplicación o el uso de técnicas de cálculo estadístico.
 - Depura la estimación de la identificación o clasificación de los objetos.
 - *Preprocesado de capa dos (perfeccionamiento de la situación):* este preprocesado desarrolla las relaciones entre los objetos y los eventos en el contexto de su entorno. Además se centra en la información relacional (por ejemplo en relaciones de proximidad física, comunicaciones, causal, temporal y otras...) para determinar el significado de la colección de entidades. Este análisis se desempeña en el contexto de información ambiental sobre el terreno, medios circundantes, hidrología, condiciones ambientales y otros factores. El perfeccionamiento de la situación enfoca la interpretación de los datos de los sensores, tal y como las personas podrían interpretarlos. Ambas técnicas formales y heurísticas se pueden usar para

examinar, en un sentido condicional, el significado de los resultados del procesado de la capa 1.

- *Preprocesado de capa tres (perfeccionamiento de las amenazas)*: Este preprocesado trata de proyectar en el futuro la situación actual para conseguir así anticiparse a los posibles cambios del sistema. Esto es particularmente complejo ya que el sistema ha de desarrollar diferentes hipótesis de trabajo sobre las posibles estrategias futuras a seguir y los posibles efectos que pueden tener las informaciones no conocidas a priori.
- *Preprocesado de capa cuatro (perfeccionamiento del procesado)*: Este proceso se ha de considerar como un conjunto de procesos, ya que atañe al resto de los procesos. Se pueden describir cuatro funciones o claves principales:
 - Monitoriza el funcionamiento de los procesos de la fusión de datos para proveer información sobre el control en tiempo real y el rendimiento de estos a lo largo del tiempo.
 - Identifica qué información es necesaria para mejorar el producto multinivel de la fusión de datos (como por ejemplo: interferencias, posiciones, identidades,...)
 - Determina los requerimientos específicos de las fuentes de datos para recabar el máximo de información (por ejemplo el tipo de sensores necesarios, qué sensores específicos se han de utilizar, qué bases de datos,...)
 - Asigna y administra las fuentes para conseguir llevar a término los objetivos.

Esta última función puede dejarse fuera de las funciones específicas de la fusión de datos, por esta razón en la Figura 3 se puede observar como esta función está parcialmente dentro y fuera del proceso de fusión de datos.

- *Sistema de administración de bases de datos*: Es la función de soporte más extensa requerida para permitir la fusión de datos. Se trata de una colección de funciones que permiten el acceso y la administración de las bases de datos de la fusión de datos, incluyendo la recuperación de datos, almacenamiento, archivado, compresión, preguntas relacionales, y la protección de los mismos. La administración de bases de datos en los sistemas de fusión de datos es particularmente complejo debido a la gran variedad y cantidad de datos a manejar (por ejemplo: imágenes, señales, vectores, textos,...) y a las necesidades de velocidad tanto por la cantidad de datos que se reciben como por la necesidad de una rápida respuesta.

Este modelo general de la fusión de datos (JDL), es un modelo genérico y pretende ser simplemente una base para el entendimiento común y la discusión de los diferentes grupos de trabajo que estudian la fusión de datos.

La separación de los procesos en capas es una división artificial ya que en las implementaciones reales de los sistemas de fusión de datos, se integran e interpolan estas funciones en un flujo conjunto de procesado.

Cabe destacar que el JDL, aunque fue desarrollado inicialmente para aplicaciones militares, se puede utilizar y de hecho así es, en aplicaciones no militares.

Existe una gran diversidad de áreas de aplicación y de utilidad de la fusión de datos, tradicionalmente, estas áreas incluyen desde la gestión de comandos y de control para aplicaciones militares, pasando por la robótica, y el procesado de imágenes, hasta la diagnosis médica.

2.2.1 Aplicaciones de la fusión de datos

Las aplicaciones de la fusión de datos multisensor son muy extensas, pudiéndose realizar una clasificación en función de si estas aplicaciones son de carácter militar o no.

Aplicaciones militares: Las principales aplicaciones militares son: el reconocimiento automático de objetivos, el guiado autónomo de vehículos, la percepción remota, la vigilancia en el campo de batalla, y los sistemas automáticos de reconocimiento de amenazas, tales como los sistemas de identificación de enemigos-neutrales-amigos (IFFN), así como aplicaciones de vigilancia de océanos, defensa aire-aire, inteligencia en batalla, vigilancia, adquisición de objetivos, y prevención estratégica y defensa.

Aplicaciones no militares: Las aplicaciones no militares incluyen el monitorizado de procesos de manufacturado, mantenimiento basado en las condiciones cambiantes de máquinas complejas, robótica, y aplicaciones médicas.

Históricamente los métodos de fusión de datos fueron desarrollados para aplicaciones militares, sin embargo en los últimos años estos métodos se han ido utilizando en aplicaciones civiles, con lo que ha empezado a aparecer una transferencia de tecnología bidireccional entre los dos mundos.

2.2.2 Arquitecturas de la fusión de datos

Una vez analizadas las partes del modelo general de la fusión de datos, nos vamos a fijar en dos situaciones posibles para la fusión de datos a nivel de capa uno (perfeccionamiento de objetos): la fusión de información local y la fusión de datos paramétricos o de identidad.

2.2.2.1 Fusión de información local

Existen tres alternativas para la fusión de información local: fusión de los datos sin procesar o a nivel de datos, fusión de los vectores de estado y el método híbrido que permite la fusión de datos sin procesar o la fusión de vectores de estado en función de las necesidades.

- Fusión de los datos sin procesar o a nivel de datos (fusión centralizada):* Ver Figura 4. Los datos de cada sensor se alinean para transformar sus unidades y coordenadas basadas en los sensores, a las coordenadas y unidades convenientes para el procesado centralizado. Los datos se asocian o correlan para determinar qué observaciones de los sensores pueden asociarse. Es decir, en un entorno multisensor y multidespacho es necesario determinar qué datos representan observaciones de la misma entidad física, ya que el problema de esta observación o correlación puede ser muy complejo en entornos con alto tráfico. Al realizar este procesado los datos se fusionan usando técnicas de estimación secuencial tales como los filtros de Kalman. Esta metodología de fusión centralizada es teóricamente la mejor manera de fusionar los datos si asumimos que la asociación y correlación puede realizarse correctamente. Sin embargo, esto requiere que todos los datos se transmitan desde los sensores a la central, lo cual, en el caso del tratamiento de imagen, requiere un ancho de banda en las comunicaciones muy alto, que en algunos casos puede exceder lo físicamente posible.

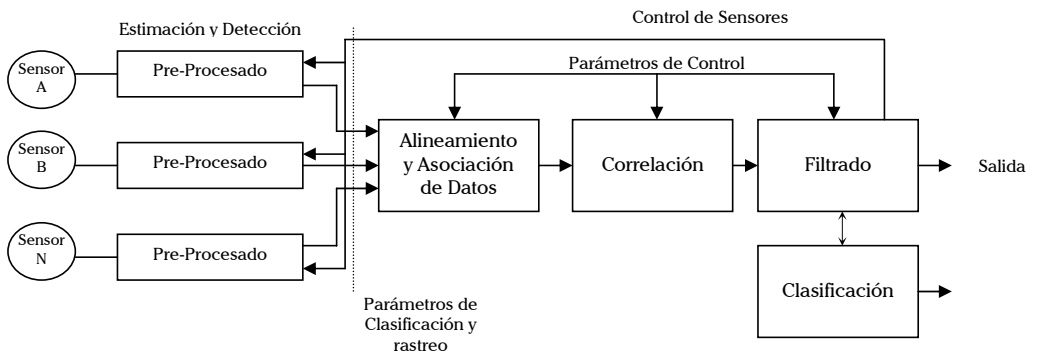


Figura 4. Fusión centralizada.

- Fusión de los vectores de estado (fusión distribuida o autónoma):* Ver Figura 5. En este tipo de arquitectura, cada sensor genera su propia estimación por fuente, generando un vector de características por cada sensor. Estas estimas son la entrada al proceso de fusión de datos para conseguir una estima unificada del vector de características basada en múltiples sensores. Las arquitecturas de fusión distribuida reducen las comunicaciones necesarias entre sensores y el procesador de fusionado, ya que los datos de los sensores se comprimen en el vector de características. Además, el proceso de asociación y/o correlación es conceptualmente más fácil que la

fusión a nivel de datos. Sin embargo, en general el vector de características fusionado no es tan acertada como la fusión a nivel de datos, ya que se pierde información. En particular, los datos originales obtienen información sobre la calidad de la señal, la cual sólo se puede aproximar con el vector de características y su matriz de covarianza asociada.

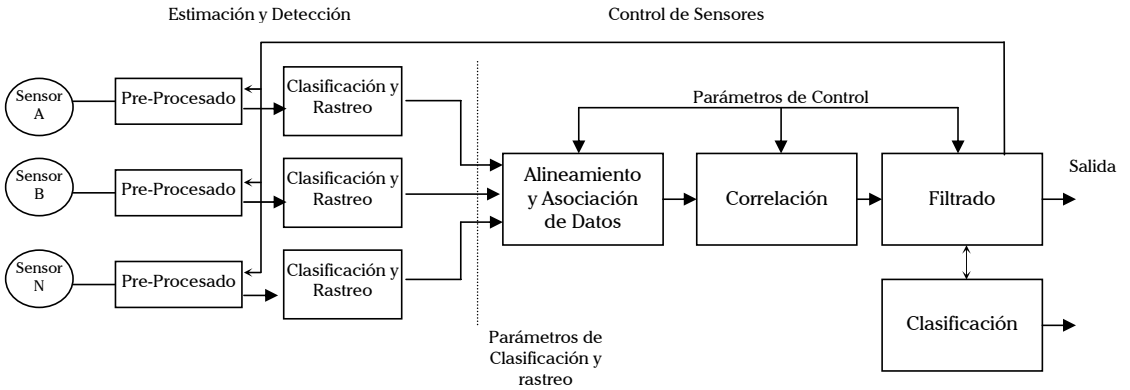


Figura 5. Fusión autónoma

- Método híbrido que permite la fusión de datos sin procesar o la fusión de vectores de estado en función de las necesidades:* Ver Figura 6. Habitualmente, se utiliza la fusión del vector de características para reducir el trabajo computacional y la demanda de comunicaciones. Sin embargo, bajo circunstancias específicas (cuando se requiere más precisión o en entornos de baja densidad), se prefiere la fusión a nivel de datos. Alternativamente, si se tienen los sensores adecuados, la combinación de la fusión del vector de estado y la fusión a nivel de datos implica mayor flexibilidad, aunque requiere un mayor control del proceso de fusión y un monitorizado para seleccionar entre fusión a nivel de datos o de vector de estado.

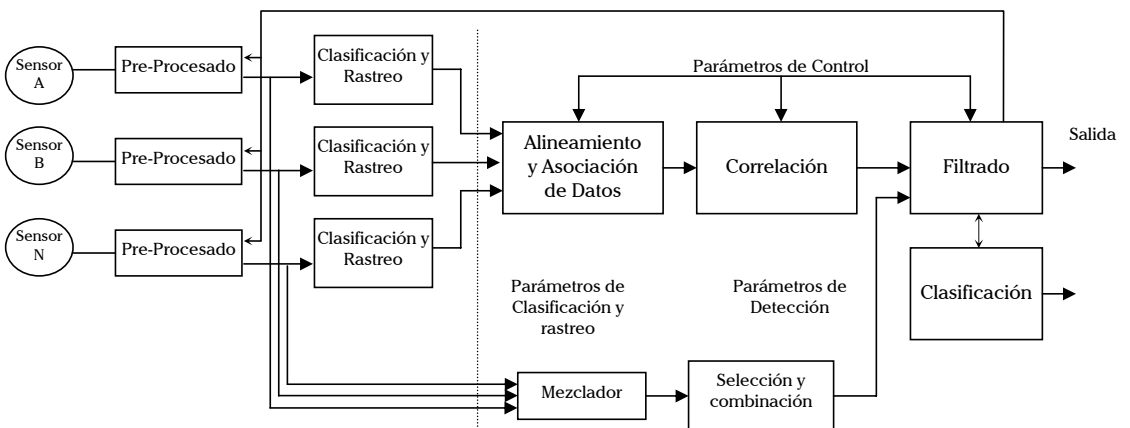


Figura 6. Fusión híbrida

No existe una única arquitectura óptima para cada aplicación de fusión de datos, en cambio, la elección de la arquitectura puede equilibrar los recursos computacionales, el ancho de banda disponible en comunicaciones, la precisión deseada, las capacidades de los sensores, y la financiación disponible.

2.2.2.2 Fusión de datos paramétricos o de identidad

En este tipo de fusión de datos intentamos convertir los atributos de salida de las observaciones de los múltiples sensores en una declaración compartida de la identidad de la salida.

Existen varias arquitecturas que podemos utilizar para la fusión de identidades, tales como la fusión a nivel de datos, la fusión a nivel de características y la fusión a nivel de decisiones.

- *Fusión a nivel de datos:* Ver Figura 7. En este tipo de arquitectura, las observaciones de cada sensor se combinan y se pasan al proceso de fusión a nivel de datos, antes de extraer el vector de características. A este proceso se le denomina la extracción del vector de características de los datos ya fusionados, para posteriormente generar la declaración de identidad común. Los métodos más utilizados en este tipo de arquitectura incluyen desde las redes neuronales, pasando por métodos estándar o plantilla, hasta métodos de reconocimiento de patrones tales como los algoritmos de racimo. Para poder fusionar los datos de los sensores, en este tipo de arquitectura, la información original de cada sensor debe ser proporcional, es decir que las observaciones sean de un mismo entorno físico tales como imágenes visuales, etc.... Bajo estas condiciones, la fusión a nivel de datos proporciona los mejores resultados posibles.

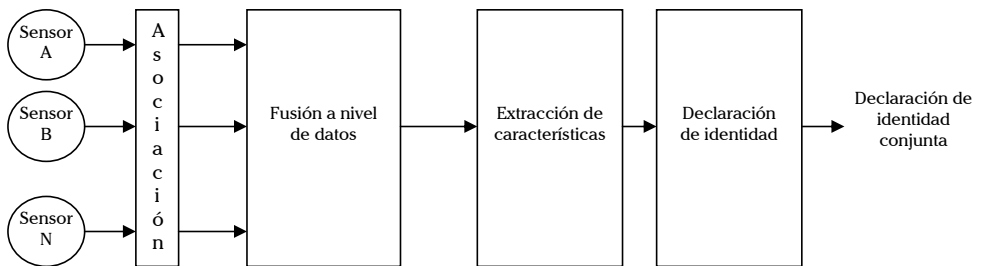


Figura 7. Arquitectura de fusión a nivel de datos.

- *Fusión a nivel de características:* Ver Figura 8. En este caso, cada sensor proporciona unos datos de los que se extrae un único vector de características por sensor, el cual sirve de entrada al proceso de declaración de identidades como fusión de estas características, pudiendo utilizar, este proceso de fusión, técnicas de redes neuronales o de algoritmos de racimo. Por lo tanto la salida del sistema se convierte en una fusión de declaraciones de las identidades, basadas en la combinación de vectores de características de todos los sensores. Para poder utilizar este tipo de arquitectura, es

necesario conocer a priori las funciones de autocorrelación y de correlación cruzada de los datos de los sensores.

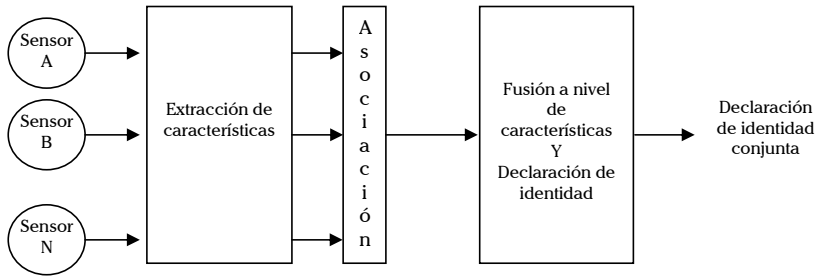


Figura 8. Arquitectura de fusión a nivel de características.

- **Fusión a nivel de decisiones:** Ver Figura 9. Finalmente, en esta arquitectura, se van extrayendo tantos vectores de características como sensores existan de forma independiente y se genera una declaración de identidad preliminar por cada sensor. Posteriormente se realiza un proceso de asociación de estas identidades preliminares y se genera una declaración de identidad conjunta como resultado de la fusión de estas decisiones preliminares. Para realizar esta fusión de decisiones se utilizan habitualmente las técnicas clásicas de deducción tales como la deducción Bayesiana, los métodos de decisión pesados, los métodos de Dempster-Shafer, entre otros. Al igual que en las otras arquitecturas, se requiere el conocimiento de la asociación de los datos y de la correlación, para estar seguros de que los datos a fusionar se refieren a los mismos fenómenos físicos.

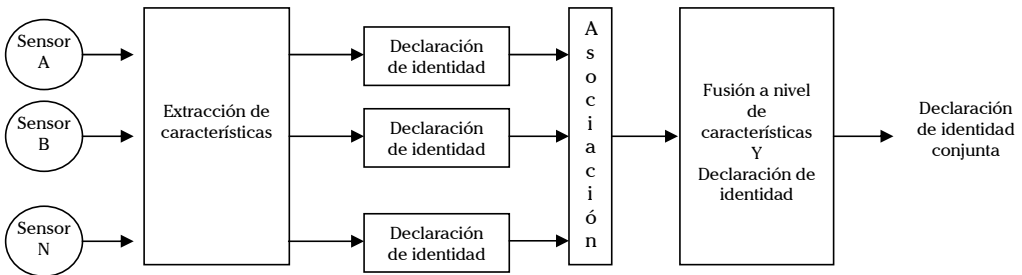


Figura 9. Arquitectura de fusión a nivel de decisiones.

2.3 Fundamentos de detección distribuida con sensores múltiples.

2.3.1 Introducción.

Con los métodos clásicos de detección y estima con múltiples sensores, se asume que todos los sensores comunican todos sus datos a un procesador central, el cual realiza una detección óptima basada en técnicas estadísticas convencionales. Sin embargo, en el procesado descentralizado, se realiza cierto procesado preliminar de los datos in situ, de forma que se condensa la información a transmitir desde cada sensor al resto de sensores y finalmente al procesador central, el cual se le conoce con el sobrenombre de central de fusión. Esto es lo que se conoce en terminología de redes de sensores distribuidos como que la red tiene inteligencia en cada nodo. [7]

El esquema centralizado puede ser en muchos casos muy restrictivo e incluso desaconsejable, por lo que, en estos casos, el esquema óptimo suele ser el basado en esquemas de procesado descentralizados. Las ventajas de estos esquemas distribuidos de procesado se reducen a los menores requerimientos de ancho de banda en las comunicaciones, mayor fiabilidad, y reducción de costes. Además, estos sistemas permiten una mayor respuesta a los cambios rápidos en el entorno. En contra de estos sistemas podemos observar que al transmitir únicamente una parte de la información de los sensores, pueden dar lugar a la pérdida de datos y por lo tanto, si se comparan con los sistemas centralizados, son sistemas con un menor rendimiento, sin embargo, esta pérdida de rendimiento puede reducirse si se introduce un procesado óptimo en cada uno de los sensores. Por lo tanto, la mayoría de los estudios en este campo tratan de desarrollar algoritmos eficientes computacionalmente hablando tanto en los sensores como en la central de fusión.

Siguiendo con la clasificación clásica de los métodos de inferencia estadística entre test de hipótesis y estima, se pueden identificar dos áreas de procesado de señal distribuido: la *detección distribuida* y la *estimación distribuida*.

A continuación vamos a desarrollar el problema de la detección distribuida, donde se van a estudiar las topologías en paralelo (ver Figura 10 y Figura 12), en serie (ver Figura 11), y en forma de árbol (ver Figura 13).

2.3.2 Formulación de Neyman-Pearson.

Vamos a describir los fundamentos de la formulación de Neyman-Pearson sobre el problema de la detección distribuida, utilizando tanto la configuración en paralelo como en serie. Asumimos para ello que estamos ante un problema de test de hipótesis en donde las observaciones de todos los sensores corresponden a presencia de señal (hipótesis H_1) o a ausencia de señal (hipótesis H_0).

2.3.2.1 Configuración en Paralelo.

En la Figura 10, asumimos que los sensores están intercomunicados y que no existe “feedback” entre la central de fusión y los sensores.

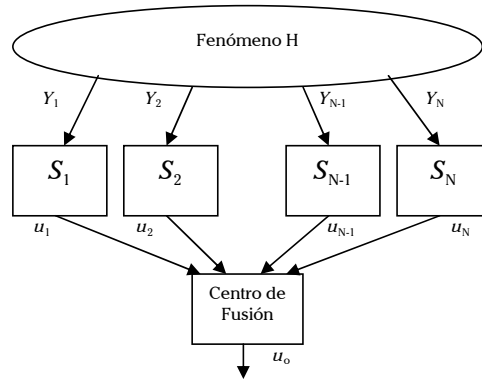


Figura 10. Configuración en Paralelo con Central de Fusión

El sensor i -ésimo utiliza la función de decisión $u_i = W(y_i)$ y transmite la información cuantizada u_i a la central de fusión, ésta, basándose en la información recibida $\mathbf{u} = (u_1, u_2, \dots, u_N)$ llega a una decisión global $u_o = W_o(\mathbf{u})$ que proporciona como respuesta H_1 (si $u_o = 1$) o H_0 (si $u_o = 0$).

La formulación de NP del problema de detección distribuida sería la siguiente: para una probabilidad de falsa alarma (PFA) dada, buscamos la regla de decisión óptima $\mathbf{W} = (\omega_0, \omega_1, \dots, \omega_N)$ que maximizan la probabilidad de detección (PD). Variaciones de esta formulación incluyen la optimización de las reglas de fusión de únicamente una serie de reglas de decisión local y la optimización de solamente las reglas de decisión locales para una regla de fusión dada.

Además, la solución a estos problemas depende de cómo son las observaciones de los sensores, si éstas son *independientemente condicionadas* (condicionadas a las hipótesis) o por el contrario *con dependencia condicional*.

Si se trata de observaciones con *independencia condicional*, la densidad de probabilidad conjunta está condicionada a la hipótesis H_l por lo que la formulación es como sigue:

$$p(y_1, \dots, y_N | H_l) = \prod_{i=1}^N p(u_i | H_l), \quad \text{para } l = 0, 1. \quad (3)$$

Tanto las reglas de mapeo en los sensores como las reglas de decisión en la central de fusión utilizan los umbrales apropiados a los ratios de probabilidad.

En el caso en el que los u_i con $i = 1, \dots, N$ sean valores binarios, lo que implica que $u_i \in \{0, 1\}$ cuando el i -ésimo sensor decide que la hipótesis correcta es H_0 o H_1 , el test de la central de fusión óptima sigue la siguiente expresión:

$$\Lambda(\mathbf{u}) = \frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} \begin{cases} > \lambda_0 & \text{decide } H_1 \text{ ó } u_0 = 1 \\ = \lambda_0 & \text{aleatoriamente decide } H_1 \text{ con probabilidad } \varepsilon \\ < \lambda_0 & \text{decide } H_0 \text{ ó } u_0 = 0 \end{cases} \quad (4)$$

Donde el umbral λ_0 y la probabilidad $\varepsilon \in$ se eligen para satisfacer una cierta probabilidad de falsa alarma dada $PFA = \alpha$. En este caso, el test de la central de fusión óptima es un test de razón de verosimilitud “likelihood ratio test” (LRT)

Si por el contrario se trata de observaciones con *dependencia condicional*, estamos hablando de que las observaciones de los sensores son dependientes, por lo que la densidad de probabilidad conjunta de estas observaciones, dada una hipótesis, no se puede escribir como el producto de las densidades de probabilidad marginales. Esto implica que, en general, la solución óptima no tenga una formulación sencilla, y en la práctica pueda llegar a ser intratable.

Cuando las observaciones son discretas y dependientes condicionalmente, la solución óptima es una forma polinomial, y cuando las distribuciones conjuntas de las observaciones en los sensores tienen una cierta estructura, existen ciertas reglas de decisión distribuidas que se pueden determinar fácilmente [19], [20].

2.3.2.2 Configuración en Serie.

En la configuración en serie o en tandem de N sensores, el sensor $(j-1)$ -ésimo pasa la información cuantizada al sensor j -ésimo, el cual genera su información cuantizada basándose en sus propias observaciones y en los datos cuantizados recibidos del sensor previo. (Ver Figura 11)




Figura 11. Configuración en Serie

La solución óptima del problema bajo el criterio de NP, cuando se utiliza la configuración serie, existe y es alcanzable siempre que las observaciones de los sensores sean condicionalmente independientes. Convirtiéndose en un problema intratable cuando se supone que las observaciones de los sensores son condicionalmente dependientes.

Considerando entonces el caso de independencia condicional y que cada sensor toma una decisión de tipo binario $u_i \in \{0,1\}$ para $i = 1,2, \dots, N$. Y considerando que denominamos a la probabilidad de falsa alarma en el sensor j -ésimo PFA_j y a la probabilidad de detección en el sensor j -ésimo PD_j , el problema

de NP queda descrito de la siguiente forma: dada una $PFA_N \leq \alpha$, se ha de buscar las reglas de decisión para todos los sensores, de forma que estas reglas juntas generan la máxima PD_N posible.

En general las configuraciones en serie tienen serios problemas de fiabilidad, debido a que cada paso del sistema debe esperar a que el paso anterior haya finalizado, por lo que aparece un serio problema de retardo. Otro problema que surge en estas configuraciones es el de la gran dependencia de la cadena de cada uno de los pasos, es decir, que si por cualquier motivo se rompe la cadena, el sistema es incapaz de ofrecer una solución al problema.

Además en general no se ha podido demostrar que la configuración en serie sin fallos, genere mejores resultados que la configuración en paralelo, e incluso se ha demostrado que, en redes de detección distribuida con únicamente dos sensores, la red serie óptima funciona tan bien como la red óptima en paralelo.

2.3.3 Formulación Bayesiana.

A continuación vamos a describir los fundamentos de la formulación Bayesiana sobre el problema de la detección distribuida. Para ello utilizaremos configuraciones en paralelo, en serie y otro tipo de topologías de red más generales. El objetivo de esta formulación es la minimización del riesgo bayesiano, para lo que se asignarán una serie de costes a diferentes caminos o vías de procesado a seguir, con el conocimiento a priori de las probabilidades de cada una, por lo que se asume que las observaciones de los sensores son condicionalmente independientes.

2.3.3.1 Configuración en Paralelo.

En esta configuración en paralelo, vamos a considerar dos casos especiales, el caso de la *configuración paralelo sin una central de fusión*, y el caso de la *optimización global*.




Figura 12. Configuración en Paralelo sin Central de Fusión

Comenzando con el primer caso de *configuración en paralelo sin la central de fusión*, (ver Figura 12), podemos observar cómo todos los sensores observan un

mismo fenómeno físico común y generan decisiones locales de acuerdo con éste, por lo que estas decisiones no se unen para generar una decisión global.

Suponemos que los costes de las decisiones de cada sensor están asociados y que el sistema se optimiza basándose en esta asociación de costes, por lo que las reglas de decisión resultado están asociadas también.

Si nos fijamos en el caso de una red con únicamente dos sensores, y teniendo en cuenta que se pueden deducir los resultados para redes mayores a partir de los resultados obtenidos con ésta. Llamando P_0 y P_1 las probabilidades a priori de las dos hipótesis H_0 y H_1 , y al coste de las posibles líneas de acción C_{ijk} , donde $i, j, k = \{0,1\}$.

Se trata de minimizar el riesgo Bayesiano dado por la siguiente expresión:

$$\mathfrak{R} = \sum_{i,j,k} \int_{y_1, y_2} p(u_1, u_2, y_1, y_2, H_k) C_{ijk} = \sum_{i,j,k} \int_{y_1, y_2} P_k C_{ijk} P(u_1, u_2 | y_1, y_2, H_k) p(y_1, y_2 | H_k) \quad (5)$$

De forma que el umbral del primer sensor (t_1) cumpla con la siguiente expresión:

$$t_1 = \frac{P_0 \int_{y_2} p(y_2 | H_0) \{ [C_{110} - C_{010}] + P(u_2 = 0 | y_2) [C_{100} - C_{000} + C_{010} - C_{110}] \}}{P_1 \int_{y_2} p(y_2 | H_1) \{ [C_{011} - C_{111}] + P(u_2 = 0 | y_2) [C_{001} - C_{101} + C_{111} - C_{011}] \}} \quad (6)$$

Se debe tener en cuenta que t_1 es una función de $P(u_2 = 0 | y_2)$ la cual se determina con la regla de decisión del segundo detector, por lo que t_1 es función de t_2 , y por lo tanto se puede obtener una expresión similar para t_2 a partir de t_1 .

La solución de esta pareja de ecuaciones genera una solución localmente óptima, de forma que cuando existen múltiples mínimos locales, hay que ir examinando cada uno para obtener la mejor solución.

A continuación buscamos la fusión óptima de las decisiones locales, lo que consiste en determinar la regla de fusión que minimice el riesgo bayesiano, para lo que se utiliza la siguiente expresión (LRT):

$$\frac{P(u_1, u_2, \dots, u_N | H_1)}{P(u_1, u_2, \dots, u_N | H_0)} \underset{u_0=0}{\overset{u_0=1}{>}} \frac{P_0 (C_{10} - C_{00})}{P_1 (C_{01} - C_{11})} = \eta \quad (7)$$

Donde C_{ij} indica el coste de la decisión global de H_i cuando H_j está presente, y donde se puede expresar de la siguiente forma:

$$\sum_{i=1}^N \left[u_i \log \frac{1 - PD_i}{PFA_i} + (1 - u_i) \log \frac{PD_i}{1 - PFA_i} \right] \underset{u_0=0}{\overset{u_0=1}{>}} \log \eta \quad (8)$$

Finalmente consideramos el caso de la *optimización global* como en la Figura 12, el que se pueden ver una serie de sensores conectados en paralelo con una central de fusión. En este caso el objetivo de la formulación bayesiana es la obtención de una serie de reglas de decisión $\Gamma = \{\gamma_1, \dots, \gamma_N\}$ que minimicen el coste medio del conjunto del sistema. El riesgo bayesiano se puede expresar de la siguiente forma:

$$\mathfrak{R} = C + C_F \sum_u P(u_0 = 1 | \mathbf{u}) P(\mathbf{u} | H_0) - C_D \sum_u P(u_0 = 1 | \mathbf{u}) P(\mathbf{u} | H_1) \quad (9)$$

donde:

$$\begin{aligned} C_F &= P_0(C_{10} - C_{00}) \\ C_D &= (1 - P_0)(C_{01} - C_{11}) \\ C &= C_{01}(1 - P_0) + C_{00}P_0 \end{aligned} \quad (10)$$

siendo las funciones de coste de la forma:

$$C_{ij} = \log \left\{ \frac{P(u_{0i}, H_j)}{P(u_{0i})P(H_j)}, \quad i, j = 0, 1 \right\} \quad (11)$$

2.3.3.2 Configuración en Serie.

A continuación vamos a considerar el problema del test de hipótesis bayesiana en una configuración en serie, para simplificar nos fijaremos en una red con dos detectores en serie, donde el primer detector genera una decisión $u_1 = i$ basada únicamente en y_1 , y el segundo detector genera una decisión u_2 basada en u_1 y en y_2 , de forma que en este caso C_{ij} indica el coste de decidir $u_2 = j$ cuando H_i está presente.

El objetivo es la deducción de las reglas de decisión de ambos detectores de forma que el coste medio de tomar la decisión u_2 se minimice. El riesgo bayesiano se puede expresar, en este caso, de la siguiente forma:

$$\mathfrak{R} = \sum_{i,j,k} \int_{y_1, y_2} P_k C_{jk} P(u_2 | u_1, y_2) p(u_1, y_1 | H_k) p(y_2 | H_k) \quad (12)$$

Las reglas de decisión en ambos casos son LRT, utilizándose un único umbral en el primer detector (t_1), mientras que en el segundo detector se utilizan dos umbrales que dependen de la decisión del primer detector (t_2^i). Estos umbrales son:

$$\begin{aligned}
 t_1 &= \frac{C_F}{C_D} \frac{PFA_2(t_2^1) - PFA_2(t_2^0)}{PD_2(t_2^1) - PD_2(t_2^0)} \\
 t_2^1 &= \frac{C_F}{C_D} \frac{PFA_1}{PD_1} \\
 t_2^0 &= \frac{C_F}{C_D} \frac{1 - PFA_1}{1 - PD_1}
 \end{aligned}
 \tag{13}$$

En el caso de redes con N detectores serie, serían necesarias $(2N - 1)$ ecuaciones para determinar los umbrales, y si el N crece, lo más conveniente es utilizar ecuaciones recursivas para resolver los umbrales.

Una cuestión importante es qué topología es mejor bajo el criterio de Bayes, si la serie o el paralelo. Al respecto de esta cuestión es conocido que la red en paralelo es mejor que la serie cuando N crece, lo que no se conoce con exactitud es a partir de qué valor de N , la configuración en paralelo es mejor que la serie.

2.3.3.3 Configuraciones más generales.

Otra configuración posible es la tipo árbol (ver Figura 13) en la que se puede trabajar de forma similar a las configuraciones anteriores de forma que las reglas de decisión se deriven para todos los detectores.

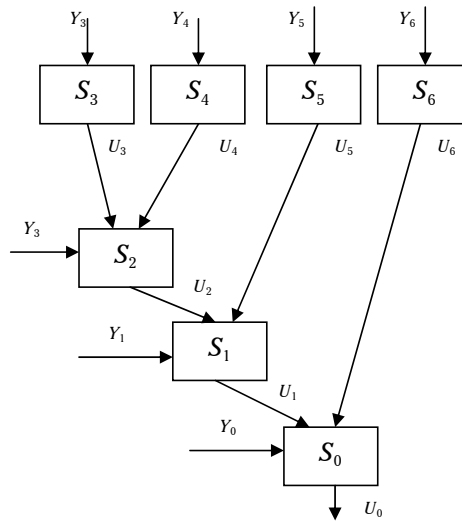


Figura 13. Configuración en árbol

Hasta ahora, toda la información ha fluido en un único sentido, es decir de los sensores a la central de fusión, pero existen estudios en los que se buscan métodos que utilicen “feedback”, de forma que fluya cierta información desde la central de decisiones a los sensores. Por ejemplo, en la red en paralelo con “feedback”, las observaciones llegan secuencialmente a los sensores y tras recibirlos, cada sensor genera una decisión de tentativa que transmite a la central de fusión. Ésta combina

toda la información y transmite la decisión tentativa global a los sensores, de forma que los sensores utilizan esta nueva información para adaptar sus decisiones anteriores.

Otros métodos buscan formas colectivas de toma de decisiones, de forma que cada sensor transmita su decisión tentativa al resto de sensores y cada sensor reconsidere su decisión generando una nueva decisión tentativa, continuando el proceso hasta que todos los sensores llegan a un consenso.

2.3.4 Temas avanzados en la detección distribuida con sensores múltiples

Hasta ahora nos hemos fijado en los criterios de detección de Neyman-Pearson y de Bayes en situaciones que nos conducían al uso de técnicas basadas en el razón de verosimilitud de los sensores individuales y en la central de fusión con redes de detección distribuidas. Y utilizando como modelos de señal y ruido modelos estadísticos de tipo paramétricos, y usualmente gaussianos.

2.3.4.1 Introducción

En este apartado, vamos a fijarnos en los desarrollos adicionales que han ido surgiendo como técnicas avanzadas en la detección distribuida con sensores múltiples. Particularmente vamos a estudiar métodos óptimos de detección distribuida de señales débiles, de señales no paramétricas, detección distribuida robusta y esquemas secuenciales de detección distribuida.

Cuando un problema de test de hipótesis simple en detección de señales se convierte en un problema de hipótesis compuesta, pensamos que puede obtener unos resultados de detección mejores para un esquema óptimo, pero en general esto no es así, sobre todo cuando estamos hablando de una detección distribuida con condiciones de ruido no-gaussiano.

Teniendo en cuenta todas estas condiciones de partida, en el presente apartado del trabajo vamos a empezar describiendo la *detección distribuida localmente óptima* basada en el criterio generalizado de Neyman-Pearson. Considerando que los modelos de ruido a utilizar no van a ser necesariamente gaussianos y que las componentes de señal de los diferentes sensores no serán necesariamente independientes.

A continuación pasaremos a describir los estudios realizados sobre la *detección distribuida no paramétrica* y lo que se conoce como el *ratio de falsa alarma constante (CFAR)*. Para pasar a comentar la teoría de la *detección de señales robusta*, basada en los conceptos de mínimos y máximos. Para finalizar con *métodos secuenciales de detección distribuida*, que ofrecen la posibilidad de generar decisiones finales sin grandes requerimientos de fiabilidad y con pocos datos. Estos métodos se utilizan cuando el coste de la adquisición de los datos es grande y cuando se necesitan tiempos de respuesta rápidos.

2.3.4.2 Detección localmente óptima de señales distribuidas

Si consideramos el diseño de un esquema de detección con N sensores distribuidos en el que se ha de considerar entre decidir la hipótesis de señal presente o la hipótesis de señal no presente. En la detección localmente óptima de señales distribuidas, cada sensor lleva asociado un procesador que genera su decisión basándose únicamente en las observaciones obtenidas de su propio sensor. Estas decisiones se transmiten a la central de fusión de decisiones en donde se toma la decisión global del sistema.

La nomenclatura utilizada es la que hemos visto en los apartados anteriores donde un valor particular y_k del vector aleatorio Y_k se observa en el k -ésimo sensor, con $k=1, \dots, N$, donde y_k es un vector de m_k observaciones reales. No teniendo porque ser los Y_1, \dots, Y_N , en general, independientes, entonces la decisión binaria conjunta se designa con la variable aleatoria U_o , donde u_o es una realización particular de ella y donde $u_o = 0$ implica que la decisión de que no hay señal y $u_o = 1$ significa tomar la decisión de que sí que hay señal. Pudiéndose generalizar este procedimiento para la variable aleatoria U_k con la realización u_k que describe la decisión que se hace en el k -ésimo sensor.

Asumiendo que la función de densidad de probabilidad (pdf) de las observaciones en el sensor k -ésimo $f_{y_k}(y_k | \theta)$ se puede parametrizar con el parámetro de la relación señal a ruido θ y que la hipótesis alternativa corresponde con el caso en el que $\theta > 0$, de forma que la hipótesis inválida sea cuando $\theta = 0$ (sin señal). Se obtiene la probabilidad de detección como $PD(\theta) = \text{Prob}(U_o = 1 | \theta)$, que en general depende de θ , y la probabilidad de falsa alarma como $PFA = \text{Prob}(U_o = 1 | \theta = 0)$.

En este caso, el esquema localmente óptimo (LO) se puede buscar considerando aquel que maximice la $\left. \frac{d}{d\theta} PD(\theta) \right|_{\theta=0}$ bajo la restricción de que la probabilidad de falsa alarma sea constante $PFA = \alpha_0$, asumiendo que $\left. \frac{d}{d\theta} PD(\theta) \right|_{\theta=0}$ no sea cero para todas las posibles pruebas de los sensores. De forma que el esquema LO optimice el rendimiento para señales débiles. Si $\left. \frac{d}{d\theta} PD(\theta) \right|_{\theta=0}$ es cero, el esquema LO debe maximizar la $\left. \frac{d^l}{d\theta^l} PD(\theta) \right|_{\theta=0}$ para el menor orden l de forma que no sea cero.

Para el caso de observaciones independientes, las mejores reglas de decisión para los sensores son aquellas que siguen la forma que se usa en el esquema de sensores aislados con el mismo esquema estadístico para las observaciones. Que en general es el utilizado en las teorías de detección centralizada.

En general, dada unas reglas de fusión y asumiendo que se conocen estas reglas para cada uno de los sensores, el test estadístico LO para el sensor k -ésimo es el que se obtiene de la expresión siguiente:

$$T_k(y_k) = \left. \frac{\frac{d^l}{d\theta^l} f_{y_k}(y_k | \theta)}{f_{y_k}(y_k | \theta)} \right|_{\theta=0} + \left. \frac{\sum_{u^k} C(u^k) \left[\frac{d^l}{d\theta^l} \text{Prob}(U^k = u^k | Y_k = y_k, \theta) \right]}{\sum_{u^k} C(u^k) [\text{Prob}(U^k = u^k | Y_k = y_k, \theta)]} \right|_{\theta=0} \quad (14)$$

Donde el estadístico de test T_k se corresponde con la suma de dos términos, el primero que es test estadístico óptimo para sensores aislados, y el segundo término indica las diferencias existentes respecto al test estadístico óptimo para sensores aislados.

Este test estadístico óptimo T_k se comprara con el umbral λ_k para generar la decisión final.

Por otro lado, cuando se consideran problemas de detección con señales débiles, frecuentemente es interesante utilizar tamaños de muestra largos, en estos casos es mas apropiado la utilización de medidas de rendimiento asintóticas, en donde el número de observaciones se acerca al infinito.

Otros posibles esquemas de detección distribuida son aquellos en los que las observaciones son independientes, otros son aquellos en los que se introduce el concepto de feedback o realimentación, o aquellos en los que las observaciones son correladas.

2.3.4.3 Detección distribuida no paramétrica y con ratio de falsa alarma constante.

Existen bastantes investigaciones en el campo de las técnicas de detección no paramétricas para problemas de detección de señales centralizadas, basadas en formulaciones de test de hipótesis no paramétricas. Estas hipótesis no paramétricas no especifican las formas funcionales en detalle de las distribuciones colectivas, ya que estas distribuciones bajo las hipótesis no paramétricas generan una gran cantidad de posibilidades que no se pueden indexar mediante un número finito de parámetros.

Otro campo de la detección no paramétrica que conlleva una gran atención es la de las técnicas de ratio de falsa alarma constante (CFAR), las cuales, aunque asumen modelos paramétricos para sus observaciones, se clasifican como esquemas no paramétricos. Para señales en entorno no estacionarios y posiblemente desconocidos, los detectores CFAR se han mostrado muy útiles, sobre todo en aplicaciones de tipo radar o sonar.

2.3.4.4 Esquemas no paramétricos de detección distribuida

Comenzando por los *esquemas no paramétricos de detección distribuida*, estos suelen estar basados en señales y rangos que funcionan bastante bien bajo condiciones de ruido gaussiano. En muchos escenarios de detección, estos esquemas son capaces de generar unas probabilidades de falsa alarma independientes de la distribución exacta de ruido, siempre que ésta sea de tipo

simétrica. En algunas aplicaciones, la información disponible corresponde con modelos estadísticos específicos que pueden ser fácilmente encontrados, tal información habitualmente se indica en forma de modelos estadísticos nominales y puede ser usada para el diseño de esquemas de detección no paramétricos buenos.

Por otro lado están los esquemas de detección no paramétrica descentralizados, en donde los estadísticos de test de rango suscrito (Wilcoxon), se envían a la central de fusión con gran precisión. Los estudios sobre los esquemas de detección descentralizados basados en Wilcoxon consideran que funcionan correctamente en los casos en que se tienen ruidos no gaussianos con cola pesada en comparación con los esquemas diseñados para los casos de ruido gaussiano donde las reglas de comparación utilizan medidas de rendimiento no asintóticas.

Los test estadísticos de rango suscrito Wilcoxon, la detección de firma, los detectores de zona muerta y sus extensiones, reciben una gran atención para los casos centralizados ya que tienen un buen rendimiento en una gran parte de los casos, pero no son óptimos como detectores para ningún entorno operativo particular de interés. Aunque los esquemas no paramétricos basados en rangos y firmas pueden construirse de forma que generen un rendimiento LO bajo un modelo dado para problemas de detección de señales centralizados.

Detección de señales distribuidas mediante técnicas de ratio de falsa alarma constante (CFAR)

Se han propuesto muchas técnicas para fijar el umbral en sistemas de detección de señales CFAR centralizadas, y muchas de estas técnicas también han sido utilizadas en casos distribuidos.

Una de estas técnicas es la denominada método CFAR del promedio de célula CA-CFAR, donde los umbrales son proporcionales a la media del cuadrado de la envolvente de las observaciones de referencia. Esta técnica tiene unos resultados pobres en los casos donde existe una rápida variación del ruido de fondo o en casos de detección en presencia de interferencia, por lo que, en estos casos se utiliza otra técnica llamada OS-CFAR, en donde el orden de los estadísticos de las observaciones de referencia se utilizan para generar el umbral. Además diversos estudios indican que la técnica OS-CFAR genera unos mejores resultados para los casos en donde existe un ruido de fondo no homogéneo.

2.3.4.5 Detección distribuida robusta.

El principio básico de la detección distribuida robusta es que los detectores robustos se pueden idear mediante el diseño de detectores óptimos para ciertos modelos poco favorables.

Como ejemplo consideraremos el problema de la detección centralizada en la toma de decisiones entre dos distribuciones marginales (P_0 y P_1) para una serie de observaciones Y_1, Y_2, \dots, Y_k . En este caso existen tres posibles criterios óptimos de interés para el diseño del detector:

- Detector Bayesiano, que minimiza la probabilidad de error media.
- Detector Minimax, que minimiza el máximo de la probabilidad de falsa alarma y las probabilidades de fallo.
- Detector Neyman-Pearson, que minimiza la probabilidad de fallo sin merma de la probabilidad de falsa alarma.

Cada uno de estos problemas se resuelve mediante un ratio de test de verosimilitud, que decide entre P_0 y P_1 bajo los principios de los valores del ratio de verosimilitud relativos al umbral.

$$\prod_{i=1}^k L(Y_i) \quad (15)$$

Donde $L(Y_i)$ es el ratio de verosimilitud entre P_0 y P_1 basado en una sola muestra Y_i . De esta forma el valor del umbral se determina mediante el uso de uno de los tres criterios citados anteriormente. Si P_j tiene como probabilidad de falsa alarma p_j para $j=0,1$ entonces:

$$L(Y_i) = \frac{p_1(Y_i)}{p_0(Y_i)}, \quad i = 1, 2, \dots \quad (16)$$

La forma habitual de buscar la robustez de este esquema es la de reemplazar las hipótesis simples de forma que la distribución marginal de las observaciones sea P_0 o P_1 , por unas hipótesis compuestas de forma que la distribución marginal de las observaciones derive de una o dos clases inciertas P'_0 y P'_1 de distribuciones marginales. La idea es que P'_0 represente el rango de comportamiento estadístico posible bajo la hipótesis H_0 , y de forma parecida P'_1 .

La cuestión de la robustez ha sido considerada en el contexto de la detección distribuida en diversos áreas, por ejemplo en minimax, donde la robustez se considera cuando tenemos detección distribuida en redes con y sin central de fusión, de forma que de la detección minimax robusta se utiliza en la detección distribuida mediante el diseño óptimo de detectores distribuidos para los casos de modelos más desfavorables.

Por lo tanto, en general el problema de la detección distribuida robusta se reduce al diseño de sistemas de detección distribuida óptimos en los casos más desfavorables.

2.3.4.6 Métodos secuenciales en detección distribuida.

Hasta ahora nos hemos estado fijando en los procedimientos de detección distribuida donde los detectores tienen un tamaño de muestra fija, es decir, estos procedimientos operan con un número de observaciones fijo determinado cuando se diseña el detector.

Una alternativa a este tipo de detectores es la de los detectores secuenciales, en donde el número de observaciones a utilizar en la decisión entre las diferentes hipótesis es una variable de calidad aleatoria que depende de las propias

observaciones. En estos procedimientos, existe habitualmente un gran número de observaciones (posiblemente infinitas) que se pueden considerar, y tanto la decisión como cuantas observaciones debemos valorar entra a formar parte del propio proceso de la detección.

Los índices de rendimiento a utilizar para el diseño de cada detector deben incluir, por lo tanto, los costes de utilizar unas u otras observaciones, de forma que hay que elegir entre calidad en la detección (medida mediante la probabilidad de error) y el coste medio por muestra.

Existen tres posibles situaciones básicas que vamos a considerar:

- La primera situación es que en una red distribuida de detección, cada sensor individualmente genere sus propias decisiones a la central de fusión. (Ver Figura 12)
- La segunda posibilidad es que cada sensor individualmente genere sus propias decisiones secuenciales. (Ver Figura 14)
- Y la tercera situación se fija en el problema de la detección rápida, en donde se busca la detección de cualquier cambio abrupto en un tiempo desconocido. En donde se puede utilizar tanto la topología con central de fusión como sin ella.

Antes de pasar a describir cada una de estas posibles situaciones vamos a describir el problema de la detección secuencial centralizada, en donde existen dos posibles maneras de actuar:

- La regla de cuando parar, en donde se utiliza una función que decide, en base a las observaciones que se van obteniendo de forma secuencial, cuando parar de tomar observaciones. Y se utiliza el tiempo de parada, que es una variable aleatoria que depende de las observaciones, como el tiempo que tarda la regla de parar en tomar esta decisión de detener la toma de observaciones.
- La regla de la decisión de parar, en donde se busca una regla de decisión a aplicar sobre las observaciones cuando vence el tiempo de parada y deja de actuar la regla de parada.

El test secuencial se puede ver ilustrado en la Figura 14, en donde se puede observar como el test continua tomando observaciones hasta que se tienen suficientes evidencias para optar por una u otra hipótesis acumulativa. Entonces para y toma una decisión, permitiendo la flexibilidad de parar precozmente cuando se tiene clara la decisión a tomar o continuar observando hasta que se aclare la decisión.

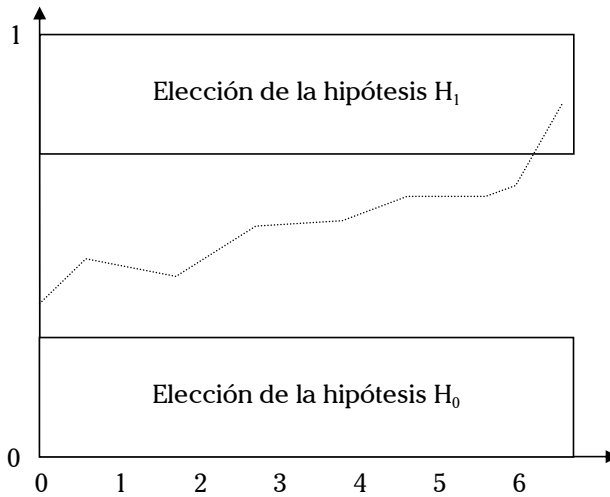


Figura 14. Test secuencial.

Detección distribuida con test secuencial en la central de fusión.

La primera situación que vamos a considerar es en la que los sensores individualmente generan decisiones intermedias con su test secuencial que transmiten a la central de fusión. Se asume que las observaciones son independientes de un sensor a otro y que son i.i.d. en cada sensor.

La idea es que los mensajes resumen se escojan de un reducido alfabeto finito (incluso binario) que sea fácil de transmitir sobre un canal de transmisión con capacidad limitada. Y la central de fusión procese mediante el test secuencial estos mensajes. Es decir que la central de fusión debe estar observando los mensajes y decidiendo cuando dejar de tomar observaciones y generar una decisión.

El objetivo del diseño del detector es, por tanto, elegir la regla de decisión y la regla de parada de la central de fusión más adecuadas, y en los sensores elegir el procesamiento necesario para la generación de los mensajes, para así minimizar el coste de la toma de muestras además de la media de la probabilidad de error.

Existen algunas distinciones importantes que se deben realizar, entre el caso que nos ocupa y el caso centralizado.

- Primeramente, en muchos problemas de detección distribuida, el umbral de detección para los sensores locales es bastante complicado de obtener.
- Y en segundo lugar, las observaciones sobre las que la central de fusión está tomando las decisiones no son i.i.d. (a pesar de que sí lo sean en los sensores locales), no obstante las conexiones están despejadas.

Detección distribuida con sensores generando tests secuenciales.

La segunda situación de interés es en la que los propios sensores son capaces de generar el test secuencial, de forma que cada sensor decide, basándose únicamente en sus propias observaciones, cuando ha de dejar de tomar datos.

En estos casos, los sensores trabajan en equipo para optimizar el índice de rendimiento, de manera que las acciones de los sensores se emparejan a través de su objetivo de funcionamiento común.

Detección distribuida rápida.

Por último, aparece la detección distribuida rápida o veloz, que como cualquier técnica de detección secuencial involucra el diseño de una regla de parada, sin embargo las hipótesis básicas de interés para la detección no son binarias, sino que más bien hay una hipótesis por cada posible intervalo de observación. Particularmente la hipótesis t -ésima es aquella en la que la distribución de las observaciones cambia en el intervalo t , para $t = 1, 2, \dots$

El objetivo del problema de la detección distribuida rápida (o problema del caos) es la detección de cambios en la distribución tan rápidamente como sea posible, sin restringir el ratio de probabilidad de falsa alarma.

Existen dos formulaciones básicas para este problema:

- Una en la que el punto de cambio t se asume que es una variable aleatoria con una distribución previa conocida.
- Otra en la que t se asume desconocido pero no aleatorio (incluso siendo posible que t tienda al infinito).

2.4 Detección distribuida y fusión de decisiones óptima.

Una vez comentado el modelo general de la fusión de datos, con sus aplicaciones y arquitecturas más comunes, y los fundamentos generales de la detección distribuida con múltiples sensores. En este apartado vamos a estudiar la fusión óptima en sistemas de detección con múltiples sensores, inicialmente incorrelados para, posteriormente, ver el efecto que produce la inclusión de un ruido correlado en el rendimiento de los sistemas de detección distribuida, mediante la revisión histórica de diversos estudios realizados.

2.4.1 Fusión óptima en sistemas de detección con múltiples sensores incorrelados.

Vamos a comenzar con [18] donde se presenta una serie de estructuras óptimas de fusión de datos, en el caso de que los detectores de cada sensor distribuido estén dados de antemano con su PFA y su PD . Se va a obtener la regla óptima de fusión de decisiones suponiendo primeramente independencia estadística, y generando finalmente el criterio óptimo de fusión que minimiza la probabilidad de error.

Para este estudio utilizaremos una estructura de tipo paralelo (ver Figura 10) de forma que cada sensor toma una primera decisión que se transmite a la central de fusión donde se toma la decisión final.

Consideraremos el típico problema de test de hipótesis binario suponiendo:

$$\begin{aligned} H_0 &: \text{Sin señal}, P(H_0) = P_0 \\ H_1 &: \text{Señal}, P(H_1) = P_1 \end{aligned} \quad (17)$$

Asumiremos independencia estadística entre las observaciones de los sensores y_i de forma que las decisiones locales u_i pueden tomar únicamente dos valores posibles: +1 si se cumple la hipótesis H_1 o -1 si la hipótesis que se cumple es la H_0 . De forma que finalmente la central de fusión decidirá, en fusión de todas estas decisiones parciales, la decisión final \mathbf{u} .

$$\mathbf{u} = f(u_1, \dots, u_n) \quad (18)$$

Para este estudio vamos a suponer que ya se conocen todas estas decisiones locales de forma que centramos el problema en tomar la decisión óptima global.

Esta decisión, en general, se suele obtener suponiendo que si k o más decisores locales deciden la hipótesis H_1 , entonces la decisión global será H_1 .

$$\mathbf{u} = \begin{cases} +1, & \text{si } u_1 + u_2 + \dots + u_n \geq 2k - n \\ -1, & \text{en el resto de casos} \end{cases} \quad (19)$$

Hay que darse cuenta de que esta forma de tomar la decisión es la más genérica posible ya que los casos de funciones de decisión tipo AND o OR quedan incluidas dentro de esta función de decisión global.

En este estudio se va a considerar el problema lo más genéricamente posible, de forma que podemos verlo como un problema clásico de detección con dos hipótesis posibles donde las decisiones individuales locales serán nuestras observaciones.

El decisor óptimo de mínimo coste (según el criterio bayesiano) en este caso es el que se obtiene con el test de verosimilitud dado por:

$$\frac{P(u_1, \dots, u_n | H_1)}{P(u_1, \dots, u_n | H_0)} > \frac{P_0(C_{10} - C_{00})}{P_1(C_{01} - C_{11})} \quad (20)$$

donde C_{ij} es el coste de decidir H_i siendo cierta H_j .

La parte de la izquierda corresponde al test de verosimilitud y la parte de la derecha corresponde al umbral óptimo según el criterio de Bayes.

Si se asume el criterio de mínima probabilidad de error, entonces $C_{00}=C_{11}=0$ y $C_{10}=C_{01}=1$, simplificándose la expresión de la siguiente forma:

$$\frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} > \frac{P_0}{P_1} \quad (21)$$

Utilizando ahora las reglas de Bayes, se obtiene:

$$\frac{P(H_1 | \mathbf{u})}{P(H_0 | \mathbf{u})} > 1 \rightarrow \log \frac{P(H_1 | \mathbf{u})}{P(H_0 | \mathbf{u})} > 0 \quad (22)$$

De forma que se puede obtener una expresión cerrada para implementar la regla de decisión [18].

$$\log \frac{P(H_1 | \mathbf{u})}{P(H_0 | \mathbf{u})} = \log \frac{P_1}{P_0} + \sum_{S^+} \log \frac{PD_i}{PFA_i} + \sum_{S^-} \log \frac{1 - PD_i}{1 - PFA_i} \quad (23)$$

Donde PD es la probabilidad de detección, PFA es la probabilidad de falsa alarma, S^+ es el conjunto de todos los elementos que cumplen que $u_i = +1$, y S^- es el conjunto de todos los elementos i que cumplen que $u_i = -1$.

Por lo tanto se puede concluir que la expresión general de la regla de decisión óptima es la siguiente:

$$f(u_1, \dots, u_n) = \begin{cases} +1, & \text{si } a_0 + \sum_{i=1}^n a_i u_i > 0 \\ -1, & \text{en el resto} \end{cases}$$

$$a_0 = \log \frac{P_1}{P_0} \quad (24)$$

$$a_i = \log \frac{PD_i}{PFA_i}, \text{ si } u_i = +1$$

$$a_i = \log \frac{1 - PFA_i}{1 - PM_i}, \text{ si } u_i = -1$$

La cual se puede ver en forma de esquema en la Figura 15:




Figura 15. Estructura óptima de la central de fusión de datos.

Donde los pesos a_i dependen de la probabilidad de falsa alarma y la probabilidad de pérdidas.

2.4.2 Detección distribuida con decisiones correladas.

Vamos a ver ahora una revisión de diversos estudios que se han realizado sobre la detección distribuida con decisiones correladas.

2.4.2.1 Caso general y estrategias de fusión.

Vamos a ver ahora el esquema sub-óptimo de tipo paralelo con central de fusión (Figura 10), donde asumimos que los sensores locales parten del mismo punto de operación, y donde la distribución de las observaciones es simétrica, lo que implica que las distribuciones conjuntas de las decisiones de los sensores y su decisión fusionada son funciones simétricas de las decisiones de los sensores, estudiando tanto la detección de señales en ruido gaussiano aditivo como en ruido laplaciano [19]

Vamos a considerar ahora el problema de test de hipótesis binario, como en el caso anterior, pero sobre un fondo de ruido de forma que:

$$Y_i = \begin{cases} n_i, & \text{bajo la hipótesis } H_0 \\ n_i + S, & \text{bajo la hipótesis } H_1 \end{cases} \quad (25)$$

Donde el ruido n_i en general no es independiente de un sensor a otro, y cada sensor localmente realiza un test de verosimilitud y genera su propia decisión u_i que puede ser “0” si no encuentra señal sobre el ruido, o “1” si encuentra la señal.

Una vez que cada sensor, por separado, toma su decisión la central de fusión decide globalmente utilizando el test de verosimilitud, como se ha visto en el apartado anterior, donde ahora el umbral no es cero sino que es un cierto valor “ λ ” común para todos los sensores, el cual se determina en función de los requerimientos de *PFA*.

$$\Lambda(\mathbf{u}) = \frac{P(\mathbf{u} | H_1)}{P(\mathbf{u} | H_0)} = \frac{P(u_1, u_2, \dots, u_n | H_1)}{P(u_1, u_2, \dots, u_n | H_0)} \underset{H_0}{\overset{H_1}{>}} \lambda \quad (26)$$

Seguidamente se realiza un estudio pormenorizado de diferentes estrategias posibles en la central de fusión con dos ejemplos numéricos: considerando tres sensores locales que reciben un ruido equicorrelado de media cero y varianza unidad, y considerando dos sensores con ruido laplaciano. Especificando en los dos casos la probabilidad de falsa alarma requerida en la central de fusión de datos.

Es interesante destacar en este punto cuales son estas estrategias de fusión y en que consisten básicamente.

- **Estrategia tipo OR:** La central de fusión decide la hipótesis H_0 (sin señal) únicamente cuando todas las decisiones locales deciden H_0 . De forma que se decide H_1 si cualquier decisor local decide H_1 . En este caso la *PFA* sería:

$$PFA = 1 - \Pr(u_1 = 0, u_2 = 0, \dots, u_n = 0 | H_0) \quad (27)$$

- **Estrategia tipo AND:** La central de fusión decide a favor de la hipótesis H_1 (detección de señal) únicamente si todos los sensores toman esta misma decisión H_1 . Por lo que si algún detector decidiese que no hay señal H_0 , el decisor global decidiría H_0 . En este caso la *PFA* sería:

$$PFA = 1 - \Pr(u_1 = 1, u_2 = 1, \dots, u_n = 1 | H_0) \quad (28)$$

- **Estrategia de la MAYORÍA:** En este caso la central de fusión decide a favor de la hipótesis H_1 (detección) cuando la mayoría de los sensores locales han decidido en este sentido.

Los resultados que se obtienen de [19] nos muestran que el rendimiento de los sistemas empeora cuando la correlación entre los ruidos de los sensores es positiva y creciente, mientras que este rendimiento mejora considerablemente cuando la correlación es negativa y aumenta en magnitud.

Podemos concluir en este caso que cuando tenemos un número pequeño de sensores y las probabilidades de falsa alarma no son muy altas, el rendimiento de los esquemas basados en la regla OR, aunque son relativamente insensibles a los cambios en el coeficiente de correlación, son peores si los comparamos con los esquemas basados en la regla de decisión AND.

2.4.2.2 Fusión óptima conocidas las reglas de decisión y las correlaciones locales, según el criterio de Neyman-Pearson.

A continuación vamos a pasar a describir los estudios realizados en [20] donde se diseña el esquema de combinación óptima en la central de fusión cuando se conocen las reglas de decisión locales y las correlaciones entre las decisiones locales.

Específicamente se estudian las reglas de decisión óptimas en términos del criterio de Neyman-Pearson, demostrando el teorema que muestra que las reglas óptimas de fusión requieren únicamente, para cada subconjunto de decisiones locales, que la probabilidad de que cada decisión local sea positiva (presencia de señal), mostrando además que esta regla de decisión óptima desplaza a la regla óptima que se deriva de [18] cuando las decisiones locales están incorreladas.

Además, se muestra la situación en la que el sistema de detección distribuida se utiliza como un detector local único cuando las decisiones locales están al cien por cien correladas, lo que ocurre únicamente si todos los detectores locales tienen la misma tasa de falsa alarma.

Concluye con el comentario de cómo la correlación se ha expresado mediante un número finito de coeficientes que son esencialmente ciertas probabilidades condicionales, y como se ha podido mostrar que las reglas de decisión se pueden expresar como una función de estos coeficientes de correlación dados.

Finaliza mostrando un modelo de correlación particular que puede ser catalogado mediante un único parámetro denominado índice de correlación, el cual, si vale "0" indica que las decisiones locales son mutuamente independientes, y si vale "1", implica que estas decisiones tienen una dependencia máxima. Se estudian las relaciones entre el funcionamiento de la regla de decisión óptima de fusión y el grado de correlación entre las decisiones locales, mostrando que el rendimiento se degrada cuando el grado de correlación aumenta, y que la ventaja en el rendimiento al utilizar un gran número de detectores locales disminuye cuando incrementa la correlación entre ellos.

Reglas de decisión óptimas con decisiones locales correladas.

Inicialmente considera el problema ya clásico de test de hipótesis binario H_j , $j=0,1$, con una estructura de fusión paralela con central de fusión (como se vió en la Figura 10), suponiendo que se conocen las reglas de decisión de los decisores locales, y que estas decisiones locales están correladas y también se conoce el conjunto finito de coeficientes de correlación C .

$$C = \left\{ E_j \left[\prod_{i \in I} u_i \right] : I \subseteq \{1, \dots, n\}, I \neq \emptyset, j = 0, 1 \right\} \quad (29)$$

Entonces [20] resuelve que teniendo en cuenta que según el criterio de Neyman-Pearson, la regla de decisión óptima para H_0 en función de H_1 se define de la siguiente forma:

$$\delta(U) = \begin{cases} 1, & \text{si } T(\mathbf{u}) > t \\ \gamma, & \text{si } T(\mathbf{u}) = t \\ 0, & \text{si } T(\mathbf{u}) < t \end{cases} \quad (30)$$

Donde $\delta(U)$ es la probabilidad condicional de que suponiendo H_1 , la central de fusión observe $\mathbf{u}=(u_1, \dots, u_n)$. Siendo $T(\mathbf{u})$ el ratio de máxima verosimilitud dado por:

$$T(\mathbf{u}) = \frac{P_1(\mathbf{u})}{P_0(\mathbf{u})}$$

$$P_j(\mathbf{u}) = P_j(u_1, \dots, u_n) = \sum_{I \subseteq A_0} (-1)^{|I|} E_j \left[\prod_{i \in A_1 \cup I} u_i \right] \quad (31)$$

$$A_\mu = \{i : u_i = \mu\}, \quad 1 \leq i \leq n, \quad \mu = 0, 1$$

Siendo las probabilidades de detección y falsa alarma las siguientes:

$$PD(\delta) = E_1[\delta(\mathbf{u})] = P_1(T(\mathbf{u}) > t) + \gamma \cdot P_1(T(\mathbf{u}) = t)$$

$$PFA(\delta) = E_0[\delta(\mathbf{u})] = P_0(T(\mathbf{u}) > t) + \gamma \cdot P_0(T(\mathbf{u}) = t) \quad (32)$$

que satisfacen el criterio de N-P:

$$PFA \leq \alpha \quad \text{y} \quad PD = \max_{\delta} PD(\delta) \quad (33)$$

Teniendo en cuenta todo lo anterior en [20] se sugiere como se ha de implementar la regla de decisión (30) en la central de fusión de decisiones teniendo en cuenta los coeficientes de correlación dados (29). De forma que una vez calculado el ratio de máxima verosimilitud (31), se pueden calcular la constante de incertidumbre γ y el umbral t , en términos del criterio N-P, de la siguiente forma:

$$t = \begin{cases} T(u_i), & \text{si } \lambda_i \leq \alpha < \lambda_{i-1}, \quad i = 1, \dots, N \\ 0, & \text{si } \alpha = 1 \end{cases} \quad (34)$$

$$\gamma = \begin{cases} \frac{(\alpha - \lambda_i)}{\sum_{\{u_i: T(u_i)=t\}} P_0(u_i)}, & \text{si } \lambda_i \leq \alpha < \lambda_{i-1}, \quad i = 1, \dots, N \\ \text{arbitrario}, & \text{si } \alpha = 1 \end{cases} \quad (35)$$

obteniendo finalmente la probabilidad de detección:

$$PD = d_i + (\alpha - \lambda_i) \frac{\sum_{\{u_i: T(u_i)=t\}} P_1(u_i)}{\sum_{\{u_i: T(u_i)=t\}} P_0(u_i)}, \quad \text{si } \lambda_i \leq \alpha < \lambda_{i-1} \quad (36)$$

donde

$$\lambda_i = \begin{cases} 1 - \sum_{j=1}^i P_0(u_j), & \text{si } 1 \leq i \leq N \\ 1, & \text{si } i = 0 \end{cases} \quad (37)$$

$$d_i = \begin{cases} 1 - \sum_{j=1}^i P_1(u_j), & \text{si } 1 \leq i \leq N \\ 1, & \text{si } i = 0 \end{cases} \quad (38)$$

A continuación se aplican las expresiones calculadas anteriormente a dos casos concretos de modelos de correlación entre las fuentes: cuando las decisiones locales son mutuamente independientes bajo la hipótesis H_j , y cuando existe dependencia máxima.

Considerando el primer caso de independencia mutua, se obtienen las siguientes expresiones:

Definiendo el caso de independencia mutua de la siguiente forma:

$$P_j(\mathbf{u}) = \prod_{i=1}^n P_j(u_i), \quad j = 0, 1 \quad (39)$$

Aplicando las expresiones calculadas anteriormente se obtiene:

$$\begin{aligned} P_1(\mathbf{u}) &= \prod_{i \in A_1} PD_i \prod_{k \in A_0} (1 - PD_k) \\ P_0(\mathbf{u}) &= \prod_{i \in A_1} PFA_i \prod_{k \in A_0} (1 - PFA_k) \end{aligned} \quad (40)$$

Donde podemos observar como coinciden con las expresiones obtenidas en (18) en el caso de decisiones locales independientes.

De forma que la condición necesaria y suficiente para que (39) sea cierta es:

$$E_j \left[\prod_{i \in I} u_i \right] = \prod_{i \in I} E_j [u_i] \quad (41)$$

En el segundo caso de decisiones locales maximalmente dependientes, se obtienen las expresiones que se enuncian a continuación:

Considerando que las decisiones locales u_1, u_2, \dots, u_n tienen una dependencia maximal bajo la hipótesis H_j , si para cada pareja de ellas u_i, u_k con $E_j[u_k] \leq E_j[u_i]$ se cumple que:

$$\begin{aligned} P_j(u_i = 1 | u_k = 1) &= 1 \\ P_j(u_i = 0 | u_k = 0) &= 1 \end{aligned} \quad (42)$$

Por lo que la dependencia maximal implica tener unos coeficientes máximos de correlación. De forma que se obtiene:

$$E_j [u_{i_1}, u_{i_2}, \dots, u_{i_q}] = \min_{1 \leq v \leq q} E_j [u_{i_v}] \quad (43)$$

Se obtiene la siguiente expresión bajo las reglas de decisión de N-P vistas anteriormente:

$$P_j(\mathbf{U}) = \begin{cases} 1 - E_j [u_{i_n}] & \text{si } A_0 = \{1, 2, \dots, n\} \\ E_j [u_{i_{s+1}}] - E_j [u_{i_s}] & \text{si } A_0 = \{i_1, i_2, \dots, i_s\} \\ E_j [u_{i_1}] & \text{si } A_0 = 0 \\ 0, & \text{en resto} \end{cases} \quad (44)$$

$1 \leq s < n$

Y si todas las decisiones locales maximalmente dependientes están asociadas con la misma probabilidad de falsa alarma Pf , entonces se obtiene la siguiente expresión para la probabilidad de detección PD :

$$PD = \begin{cases} \max_{1 \leq i \leq n} Pd_i + \min_{1 \leq i \leq n} Pd_i \left[\frac{PFA}{Pf} - 1 \right], & \text{si } PFA \leq Pf \\ \frac{PFA - Pf}{1 - Pf} + \max_{1 \leq i \leq n} Pd_i \frac{1 - PFA}{1 - Pf}, & \text{si } PFA > Pf \end{cases} \quad (45)$$

Se ha de tener en cuenta en este punto que la solución obtenida en (43) corresponde a una solución en el contexto del criterio de N-P cuando la PF es fija. De forma que si en vez de fijar la PFA se impone el criterio natural de que el sistema global decida la hipótesis H_j cuando todos los decisores locales decidan H_j , tendríamos que $t=t_0$ lo que implica que $\gamma=0$, que $PFA=PF$ y que por lo tanto

$PD = \max_{1 \leq i \leq n} Pd_i$. En este caso el sistema de detección distribuida se convertiría en un sistema con un único detector.

Además se ha de tener en cuenta que en general los detectores locales tienen diferentes probabilidades de falsa alarma y por lo tanto la regla de decisión óptima se caracteriza por la expresión vista anteriormente (44).

Modelo especial de correlación.

En este apartado de [20], se estudia un caso especial de modelo de correlación que consiste en utilizar una estructura de correlación entre los decisores locales que puede ser suficientemente caracterizada con un único parámetro de correlación llamado índice de correlación, ρ^j para la hipótesis H_j , $j=0,1$. De forma que si $\rho^j=0$ estamos en el caso de independencia mutua entre decisores locales, y si $\rho^j=1$ estaremos en el caso de dependencia maximal.

Particularmente respecto a (41) y (43) obtendremos:

$$E_j[u_{i_1}, u_{i_2}, \dots, u_{i_q}] = \begin{cases} \prod_{v=1}^q E_j[u_{i_v}] & \text{si } \rho^j = 0 \\ \min_{1 \leq v \leq q} E_j[u_{i_v}] & \text{si } \rho^j = 1 \end{cases} \quad (46)$$

Obteniendo una serie de expresiones cerradas para las probabilidades:

$$\begin{aligned} P_j(\mathbf{u}) &= \sum_{i=0}^m (-1)^i \binom{m}{i} \varepsilon_1^j \cdot \prod_{k=0}^{n-m+i-2} \frac{\rho^j(k+1-\varepsilon_1^j) + \varepsilon_1^j}{1+k\rho^j} \\ PD &= Pd \sum_{m=0}^n \delta(m) \sum_{i=0}^m (-1)^i \binom{m}{i} \prod_{k=0}^{n-m+i-2} \frac{\rho^1(k+1-Pd) + Pd}{1+k\rho^1} \\ PFA &= Pf \sum_{m=0}^n \delta(m) \sum_{i=0}^m (-1)^i \binom{m}{i} \prod_{k=0}^{n-m+i-2} \frac{\rho^0(k+1-Pf) + Pf}{1+k\rho^0} \end{aligned} \quad (47)$$

y la regla de decisión:

$$\begin{aligned} \delta(\mathbf{u}) = \delta(m) &= \begin{cases} 1, & \text{si } w_n(m, t) > 0 \\ \lambda, & \text{si } w_n(m, t) = 0 \\ 0, & \text{si } w_n(m, t) < 0 \end{cases} \\ w_n(m, t) &= \sum_{i=0}^m (-1)^i \binom{m}{i} \left[Pd \prod_{k=0}^{n-m+i-2} \frac{\rho^1(k+1-Pd) + Pd}{1+k\rho^1} - tPf \prod_{k=0}^{n-m+i-2} \frac{\rho^0(k+1-Pf) + Pf}{1+k\rho^0} \right] \end{aligned} \quad (48)$$

De donde se puede deducir, como conclusión final, que el rendimiento se degrada cuando el grado de correlación aumenta, y que la ventaja en el rendimiento al utilizar un gran número de detectores locales disminuye cuando incrementa la correlación entre ellos.

2.4.2.3 Generalización de la detección óptima incorrelada en función de los coeficientes de correlación condicional, bajo el criterio Bayesiano.

En este estudio [21] se generaliza la solución dada por Chair y Varshney en [18] sobre el problema de la fusión de datos para detectores locales binarios con decisiones estadísticamente independientes, utilizando las funciones de expansión de densidad de probabilidad de Bahadur-Lazarsfeld, para el problema de las reglas de decisión para decisiones binarias locales correladas, en términos de los coeficientes de correlación condicional en todos los ordenes, de forma que si todos los coeficientes son cero, las reglas coinciden con las de Chair-Varshney en [18] ya que son estadísticamente independientes.

Se va a considerar para este estudio el esquema ya estudiado de la Figura 10 con un banco de n sensores con dos hipótesis posibles H_0 sin señal, o H_1 detección de señal. De forma que cada detector tomará una decisión $u_i=0,1$ en función de si acepta la hipótesis H_0 o H_1 respectivamente. Estas decisiones locales se transmiten a la central de fusión de datos la cual tomará una decisión u que minimizará la siguiente función de coste Bayesiana donde los C_{jk} son conocidos.

$$\bar{C} = \sum_{j=0}^1 \sum_{k=0}^1 C_{jk} P(\mathbf{u} = j, H_k) \quad (49)$$

Por lo que el problema a resolver es encontrar la regla de decisión $\mathbf{u}=f(u_1, u_2, \dots, u_n)$, $f: \{0,1\}^n \rightarrow \{0,1\}$, que minimice esta función de coste bayesiana.

Como ya hemos visto en el apartado 2.4.1, cuando las decisiones locales están incorreladas existe una solución óptima resuelta por Chair y Varshney [18]. Mientras que en el caso de que las decisiones tengan cierta correlación existen mayores dificultades para encontrar la solución óptima como hemos visto en los apartados precedentes y en [19], [20].

En este estudio se va a abordar el caso de la utilización de funciones de expansión de densidad de probabilidad de Bahadur-Lazarsfeld para diseñar la central de fusión de decisiones y para generalizar las soluciones de Chair y Varshney.

La regla de decisión óptima bajo el criterio bayesiano sigue la siguiente expresión general (20):

$$\lambda(\mathbf{U}) = \frac{P(\mathbf{u} | H_1) > \overset{H_1}{P_0(C_{10} - C_{00})}}{P(\mathbf{u} | H_0) < \underset{H_0}{P_1(C_{01} - C_{11})}} \cong \lambda_0 \quad (50)$$

Donde $P(\mathbf{u})$ es la función de densidad de probabilidad de $\mathbf{u}=[u_1, u_2, \dots, u_n]$, y P_0, P_1 son las probabilidades a priori de las hipótesis H_0 y H_1 .

A continuación expresaremos las probabilidades condicionales $P(\mathbf{u}|H_i)$ en una forma más conveniente introduciendo las siguientes variables normalizadas de forma que z_i tiene media cero y varianza unidad.

$$z_i = \frac{u_i - p_i}{\sqrt{p_i q_i}}, \quad \text{donde } p_i = P(u_i = 1) \quad (51)$$

$$u_i = 1 - p_i, \quad i = 1, 2, \dots, n$$

De forma que considerando los polinomios de Bahadur-Lazarsfeld $\varphi_i(\mathbf{u})$ [27], se obtiene la nueva regla de decisión.

$$\lambda(\mathbf{u}) = \frac{P_1(\mathbf{u} | H_1) \left[1 + \sum_{i<j} \gamma_{ij}^1 z_i^1 z_j^1 + \sum_{i<j<k} \gamma_{ijk}^1 z_i^1 z_j^1 z_k^1 + \dots + \gamma_{12\dots n}^1 z_1^1 z_2^1 \dots z_n^1 \right]}{P_1(\mathbf{u} | H_0) \left[1 + \sum_{i<j} \gamma_{ij}^0 z_i^0 z_j^0 + \sum_{i<j<k} \gamma_{ijk}^0 z_i^0 z_j^0 z_k^0 + \dots + \gamma_{12\dots n}^0 z_1^0 z_2^0 \dots z_n^0 \right]} \quad (52)$$

Donde:

$$P_1(\mathbf{u}) = \prod_{i=1}^n p_i^{u_i} q_i^{1-u_i}$$

$$\gamma_{ij} = \sum_{\mathbf{u}} z_i z_j P(\mathbf{u}), \quad \gamma_{ijk} = \sum_{\mathbf{u}} z_i z_j z_k P(\mathbf{u}), \dots, \gamma_{12\dots n} = \sum_{\mathbf{u}} z_1 z_2 \dots z_n P(\mathbf{u}) \quad (53)$$

$$P(\mathbf{u}) = \sum_{i=0}^{2^n-1} a_i \varphi_i(\mathbf{u}) = P_1(\mathbf{u}) \left[1 + \sum_{i<j} \gamma_{ij} z_i z_j + \sum_{i<j<k} \gamma_{ijk} z_i z_j z_k + \dots + \gamma_{12\dots n} z_1 z_2 \dots z_n \right]$$

Entonces teniendo en cuenta que la PFA para el detector local i es igual a $PFA_i = P(u_i=1|H_0)$ y que la probabilidad de detección para el detector local i es $PD_i = P(u_i=1|H_1)$.

Se puede obtener ratio de máxima verosimilitud genérico en forma logarítmica.

$$\log \lambda(\mathbf{u}) \underset{H_0}{\overset{H_1}{>}} \log \lambda_0 \quad (54)$$

Donde:

$$\log \lambda(\mathbf{u}) = \sum_{i=1}^n u_i \left[\log \frac{(PD_i)(1-PFA_i)}{(1-PD_i)PFA_i} \right] + \sum_{i=1}^n \log \frac{1-PD_i}{1-PFA_i} +$$

$$+ \log \left[\frac{1 + \sum_{i<j} \gamma_{ij}^1 z_i^1 z_j^1 + \sum_{i<j<k} \gamma_{ijk}^1 z_i^1 z_j^1 z_k^1 + \dots + \gamma_{12\dots n}^1 z_1^1 z_2^1 \dots z_n^1}{1 + \sum_{i<j} \gamma_{ij}^0 z_i^0 z_j^0 + \sum_{i<j<k} \gamma_{ijk}^0 z_i^0 z_j^0 z_k^0 + \dots + \gamma_{12\dots n}^0 z_1^0 z_2^0 \dots z_n^0} \right] \quad (55)$$

Siendo esta expresión válida de forma general como regla de decisión para un sistema con decisores locales correlados.

En el caso en el que todos los coeficientes de correlación condicional entre los decisores locales fuesen cero bajo las dos hipótesis planteadas, la expresión (54) se simplifica notablemente de forma que se obtiene la siguiente expresión.

$$-\log \lambda_0 + \sum_{i=1}^n \log \frac{1 - PD_i}{1 - PFA_i} + \sum_{i=1}^n \log \frac{PD_i(1 - PFA_i)}{(1 - PD_i)PFA_i} u_i \begin{matrix} > \\ < \\ < \end{matrix} \begin{matrix} H_1 \\ \\ H_0 \end{matrix} \quad (56)$$

La cual coincide exactamente con la regla de fusión óptima obtenida en [18] cuando los detectores locales son independientes (23) teniendo en cuenta que $\lambda_0 = P_0/P_1$.

2.4.2.4 Funcionamiento asintótico de los sistemas de detección distribuida bajo ruido gaussiano correlado, bajo el criterio Bayesiano.

Consideraremos ahora la detección de una señal constante sobre ruido gaussiano correlado con una gran cantidad de sensores dispersos geográficamente, considerando dos sistemas diferentes de detección, distribuida y centralizada, y teniendo en cuenta dos modelos de correlación: uno donde el coeficiente de correlación entre cada dos sensores decrece geométricamente cuando la separación entre sensores aumenta, y otro donde el coeficiente de correlación entre cada dos sensores es constante. Para cada uno de los modelos vamos a estudiar el efecto de la extensión asintótica de ellos, es decir cuando el número de sensores va creciendo, sobre el sistema de detección y la central de fusión. [22]

Por lo tanto estudiaremos dos modelos de correlación para las observaciones en la detección distribuida de una señal constante conocida sobre ruido gaussiano correlado, tanto en el caso de un sistema de detección distribuido como centralizado.

- ✍ *Primer modelo:* donde el coeficiente de correlación entre las observaciones entre un sensor dado y cualquier otro sensor decrece geométricamente cuando la separación entre sensores aumenta. Cuando el número de sensores N aumenta pero es finito, este modelo puede aproximarse a ciertas situaciones reales.
- ✍ *Segundo modelo:* donde cada par de sensores recibe observaciones equicorreladas.

Investigando en cualquiera de los dos casos el rendimiento asintótico de los sistemas de detección distribuida empleando la regla de conteo y cualquier cosa del sistema central de la que se puedan deducir decisiones basándose en un conjunto de observaciones.

Consideraremos, para realizar este estudio, el caso de detección de una constante bajo ruido gaussiano aditivo, de forma que las hipótesis posibles en este caso son:

$$\begin{aligned} H_0 : X_i &= n_i \\ H_1 : X_i &= n_i + m \end{aligned} \quad (57)$$

Donde los n_i , $i=1,2,\dots,N$ corresponde a las diferentes señales de ruido gaussiano correlado de media cero y varianza unidad en cada uno de los sensores locales, y $m>0$ es la constante conocida buscada.

En el caso de detección distribuida, supondremos que cada sensor local va a tomar su decisión local binaria $u_i=\{0,1\}$ utilizando el mismo test de verosimilitud, de forma que cada sensor utilizará el mismo umbral t .

$$X_i \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_1 \\ H_0 \end{matrix} t \quad (58)$$

Considerando como regla de fusión de decisiones la regla del conteo de forma que obtendremos:

$$l(\mathbf{u}) = \sum_{i=1}^N u_i \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_1 \\ H_0 \end{matrix} \beta \quad (59)$$

Donde $\mathbf{u}=\{u_1, u_2, \dots, u_N\}^T$, y β es el umbral de la central de fusión.

Sin embargo, si en vez de utilizar un sistema distribuido, utilizamos un sistema centralizado, la central de decisión tomará la decisión global óptima clásica dada por la siguiente expresión:

$$l(\mathbf{X}) = \mathbf{M}^T \Lambda^{-1} \mathbf{X} \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_1 \\ H_0 \end{matrix} \lambda \quad (60)$$

Donde $\mathbf{X}=\{X_1, X_2, \dots, X_N\}^T$, $\mathbf{M}=m\{1,1,\dots,1\}^T$, Λ es la matriz de covarianza y λ es el umbral de la central de fusión determinado por la PFA requerida.

Llamando al coeficiente de correlación entre la X_i y X_j : ρ_{ij} , $i,j=1, 2,\dots, N$, vamos a ver a continuación cada uno de los dos modelos mencionados.

Primer modelo: Distribución geométrica con separación de sensores.

En este primer modelo supondremos que existe una distribución geométrica decreciente entre los coeficientes de correlación cuando existe una separación creciente entre los sensores.

$$\rho_{ij} = \rho^{|i-j|} \text{ cuando } 0 \leq \rho < 1 \quad (61)$$

En este caso el test óptimo que se obtiene en el caso de un sistema centralizado a partir de la expresión (59) es el siguiente:

$$l = \frac{1}{1+\rho}(X_1 + X_N) + \frac{1-\rho}{1+\rho} \sum_{i=2}^{N-1} X_i \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_1 \\ H_0 \end{matrix} \lambda \quad (62)$$

Para cada N , l tiene una distribución de tipo gaussiano, y cuando $N \rightarrow \infty$ se obtienen las siguientes expresiones:

$$\begin{aligned} \lambda &= \sqrt{N \frac{1-\rho}{1+\rho}} Q^{-1}(PFA) \\ PD &= 1 - Q\left(m \sqrt{\frac{N(1-\rho)}{1+\rho}}\right) \end{aligned} \quad (63)$$

Donde $Q(y) = 1 - F(y)$, siendo $F(y)$ la CDF.

Así que dada una PFA la PD tiende a 1 de forma exponencial a razón de $N \frac{m^2 (1-\rho)}{2 (1+\rho)}$

Si consideramos ahora el caso del sistema distribuido se obtienen las siguientes expresiones:

$$\begin{aligned} PFA &= P\left(\sum_{i=1}^N u_i > \beta \mid H_0\right) = P\left(\frac{\sum_{i=1}^N u_i - N \cdot PFA}{\sigma_{N0}} > \frac{\beta - N \cdot PFA}{\sigma_{N1}}\right) = Q(h) \\ PD &= P\left(\sum_{i=1}^N u_i > \beta \mid H_1\right) \geq Q\left(h\left(\frac{\sigma_{N0}}{\sigma_{N1}}\right) - \frac{\sqrt{N}(PD - PFA)}{\sqrt{\left(\frac{1+\rho}{1-\rho}\right)(PD - PD^2)}}\right) \end{aligned} \quad (64)$$

De forma que si el número de sensores se hace muy grande $N \rightarrow \infty$ la PD tiende a 1.

Segundo modelo: Correlación igualitaria.

En este modelo, cada par de sensores recibe decisiones equicorreladas de forma que:

$$\rho_{ij} = \rho \text{ cuando } \frac{-1}{N} < \rho < 1 \quad (65)$$

En el caso del sistema centralizado el test de (59) queda de la siguiente forma:

$$l(\mathbf{X}) = \frac{1-\rho}{(N-1)\rho^2 - (N-2)\rho - 1} \sum_{i=1}^N X_i \underset{H_0}{\overset{H_1}{>}} \lambda \tag{66}$$

o de esta otra forma:

$$\sum_{i=1}^N X_i \underset{H_0}{\overset{H_1}{>}} \bar{\lambda}$$

$$PD = Q\left(\frac{\bar{\lambda} - Nm}{\sqrt{N(1-\rho) + N^2\rho}}\right) = Q\left(C - \frac{Nm}{\sqrt{N(1-\rho) + N^2\rho}}\right) \tag{67}$$

Donde $C = Q^{-1}(PFA) = \frac{\bar{\lambda}}{N\sqrt{\rho}}$.

De forma que si $N \rightarrow \infty$, la $PD \rightarrow Q(C - \frac{m}{\sqrt{\rho}})$ que es una constante distinta de 1. Así que en este modelo, infinitos sensores equivale a un solo sensor recibiendo una señal constante de $\frac{m}{\sqrt{\rho}}$.

Las conclusiones que se obtienen del estudio desarrollado en [22] se pueden ver en la siguiente tabla donde se observa el rendimiento asintótico del sistema central y el sistema distribuido para los modelos de correlación mencionados anteriormente.

Sistema de detección	Modelo de Correlación	
	Disminución geométrica con separación de sensores	Correlación igualitaria
Distribuido	1	Fijo, <1
Centralizado	Se acerca a 1 exponencialmente con $N(\frac{m^2}{2})(1-\frac{\rho}{1+\Delta})$	Fijo, <1

Tabla I. Probabilidad de detección (dada una probabilidad de falsa alarma >0 para $N \rightarrow \infty$)

2.4.2.5 Detección distribuida óptima bajo el criterio de Neyman-Pearson en sistemas correlados.

En este apartado comentaremos la detección distribuida óptima bajo el criterio de Neyman-Pearson (N-P) para el caso general en donde las observaciones de cada sensor pueden ser dependientes entre sí [24], [25], fijándonos en la arquitectura de tipo paralelo como la de la Figura 10. En este estudio se presentan las nuevas condiciones necesarias para el uso de los umbrales utilizados en la regla de decisión óptima de N-P, siendo estas condiciones de la misma forma que las utilizadas para la optimización de tipo Bayes.

Basándose en estas nuevas condiciones se describe el algoritmo para la búsqueda de esquemas de detección óptima N-P, que permite el uso de técnicas de azar en la central de fusión [24]. Este algoritmo permite, bien la utilización de reglas de fusión óptimas a lo largo de los sensores, o bien la búsqueda de mejores esquemas entre aquellos que utilicen una serie de reglas de fusión posibles y fijas.

Posteriormente en [25] se complementan estos estudios con una serie de ejemplos de utilización del algoritmo y extensiones al caso de decisiones locales con múltiples bits y a la tipología tipo árbol.

Habitualmente el estudio de los criterios de N-P para esquemas de detección distribuidos ha estado limitado a los casos donde las observaciones entre sensores son estadísticamente independientes, es más aquellos estudios que han intentado generar esquemas de detección distribuida óptimos bajo el criterio de N-P para los casos en donde no hace falta asumir independencia condicional, no son válidos en general ya que necesitan que la curva de operación recibida del conjunto (ROC) sea cóncava, lo que en general es una condición muy difícil de cumplir ya que habitualmente la ROC es desconocida.

Nos basaremos en el esquema paralelo típico ya estudiado anteriormente utilizando criterios de tipo Neyman-Pearson. Tendremos $k=1, \dots, N$ sensores, donde se observan \mathbf{x}_k valores particulares del vector aleatorio \mathbf{X}_k , siendo estas $\mathbf{X}_1, \dots, \mathbf{X}_k$ correladas. Cada sensor tomará una decisión local u_k de la variable aleatoria U_k de entre la hipótesis H_1 (detección de señal) o H_0 (sin detección). Llamando $\gamma_k(\mathbf{x}_k)$ a la probabilidad de decidir $U_k=1$ a partir de la observación \mathbf{x}_k .

Finalmente en la central de fusión se tomará la decisión final comprobando las realizaciones particulares u_0 de la variable aleatoria U_0 de forma que si $u_0=0$ se tomará la decisión H_0 y si $u_0=1$ la decisión H_1 . Llamando $\gamma_0(\mathbf{u})$ a la probabilidad de decidir $U_0=1$ dadas una serie de decisiones locales $\mathbf{u}=(u_1, \dots, u_N)$.

De forma que la serie completa de reglas de decisión y reglas de fusión se pueden describir por el parámetro $\gamma=(\gamma_0, \gamma_1, \dots, \gamma_N)$. Y según el criterio de Neyman-Pearson buscamos γ que maximice la probabilidad de detección $PD(\gamma)=\text{Prob}(U_0=1 | H_1)$ fijada una probabilidad de falsa alarma $PFA(\gamma)=\text{Prob}(U_0=1 | H_0)=\alpha$, con $0 \leq \alpha \leq 1$.

Por lo que tenemos que la lista completa de reglas de decisión locales y por tanto la regla de fusión global bajo el criterio de N-P se puede describir como:

$$\begin{aligned} \gamma &= (\gamma_0, \gamma_1, \dots, \gamma_N) \\ \text{Buscando } \gamma &\text{ que satisfaga que:} \\ \max_{\gamma} PD(\gamma) &\text{ sujeto a la condición de que } PFA(\gamma) = \alpha \\ 0 &\leq \alpha \leq 1 \end{aligned} \quad (68)$$

Asumiendo que las funciones de densidad de probabilidad conjuntas (pdfs) de todas las observaciones de los sensores son conocidas bajo las hipótesis clásicas, lo que implica que se pueden procesar las densidades marginalmente.

Condiciones necesarias bajo el criterio de N-P

A continuación en [24] se presenta una serie de nuevas condiciones necesarias para poder relacionar el umbral utilizado en la regla de fusión bajo el criterio óptimo de N-P con los umbrales utilizados en las reglas de decisión locales bajo el criterio de N-P óptimo. Pudiéndose demostrar que estas condiciones necesarias tienen exactamente la misma forma que si utilizamos criterios de tipo bayesiano. Concluyendo que estas condiciones necesarias requieren cierta aleatorización en la central de fusión.

En concreto estas condiciones necesarias serían las siguientes:

Dada una red tipo paralelo (Figura 10) con N sensores y una central de fusión fija, con $\mathbf{X}_1, \dots, \mathbf{X}_N$ observaciones bajo las hipótesis H_0 y H_1 . Tenemos que:

- \mathbf{X}_k es un vector aleatorio de dimensión m_k con una función densidad de probabilidad $f_{X_k}(\mathbf{X}_k | H_j)$ sin ninguna masa puntual de probabilidad bajo las hipótesis $j=0, 1$.
- $\frac{D_{1k}(\mathbf{X}_k)}{D_{0k}(\mathbf{X}_k)}$ es una variable aleatoria continua escalar con una función de densidad de probabilidad sin ninguna masa puntual de probabilidad bajo las hipótesis anteriores.

$$\begin{aligned} D_{jk}(\mathbf{X}_k) &= f_{X_k}(\mathbf{X}_k | H_j) \cdot \\ &\sum_{\tilde{u}_k} \left[\text{Prob}(U_0 = 1 | \tilde{U}_k = \tilde{u}_k, U_k = 1) - \text{Prob}(U_0 = 1 | \tilde{U}_k = \tilde{u}_k, U_k = 0) \right] \\ &\cdot \text{Prob}(\tilde{U}_k = \tilde{u}_k | \mathbf{X}_k = \mathbf{x}_k, H_j) \end{aligned} \quad (69)$$

Donde:

- $j=0, 1, k=1, \dots, N$.
- \tilde{u}_k es un valor específico de la variable aleatoria \tilde{U}_k que se obtiene al tomar las decisiones locales excluyendo la del sensor k -ésimo.
 $\tilde{U}_k = (U_1, U_2, \dots, U_{k-1}, U_{k+1}, \dots, U_N)$

- $\text{Prob}(U_0 = 1 | \tilde{U}_k = \tilde{u}_k, U_k = u_k) = \text{Prob}(U_0 = 1 | (U_1, \dots, U_N) = (u_1, \dots, u_N))$ que describe la regla de decisión γ_0 .
 - La suma de (69) es sobre todos los valores de \tilde{u}_k
 - La probabilidad condicional de (69) $\text{Prob}(\tilde{U}_k = \tilde{u}_k | \mathbf{X}_k = \mathbf{x}_k, H_j)$ se define como un límite para cuando los eventos condicionantes se reducen a un punto.
- *Definiendo la función $\gamma_0(\mathbf{u})$ como la probabilidad que se decida $U_0=1$ cuando $\mathbf{U}=\mathbf{u}$. Lo que comúnmente se denomina la función de aleatorización de la central de fusión. El criterio óptimo de N-P solo se puede obtener con una serie de reglas de decisión en los sensores $(\gamma_1, \dots, \gamma_N)$ y una regla de fusión central γ_0 que satisfaga:*

$$\gamma_k(\mathbf{x}_k) = \text{Prob}(U_k = 1 | \mathbf{X}_k = \mathbf{x}_k) = \begin{cases} 1, & \text{si } D_{1k}(\mathbf{x}_k) > \lambda D_{0k}(\mathbf{x}_k) \\ 0, & \text{si } D_{1k}(\mathbf{x}_k) < \lambda D_{0k}(\mathbf{x}_k) \end{cases} \quad (70)$$

Con $\lambda \geq 0$ para $k=1, \dots, N$ todas iguales [25] y con $\gamma_0(\mathbf{u})$ de la siguiente forma:

$$\gamma_0(\mathbf{u}) = \text{Prob}(U_0 = 1 | \mathbf{U} = \mathbf{u}) = \begin{cases} 1, & \text{si } \text{Prob}(\mathbf{U} = \mathbf{u} | H_1) > \lambda \text{Prob}(\mathbf{U} = \mathbf{u} | H_0) \\ \delta_0(\mathbf{u}), & \text{si } \text{Prob}(\mathbf{U} = \mathbf{u} | H_1) = \lambda \text{Prob}(\mathbf{U} = \mathbf{u} | H_0) \\ 0, & \text{si } \text{Prob}(\mathbf{U} = \mathbf{u} | H_1) < \lambda \text{Prob}(\mathbf{U} = \mathbf{u} | H_0) \end{cases} \quad (71)$$

O con la serie de decisiones locales equivalentes $(\gamma^*_0, \gamma^*_1, \dots, \gamma^*_N)$ donde se satisface que $\gamma_k(\mathbf{x}_k) = \gamma^*_k(\mathbf{x}_k), k=1, \dots, N$ excepto para el \mathbf{x}_k que cumpla $\text{Prob}(\mathbf{x}_k < \mathbf{X}_k \leq \mathbf{x}_k + d\mathbf{x}_k) = 0$ y $\gamma_0(\mathbf{u}) = \gamma^*_0(\mathbf{u})$ para todo \mathbf{u} excepto para el \mathbf{u} que se produzca con probabilidad cero bajo las dos hipótesis.

De donde a partir de (69) se pueden obtener la *PD* y la *PFA* de la siguiente forma:

$$\begin{aligned} PD(\gamma) &= \int_{\{x_1 | D_{11}(x_1) > \lambda D_{01}(x_1)\}} D_{11}(x_1) dx_1 + Q_{11} \\ PFA(\gamma) &= \int_{\{x_1 | D_{11}(x_1) > \lambda D_{01}(x_1)\}} D_{01}(x_1) dx_1 + Q_{01} \end{aligned} \quad (72)$$

Donde Q_{11} u Q_{01} son constantes que no dependen de γ_1 .

Para los resultados anteriores hemos supuesto que el umbral λ es común para todos los sensores, de forma que si se considera un incremento del umbral en el primer sensor de λ a $\lambda^* = \lambda + \varepsilon$, con $\varepsilon > 0$ se obtiene la siguiente relación:

$$\Delta PD < (\lambda + \varepsilon) \Delta PFA \quad (73)$$

De forma que el cambio en el umbral del primer sensor implica un cambio en la $\text{Prob}(\mathbf{u}|H_i)$, $i=0$, llamando al nuevo valor $\text{Prob}^*(\mathbf{u}|H_i)$, $i=0$.

Por lo que para volver a tener la *PFA* requerida deberemos aplicar la aleatorización en la central de fusión aumentando el umbral en un pequeño valor de forma que obtengamos un \mathbf{u}' para el cual:

$$\lambda^*_0 = \frac{\text{Prob}^*(\mathbf{u}'|H_1)}{\text{Prob}^*(\mathbf{u}'|H_0)} \quad (74)$$

Incrementando el parámetro de aleatorización de la central de fusión que inicialmente vale $\delta=0$ en $\Delta\delta$.

$$\Delta\delta = \frac{\Delta PFA}{\text{Prob}^*(\mathbf{u}'|H_0)} \quad (75)$$

Obteniendo ahora una probabilidad de detección:

$$\begin{aligned} PD^* &= (PD - \Delta PD) + \Delta\delta \text{Prob}^*(\mathbf{u}'|H_1) \\ &= PD + \lambda^*_0 \Delta\delta \text{Prob}^*(\mathbf{u}'|H_0) - \Delta PD \\ &= PD + \lambda^*_0 \Delta PFA - \Delta PD \\ &> PD + (\lambda + \varepsilon)\Delta PFA - \Delta PD \\ &> PD \end{aligned} \quad (76)$$

Teniendo en cuenta que λ_0^* es el umbral del primer sensor que cumple que $\lim_{\varepsilon \rightarrow 0} \lambda^*_0 = \lambda_0 > \lambda$, de forma que si existe $\varepsilon > 0$, $\lambda_0^* > \lambda + \varepsilon$.

Por lo tanto, se demuestra que si se elige un umbral para la central de fusión distinto de λ , podemos ir cambiándolo para conseguir una *PD* mayor para la misma *PFA*, siendo el umbral óptimo para la central de fusión el λ buscado.

Finalmente se ha de tener en cuenta que todos los resultados que se han visto hasta ahora suponen una curva ROC cóncava lo cual en general es complejo de asumir a priori.

Algoritmo óptimo de búsqueda de esquemas de detección bajo el criterio N-P.

Dada la necesidad de la aleatorización en la central de fusión para poder llegar a la decisión óptima en [24] se presenta un algoritmo capaz de encontrar los algoritmos óptimos bajo el criterio N-P para esquemas de detección distribuidos basándose en las condiciones necesarias anteriores. Para ello el algoritmo permite elegir el mejor esquema posible de entre una serie de esquemas fijos de reglas de fusión. Utilizando para ello el procedimiento de Gauss-Seidel.

El algoritmo utilizado sería el siguiente:

Para $\lambda = \lambda_{min}$ hasta λ_{max} con pasos de $\Delta\lambda$.

Para $\delta = 0$ hasta 1 con un pasos pequeños.

- Se inicializa el algoritmo eligiendo las reglas de decisión de los sensores definiendo una serie de regiones de decisión A_1, \dots, A_N definidas como:

$$U_i = \begin{cases} 1, & \mathbf{x}_i \in A_i \\ 0, & \mathbf{x}_i \notin A_i \end{cases}$$

- Inicializando $\lambda' = \lambda$.
- Se calcula la $\text{Prob}(\mathbf{U} = \mathbf{u} | H_j)$, $j=0,1$, con $\mathbf{u} = (u_1, u_2, \dots, u_N)$, $u_i = 0,1$, $i=1, \dots, N$.
- Si $0 < \delta < 1$ buscamos el valor de \mathbf{u}' que mejor aproxime $\text{Prob}^*(\mathbf{u}' | H_1) / \text{Prob}^*(\mathbf{u}' | H_0)$ a λ' y actualizamos λ' con este valor.
- Si $|\lambda' - \lambda| > \Delta\lambda$ hemos acabado con este δ .
- Si $|\lambda' - \lambda| \leq \Delta\lambda$. Se determina la regla de decisión γ_0 utilizando la expresión (71) y los valores de λ' y δ .
- Para cada sensor i , $i=1, \dots, N$
 - o Calcula A_i con la expresión (70)
 - o Y los valores actuales para γ_0 y A_j , $j=1, \dots, N$, $j \neq i$.
- Si A_i , $i=1, \dots, N$, y γ_0 tienen unas variaciones respecto a la última iteración pequeñas continua con el siguiente paso, sino vuelve al paso de cálculo de la probabilidad condicional.
- Calcula la PD y la PFA basándose en los A_i , $i=1, \dots, N$, y γ_0 .

Resumiendo para una λ específica, vamos a ir inicializando todas las reglas de decisión de forma aleatoria. Y recalculando cada una de las reglas de decisión hasta que todas estas reglas converjan.

Ejemplo de utilización del algoritmo

En general podemos hacer esto con todas las λ que nos den la probabilidad de falsa alarma requerida y elegir la solución que nos de un mejor rendimiento. Pero ésta es una tarea muy tediosa y, además, habitualmente existe una única solución para un mismo λ . Si esto es así, se puede demostrar que la probabilidad de falsa alarma es monótona respecto a λ por lo que en vez de ir buscando todos los λ posibles, podemos simplificar el procedimiento utilizando el algoritmo de Newton junto con la ecuación (70).

Para ilustrar estas ideas vamos a considerar el ejemplo típico del problema de dos sensores con hipótesis binarias [25]:

$$\begin{aligned} H_0 : x_1, x_2 &\approx N(0, 0, 1, 1, \rho) \\ H_1 : x_1, x_2 &\approx N(s_1, s_2, 1, 1, \rho) \end{aligned} \tag{77}$$

Donde la $N(a,b,c,d,e)$ es la función de densidad de probabilidad normal gaussiana bivariable con:

$$\begin{aligned} E[(x_1, x_2)^T] &= (a, b)^T \\ \text{Var}(x_1) &= c \\ \text{Var}(x_2) &= d \\ E[x_1, x_2] &= e\sqrt{cd} \end{aligned} \quad (78)$$

Asumiendo la regla de decisión fija a tipo AND y $N(1,2,1,1,0.2)$, se obtiene una curva ROC cóncava y una PFA monótona respecto a λ . Sin embargo se demuestra que si se inicializa el algoritmo de una manera diferente, se obtienen soluciones que convergen de manera distinta. Por ejemplo si en el caso anterior se utiliza una regla de decisión tipo XOR con $\rho=0.975$ se obtienen seis soluciones para $\lambda=0.5$ que corresponden a diferentes PFA 's y más de una es óptima bajo el criterio de N-P.

Otro ejemplo es considerar el caso anterior pero con independencia estadística entre los sensores y con una distribución del ruido de tipo Gaussiano. En este caso la curva ROC que se obtiene no es cóncava por lo que no podremos intentar buscar el óptimo de N-P maximizando " $PD-\lambda \cdot PFA$ ".

Extensión al caso de decisiones locales de múltiples bits.

Vamos a considerar ahora [25] el caso en el que en cada sensor $k = 1, \dots, N$ se toma una decisión de múltiples bits y se envían a la central de fusión para tomar la decisión final. En este caso podemos generalizar los resultados obtenidos hasta ahora reemplazando en (69) $D_{jk}(\mathbf{x}_k)$ por:

$$\begin{aligned} D_{jkl}(\mathbf{X}_k) &= f_{\mathbf{x}_k}(x_k | H_j) \cdot \\ &\sum_{\tilde{u}_{kl}} \left[\text{Prob}(U_0 = 1 | \tilde{U}_{kl} = \tilde{u}_{kl}, U_{kl} = 1) - \text{Prob}(U_0 = 1 | \tilde{U}_{kl} = \tilde{u}_{kl}, U_{kl} = 0) \right] \\ &\cdot \text{Prob}(\tilde{U}_{kl} = \tilde{u}_{kl} | \mathbf{X}_k = \mathbf{x}_k, H_j) \end{aligned} \quad (79)$$

De forma que todas las reglas para generar cada bit en cada sensor deberán utilizar la misma λ si se cumple que la PFA de $\frac{D_{1k}(\mathbf{X}_k)}{D_{0k}(\mathbf{X}_k)}$ bajo la hipótesis H_j es mayor que cero para $\frac{D_{1k}(\mathbf{X}_k)}{D_{0k}(\mathbf{X}_k)} > 0, j = 0,1$.

Extensión para topología tipo árbol.

Si consideramos el caso en el que, en vez de considerar la topología típica tipo paralelo, consideramos una tipología genérica con N sensores distribuidos en forma de red tipo árbol sin feedback, utilizando una matriz \mathbf{R} como elemento que indica la estructura de intercomunicación entre sensores, definiendo la entrada a un sensor como:

$$I_k = \{i : \mathbf{R}_{ik} = 1, \text{ para todo } i\} \quad (80)$$

Y las decisiones de entrada como:

$$\bar{U}_{I_k} = (U_{k_1}, U_{k_2}, \dots, U_{k_N}) \quad (81)$$

Donde k_1, k_2, \dots, k_n son elementos de I_k

Se obtiene de (69) la siguiente expresión:

$$D_{jk}(\mathbf{x}_k, \bar{u}_{I_k}) = \sum_{\bar{u}_{\{k \cup \{k\}^c}} \left[\text{Prob}(\mathbf{x}_k, \bar{U}_{\{k\}^c} = \bar{u}_{\{k\}^c} \mid H_j) \cdot \left[\begin{aligned} &\text{Prob}(U_0 = 1 \mid \bar{U}_{\{k\}^c} = \bar{u}_{\{k\}^c}, U_k = 1, \mathbf{x}_k, H_j) - \\ & - \text{Prob}(U_0 = 1 \mid \bar{U}_{\{k\}^c} = \bar{u}_{\{k\}^c}, U_k = 0, \mathbf{x}_k, H_j) \end{aligned} \right] \right] \quad (82)$$

Donde $\{k\}^c = \{1, \dots, k-1, k+1, \dots, N\}$

Concluyendo, se han proporcionado nuevos resultados teóricos en la detección distribuida óptima NP, bajo unas nuevas condiciones necesarias para la optimización y una serie de análisis del número de puntos fijos que pueden hacer falta al utilizar el procedimiento de Gauss-Seidel para intentar mejorar la regla de fusión, así como unos nuevos algoritmos para facilitar la búsqueda de los esquemas de detección distribuida bajo el criterio de NP óptimo.

2.4.2.6 Cuantización binaria óptima bayesiana bajo ruido gaussiano correlado.

Describiré a continuación la cuantización binaria óptima bajo el criterio de Bayes para la detección de cambios en la media de una pareja de variables dependientes aleatorias gaussianas.

Para ciertos problemas de parametrización, como los problemas de señales significativas o los coeficientes de correlación, la cuantización óptima es alcanzable mediante la utilización en cada observación de un umbral único, de forma igual que en los casos de observaciones independientes. En otros casos, una observación es mejor ignorarla o cuantizarla mediante dos umbrales diferentes, lo que solo tiene sentido si estamos en el caso de observaciones dependientes. Por otro lado, como distinción entre los casos de independencia, es sabido que bajo ciertas circunstancias, la fusión mediante reglas tipo XOR es óptima, y en estos casos es complicado elegir la regla de decisión correcta.

Demostrándose [26] que todos los posibles tipos de problemas de este tipo pueden ser descritos mediante la variación de unos pocos pero importantes parámetros: la señal observada en cada sensor y el coeficiente de correlación de las observaciones de cada dos sensores.

Puesto que el diseño de las reglas óptimas de fusión es en general conocido respecto al diseño de las reglas óptimas en los sensores, este estudio se centra en comprender que tipo de procesado que se debe realizar en los sensores para

conseguir un rendimiento óptimo. Para ello se realiza un exhaustivo estudio de las tres situaciones posibles que son las reglas tipo AND, OR y XOR.

Bajo condiciones de independencia condicional, las observaciones de los sensores, para un rendimiento óptimo están cuantizadas por si solas con un único umbral. Sin embargo, en general, los resultados indican que incluso este simple problema de ruido gaussiano presenta aparentemente un funcionamiento muy complejo, ya que, por ejemplo, para sistemas que utilizan la regla de fusión tipo XOR, se demuestra que si utilizamos reglas de cuantización con un solo umbral no se puede alcanzar nunca el óptimo, pero investigaciones de tipo numérico muestran como existen casos en los que el uso de técnicas de decisión tipo XOR mejoran la eficiencia si se comparan con los mejores sistemas distribuidos que utilicen reglas tipo AND o OR.

Para estas reglas de decisión AND y OR, se pueden realizar mejores progresos. Demostrándose que cualquier grupo de reglas que sean óptimas para las reglas de fusión tipo OR lo son también para las tipo AND bajo una serie de probabilidades que se pueden calcular fácilmente. Por esta razón, el estudio considera únicamente las técnicas de fusión tipo AND de forma que sirvan para obtener las reglas óptimas de decisión en los sensores tanto para las tipo AND como para las tipo OR.

Considerando estas premisas el estudio divide el espacio de todos los problemas posibles de ruido gaussiano en tres regiones: “buena”, “mala”, “fea”, demostrando matemáticamente que:

- Cualquier problema en la región “buena”, debe utilizar reglas de decisión óptimas como las utilizadas bajo condiciones de independencia condicional, de forma que estas reglas de los sensores utilizan un único intervalo de las regiones de decisión.
- Cualquier problema en la región “mala”, se ha podido demostrar matemáticamente que el esquema óptimo puede no utilizar intervalos únicos de las regiones de decisión en los dos sensores. No solo eso sino que un sensor puede utilizar un único intervalo de la región de decisión y las observaciones del otro sensor ser ignoradas, o los dos sensores utilizar intervalos de la región de decisión no únicos, y ninguno de ellos ser ignorado.
- En cuanto a la región “fea”, está dominada por la regla de decisión tipo XOR, ya que ésta no es nunca óptima fuera de esta región, de forma que sin esta región fea, cualquiera de las tres reglas puede dominar.

En general podemos expresar los problemas de detección como la generación de una decisión razonable de entre un par de hipótesis posibles, que podemos denominar “ H_0 ” y “ H_1 ” basándose en las observaciones x_i , $i=1, \dots, n$, distribuidas de acuerdo a unas densidades de probabilidad.

$$\begin{aligned} H_0 &: \text{con densidad } P_{H_0}(x_1, \dots, x_n) \\ H_1 &: \text{con densidad } P_{H_1}(x_1, \dots, x_n) \end{aligned} \quad (83)$$

Este problema se convierte en un problema de tipo distribuido o descentralizado cuando los datos se cuantifican, en cada uno de los sensores locales, al introducirlos en un esquema con una regla de decisión que típicamente suele ser de tipo binaria.

$$U_i = U_i(x_i) = \begin{cases} 1; & x_i \in A_i \\ 0; & x_i \notin A_i \end{cases} \quad (84)$$

$$A_i = \bigcap_{j=1}^{M_i} (l_{i,j}, u_{i,j})$$

De forma que a la central de fusión le llegan estas decisiones locales U_i , y las combina en una única decisión global U . Estas densidades P_{H0} y P_{H1} suelen ser multivariantes de tipo gaussiano.

Si consideramos la detección de la media en una serie de observaciones correladas de tipo gaussiano en un esquema con dos sensores distribuidos, de forma que tratamos de detectar señales conocidas bajo un fondo de ruido. En concreto hipótesis de datos gaussianos correlados con diferentes medias:

$$H_0 : x_1, x_2 \approx N(0, 0, 1, 1, \rho) \quad (85)$$

$$H_1 : x_1, x_2 \approx N(s_1, s_2, 1, 1, \rho)$$

Donde la N es la función de densidad de probabilidad normal gaussiana bivariante:

$$N(s_1, s_2, \sigma_1^2, \sigma_2^2, \rho) = \frac{1}{2\pi(1-\rho^2)\sigma_1\sigma_2} \exp\left(\frac{-1}{2(1-\rho^2)} \left[\left(\frac{x_1-s_1}{\sigma_1}\right)^2 - 2\rho \left(\frac{x_1-s_1}{\sigma_1}\right) \left(\frac{x_2-s_2}{\sigma_2}\right) + \left(\frac{x_2-s_2}{\sigma_2}\right)^2 \right]\right) \quad (86)$$

Considerando las tres reglas de fusión habituales AND, OR, XOR que quedan de la siguiente forma:

AND :

$$U = \begin{cases} 1, & \text{si } U_1 = U_2 = 1 \\ 0, & \text{en el resto} \end{cases}$$

OR :

$$U = \begin{cases} 0, & \text{si } U_1 = U_2 = 0 \\ 1, & \text{en el resto} \end{cases} \quad (87)$$

XOR :

$$U = \begin{cases} 1, & \text{si } U_1 = 0, U_2 = 1 \\ 1, & \text{si } U_1 = 1, U_2 = 0 \\ 0, & \text{en el resto} \end{cases}$$

Siendo los A_j de (84), con el umbral de decisión τ :

$$\text{Para la regla AND tendremos: } \dots \quad A_j = \left\{ x_j : \frac{\int_{A_j} P_{H_1}(x_i, x_j) dx_i}{\int_{A_j} P_{H_0}(x_i, x_j) dx_i} \geq \tau \right\} \quad (88)$$

$$\text{Para la regla OR tendremos: } \quad A_j = \left\{ x_j : \frac{1 - \int_{A_j} P_{H_1}(x_i, x_j) dx_i}{1 - \int_{A_j} P_{H_0}(x_i, x_j) dx_i} \geq \tau \right\} \quad (89)$$

Para la regla XOR tendremos:

$$A_j = \left\{ x_j : 1 - 2 \int_{A_j} P_{H_1}(x_i, x_j) dx_i \geq \tau \left[1 - 2 \int_{A_j} P_{H_0}(x_i, x_j) dx_i \right] \right\} \quad (90)$$

Teniendo en cuenta que existe una relación de equivalencia entre las reglas AND y OR, haremos un estudio por separado de la regla AND y de la regla XOR.

Regla de decisión AND.

Para el caso de la utilización de una regla de decisión en la fusión de datos de tipo AND obtendremos el siguiente test óptimo:

$$x_1(s_1 - \rho s_2) + x_2(s_2 - \rho s_1) \underset{H_0}{\overset{H_1}{>}} \lambda = (1 - \rho)^2 \ln(\tau) + \frac{s_1^2 - 2\rho s_1 s_2 + s_2^2}{2} \quad (91)$$

Obteniendo como resultado una región de decisión óptima en forma de medio plano que se puede describir gráficamente como una división del plano (s_1, s_2) en tres regiones: región buena, región mala, región fea.

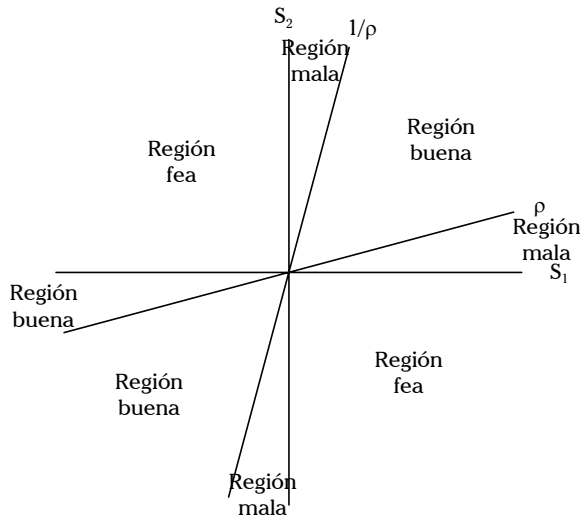


Figura 16. División del plano de señal en tres regiones.

En concreto para la región “buena” obtenemos la siguiente expresión, suponiendo $\rho > 0$, donde los dos miembros de la expresión deben ser > 0 a la vez.

$$(s_1 - \rho s_2)(s_2 - \rho s_1) \geq 0 \tag{92}$$

Lo que nos lleva al dibujo de la Figura 16 donde la región buena es la que se encuentra entre las líneas $s_2 = \rho s_1$ y $s_2 = (1/\rho)s_1$.

En cuanto a la región “mala”, se debería definir como la región complementaria a la región “buena” pero se puede demostrar que no es posible definirla así, por lo que se define, para un ρ positivo, como la región complementaria a la región “buena” intersectada con el primer y tercer cuadrante ($s_1 s_2 > 0$)

En esta región se demuestra que la convergencia solo es posible en algunos casos degenerados donde uno de los sensores se ignora completamente.

En cuanto a la región “fea”, es la región del espacio que queda al descartar las otras dos regiones, que corresponde con el segundo y cuarto cuadrante ($s_1 s_2 < 0$).

Entonces si $\rho = 0$ (señales independientes) cada cuantificador deberá utilizar un único y finito umbral lo que implica restringirnos a las reglas de decisión en la central de fusión de tipo AND y OR. Si ρ no es cero y seguimos utilizando estas reglas de decisión, la cuantificación de un único umbral es óptima en el caso de utilizar “buenos” parámetros pero nunca es óptima en el caso de parámetros “malos”.

Regla de decisión XOR.

Para el caso de la utilización de una regla de decisión tipo XOR, se demuestra que es óptima bajo observaciones dependientes, y en particular óptima en el problema de funciones de densidad de probabilidad bivariables de tipo gaussiana como en el caso anterior.

Entonces se puede demostrar que la cuantización con un único umbral finito en cada sensor nunca es óptima si se utiliza la regla de decisión de tipo XOR.

Si asumimos que el sensor 2 utiliza un umbral único $A_2 = \{x_2: x_2 > l_{2,1}\}$, de acuerdo con la expresión (84) tenemos:

$$A_1 = \left\{ e^{s_1 x_1 - s_1^2 / 2} \left[1 - 2Q \left(\frac{l_{2,1} - s_2 - \rho(x_1 - s_1)}{\sqrt{1 - \rho^2}} \right) \right] = T_1(x_1) > T_2(x_1) = \tau \left[1 - 2Q \left(\frac{l_{2,1} - \rho x_1}{\sqrt{1 - \rho^2}} \right) \right] \right\} \quad (93)$$

Donde el segundo término, si $\rho > 0$, decrece monótonamente desde τ a $-\tau$ pasando por el cero en $x_1 = l_{2,1} / \rho$. Obteniendo:

$$\begin{aligned} s_1 > 0: \quad & \lim_{x_1 \rightarrow -\infty} T_1(x_1) = 0 \\ & \lim_{x_1 \rightarrow \infty} T_1(x_1) = -\infty \\ s_1 < 0: \quad & \lim_{x_1 \rightarrow -\infty} T_1(x_1) = \infty \\ & \lim_{x_1 \rightarrow \infty} T_1(x_1) = 0 \end{aligned} \quad (94)$$

Entonces si $x_1 \rightarrow \pm\infty$ ambos o ninguno de los dos se encuentra en A_1 , de forma que si x_2 se cuantiza de acuerdo con A_2 , x_1 no puede ser cuantizado utilizando un único umbral. Por lo que habrá que utilizar por lo menos uno de los cuantizadores con múltiples umbrales o ignorar uno de los datos.

Ahora las regiones de decisión en el plano, utilizando umbrales de cuantización únicos, se convierten en la forma intuitiva de la utilización del primer y tercer cuadrante para una decisión y el segundo y cuarto cuadrante para la otra decisión.

Finalmente se hace una extensión de las definiciones de las regiones buena, mala y fea para los problemas con n sensores $n > 2$, donde se utiliza la regla de fusión tipo AND.

Para ello se utilizan vectores \mathbf{x} con matriz de covarianza \mathbf{R} y media cero bajo la hipótesis H_0 y s bajo la hipótesis H_1 .

Si nos concentramos en el sensor n° 1, definiendo $\mathbf{x}_1 = \{x_2, x_3, \dots, x_n\}$ y $\mathbf{s}_1 = \{s_2, s_3, \dots, s_n\}$ se obtiene:

$$\mathbf{R} = \begin{pmatrix} r_{11} & \mathbf{r}_{11}^T \\ \mathbf{r}_{11} & \mathbf{R}_{11'} \end{pmatrix} \quad (95)$$

Donde el bloque inferior derecho es una matriz de $(n-1) \times (n-1)$.

Siendo A_1 :

$$A_1 = \{\mathbf{x}_1 : x_2 \in A_2 \cap x_3 \in A_3 \cap \dots \cap x_n \in A_n\} \quad (96)$$

De forma que la cuantificación del sensor n° 1 en un único intervalo semi-positivo queda de la forma:

$$0 < \hat{s}_{11'} < s_1 < \frac{r_{11}}{r_{11} - \hat{\sigma}_{11'}^2} \hat{s}_{11'} \quad (97)$$

Y la cuantificación en un semi-intervalo negativo queda de la forma:

$$0 > \hat{s}_{11'} > s_1 > \frac{r_{11}}{r_{11} - \hat{\sigma}_{11'}^2} \hat{s}_{11'} \quad (98)$$

Donde se han definido las variables:

$$\begin{aligned} \hat{s}_{11'} &= \mathbf{r}_{11'}^T \mathbf{R}_{11'}^{-1} \mathbf{s}_{11'} \\ \hat{\sigma}_{11'}^2 &= r_{11} - \mathbf{r}_{11'}^T \mathbf{R}_{11'}^{-1} \mathbf{r}_{11'} \end{aligned} \quad (99)$$

Lo cual se puede extender a cualquier otro orden de los sensores.

Obteniendo las mismas regiones ahora multidimensionales, donde la región “mala” es la complementaria a la región “buena” y el resto del espacio desconocido es la región “fea”.

2.4.2.7 Acercamiento Bayesiano a la fusión de decisiones utilizando modelos jerárquicos.

Para finalizar vamos a mencionar el estudio [23] donde se reexamina el problema del diseño de reglas de fusión para la detección distribuida, y donde se introduce un novedoso método que utiliza herramientas de deducción bayesiana. Específicamente el problema de la fusión de decisiones se reformula utilizando modelos jerárquicos, y se propone la utilización de muestreadores de tipo Gibbs para la realización de una fusión posterior basada en la probabilidad. Lo que esencialmente es idéntico a la utilización de reglas de fusión óptimas basadas en la verosimilitud, cuando éstas existen. Este método es de utilidad en aquellas situaciones complejas donde se trabaja sin conocimiento de las estadísticas de la señal ni del ruido y los métodos que utilizan reglas de fusión óptimas basadas en la verosimilitud no se pueden utilizar o no son fáciles de obtener.

Si comparamos este novedoso método con los métodos tradicionales basados en reglas de fusión de verosimilitud, las ventajas que se obtienen son las siguientes:

- Robustez frente al asignamiento a priori de probabilidades, ya que no requiere de esta asignación en cada hipótesis hasta que no se tengan en la práctica.
- Gran potencial, ya que se puede aplicar igualmente a diferentes situaciones que se encuentren en la fusión de decisiones. Incluso es flexible para su extensión al caso de observaciones correladas.
- Particularmente, el método puede ser adaptado fácilmente a aquellas situaciones donde la fusión basada en la verosimilitud no es de aplicación.

En cuanto a las desventajas, existe una obvia y es que requiere una gran complejidad computacional.

Vamos a comenzar el estudio fijándonos en el modelo jerárquico equivalente para el problema típico de fusión de datos utilizando decisión binaria.

El modelo jerárquico requiere de la consecución de dos pasos o etapas:

- Conocimiento del fenómeno y la estructura de dependencias, lo que permite la creación de un modelo jerárquico que se aproxime razonablemente al problema físico a resolver. Lo que requerirá de la realización de ciertas aproximaciones.
- Selección de las prioridades para cada uno de los parámetros aleatorios que se plantean en el modelo jerárquico anteriormente descrito. Estableciendo las reglas de decisión adecuadas.

En el caso particular que nos ocupa de un modelo típico de fusión de decisiones tipo paralelo como el de la Figura 17 izquierda, definiremos inicialmente el problema de test de hipótesis binario de la forma habitual:

$$Z = \begin{cases} 0, & \text{si } H_0 \text{ es verdadero} \\ 1, & \text{si } H_1 \text{ es verdadero} \end{cases} \quad (100)$$

Donde bajo las hipótesis bayesianas se puede demostrar que la variable aleatoria Z se suele asumir comunmente como una variable aleatoria de tipo Bernoulli con probabilidad de éxito θ . Que a su vez puede no ser una probabilidad fija sino que se puede asumir con una distribución tipo *beta*.

Una vez modelada la variable aleatoria Z , las observaciones locales x_i se pueden especificar como probabilidades condicionales dependientes del valor de Z , de forma que los detectores locales tomarán una cierta decisión fija u_i apartir de este modelo de las observaciones las cuales servirán como entrada de datos a la central de fusión que tomará la decisión final u_0 . Como se puede observar en la Figura 17 derecha.

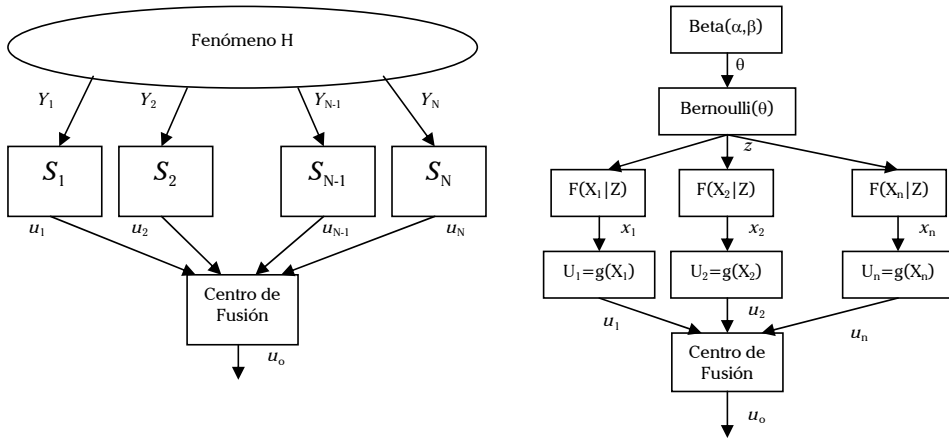


Figura 17. Esquema de fusión de datos tipo paralelo y reformulación utilizando modelos jerárquicos.

La distribución conjunta de todos los parámetros involucrados en el modelo jerárquico se puede formular de la siguiente forma:

$$f(\theta, Z, \mathbf{X}, \mathbf{U}) = f(\theta)P(Z | \theta)f(\mathbf{X} | Z)I_{\mathbf{U}=g(\mathbf{X})} \tag{101}$$

Donde se define la función de indicación como:

$$I_{\mathbf{U}=g(\mathbf{x})} = \begin{cases} 1, & \text{si } \mathbf{U} = g(\mathbf{X}) \\ 0, & \text{en resto} \end{cases} \tag{102}$$

Se asume independencia condicional entre las observaciones de los sensores, lo que simplifica considerablemente el estudio y está implícito en la Figura 17.

En este tipo de problemas complejos, con un gran número de parámetros involucrados, no es posible la obtención de una solución analítica, por lo que se suele utilizar una herramienta muy potente denominada aproximación bayesiana por muestreo, la cual permite buscar las distribuciones empíricas a posteriori de los parámetros de interés. Generando muestras de estos parámetros aleatorios que siguen las distribuciones posteriores de los parámetros condicionados con las observaciones.

Este tipo de aproximación basado en el muestreo se reconoce como la clave para la resolución de problemas de tipo bayesiano donde las soluciones analíticas, o aproximaciones de tipo analítico, fallan en situaciones complejas. Como ejemplo de este tipo de técnicas aparecen los métodos MCMC (Harkov Caín Monte Carlo), y en concreto para problemas de tipo jerárquico un método en concreto: el muestreo Gibbs.

El muestreo Gibbs básicamente consiste en un esquema de muestreo iterativo, donde en cada iteración los parámetros se muestrean alternativamente utilizando todas sus distribuciones condicionales, de forma que bajo ciertas condiciones, la

secuencia de muestras converge a una distribución específica que implica a todas las probabilidades a posteriori de todos los parámetros.

En el caso que nos ocupa del esquema jerárquico de la Figura 17, podemos utilizar el muestro Gibbs para cada capa del modelo suponiendo independencia entre capas de la siguiente forma:

$$\text{Para } \theta: f(\theta | Z, \mathbf{X}, \mathbf{U}) = f(\theta | Z) = \frac{f(\theta, Z)}{P(Z)} = \frac{f(\theta)P(Z | \theta)}{\int f(\theta)P(Z | \theta)d\theta} \quad (103)$$

$$\text{Para } \mathbf{X}: f(\mathbf{X} | \theta, Z, \mathbf{U}) = f(\mathbf{X} | Z, \mathbf{U}) = \frac{f(\mathbf{X} | Z)I_{\mathbf{U}=g(\mathbf{X})}}{\int_{\mathbf{U}=g(\mathbf{X})} f(x | z)dx} \quad (104)$$

$$\text{Para } Z: f(Z | \theta, \mathbf{X}, \mathbf{U}) = f(Z | \theta, \mathbf{X}) = \frac{f(\theta, Z, \mathbf{X})}{f(\theta, \mathbf{X})} = \frac{f(\theta, Z, \mathbf{X})}{\sum_Z f(\theta, Z, \mathbf{X})} \quad (105)$$

$$\text{donde } f(\theta, Z, \mathbf{X}) = f(\theta)P(Z | \theta)f(\mathbf{X} | Z)$$

Entonces el muestreo bayesiano basado en las reglas de fusión se puede resumir de la siguiente forma:

- Inicialización: Se eligen de manera arbitraria unos valores iniciales para las variables desconocidas: θ , \mathbf{X} y \mathbf{Z} . Aunque los valores iniciales de \mathbf{X} deben ser consistentes con las reglas de decisión locales $\mathbf{U}=g(\mathbf{X})$. Llamando a estas variables iniciales: θ^0 , \mathbf{X}^0 y \mathbf{Z}^0 .
- Muestreo bayesiano: En este punto se generan las muestras hasta conseguir la convergencia siguiendo las respectivas probabilidades a posteriori dadas por \mathbf{U} .
 - Dados θ , \mathbf{X}^t y \mathbf{Z}^t generamos θ^{t+1} , \mathbf{X}^{t+1} y \mathbf{Z}^{t+1} utilizando el generador de variables aleatorias especificado por las distribuciones condicionales dadas por (103) bajo (105).
 - Incrementamos t y repetimos el procedimiento hasta obtener T muestras que garanticen la convergencia.
- Inferencia: En este paso obtenemos el resultado final de fusión a partir de las decisiones locales muestras de la variable θ , $\theta^1, \theta^2, \dots, \theta^T$ que se ha asumido que siguen la distribución posterior θ . Entonces utilizando la regla de decisión siguiente:

$$Z = \begin{cases} 1, & \text{si } \bar{\theta} \geq 0.5 \\ 0, & \text{si } \bar{\theta} < 0.5 \end{cases} \quad (106)$$

Donde $\bar{\theta}$ es la media de las muestras de θ , excluyendo t_0 muestras del transitorio inicial.

$$\bar{\theta} = \frac{1}{T - t_0} \sum_{t=t_0+1}^T \theta^t \tag{107}$$

Teniendo en cuenta que el parámetro θ se define como la probabilidad de que $Z=1$ cuando la regla de decisión de fusión es esencialmente la regla de fusión con probabilidad posterior utilizando la aproximación del muestreo bayesiano.

Si se extiende el estudio al caso de test de hipótesis múltiple, definiendo M hipótesis posibles de forma que la variable Z queda de la siguiente forma:

$$Z = \begin{cases} 1, \text{ si } H_1 \text{ es verdadero} \\ \dots \\ M, \text{ si } H_M \text{ es verdadero} \end{cases} \tag{108}$$

Donde ahora asignamos una probabilidad a priori a cada hipótesis posible p_i , de forma que $\sum_i p_i = 1$, y la variable Z se convierte en una variable aleatoria multinomial con probabilidades de éxito $(p_1, \dots, p_{M-1}) \cong \theta$. Utilizando variables aleatorias tipo *Dirichlet* que es una generalización de la función *beta* para el caso multidimensional para la distribución tipo multinomial que es la generalización multidimensional de Bernouilli para la variable Z .

Por lo que el modelo jerárquico es similar al descrito anteriormente quedando de la siguiente forma:

- $\theta = (p_1, \dots, p_{M-1})$, con variables aleatorias tipo Dirichlet con parámetros $\alpha_1, \dots, \alpha_M$. Donde:

$$f(\theta) = \frac{\Gamma(\alpha_1 + \dots + \alpha_M)}{\Gamma(\alpha_1) \dots \Gamma(\alpha_M)} p_1^{\alpha_1-1} \dots p_{M-1}^{\alpha_{M-1}-1} \left(1 - \sum_{i=1}^{M-1} p_i \right)^{\alpha_M-1} \tag{109}$$

Donde $\Gamma(\cdot)$ es la función gamma $\Gamma(z) = \int_0^\infty e^{-t} t^{z-1} dt$.

- Z de tipo multinomial($1, \theta$)
- $F(\mathbf{X}|Z)$ es la función de verosimilitud que en este caso es diferente de un sensor a otro.
- $U_i = g(\mathbf{X}_i)$ es la regla de decisión local.

2.5 Conclusiones

Para finalizar este capítulo vamos a comentar las principales conclusiones a las que hemos llegado tras realizar el estudio teórico de la fusión de decisiones, haciendo primero una síntesis de los conceptos más destacados.

2.5.1 Síntesis del capítulo

Comenzamos el capítulo comentando el concepto de fusión como forma de combinar datos de múltiples sensores para mejorar los resultados, pudiéndose combinar o fusionar a varios niveles, aunque con cuidado, ya que en la práctica la fusión de datos puede producir peores resultados que los obtenidos utilizando sensores apropiados a cada situación. Como generalización del concepto se introdujo el modelo general de la fusión de datos, comentando las distintas aplicaciones habituales y arquitecturas de fusión.

A continuación se pasaron a describir los fundamentos de la detección distribuida con sensores múltiples, como mejora de los métodos clásicos de esquemas centralizados, con configuraciones serie y paralelo. Se hizo desde dos puntos de vista: desde el punto de vista de la formulación de Neyman-Pearson, basada en solucionar el test de hipótesis para una cierta *PFA* dada, buscando las reglas de decisión óptimas; y desde el punto de vista de la formulación Bayesiana, cuyo objetivo es minimizar el riesgo bayesiano, para lo que se asignan una serie de costes a los diferentes caminos o vías de procesado a seguir, con un conocimiento a priori de las probabilidades de cada una, asumiendo sensores independientes.

Ambas técnicas utilizan modelos estadísticos de señal y ruido de tipo paramétrico y habitualmente gaussianos. Como contrapunto se tratan los temas avanzados en la detección distribuida con sensores múltiples, fijándose en los métodos óptimos de detección distribuida de señales débiles, de señales no paramétricas, detección distribuida robusta y esquemas secuenciales de detección distribuida.

Finalmente en el punto 2.4, se trató la detección distribuida y fusión de decisiones óptima en sistemas con múltiples sensores, comenzando por la fusión de datos óptima en sistemas de detección con múltiples sensores, donde se supuso inicialmente independencia estadística y se obtuvo la regla global óptima de fusión que minimiza la probabilidad de error.

En el caso de las decisiones correladas, comenzamos por la situación general donde se elige el esquema sub-óptimo tipo paralelo con central de fusión y se estudian las diferentes estrategias de fusión posibles, tipo OR, tipo AND o de la mayoría, concluyendo que, si tenemos un número pequeño de sensores y las probabilidades de falsa alarma no son muy altas, el rendimiento de los esquemas basados en la regla OR, aunque son relativamente insensibles a los cambios en el

coeficiente de correlación, son peores si los comparamos con los esquemas basados en la regla AND.

A continuación pasamos a comentar la fusión óptima si las reglas de decisión y las correlaciones locales se conocen, según el criterio de Neyman-Pearson, demostrándose que las reglas óptimas de fusión requieren únicamente, para cada subconjunto de decisiones locales, que la probabilidad de cada decisión local sea positiva. Se muestra la situación extrema en la que el sistema de detección distribuida se convierte en un único detector local si las decisiones están completamente correladas, lo que ocurre únicamente cuando los detectores locales tienen todos la misma *PFA*. Concluimos con un modelo de correlación catalogado mediante el índice de correlación, que va desde decisiones locales mutuamente independientes (si vale 0) hasta decisiones locales con dependencia máxima (si vale 1), mostrando que el rendimiento de la regla de fusión se degrada cuando el grado de correlación aumenta y que la ventaja en el rendimiento, al utilizar un gran número de detectores locales, disminuye cuando incrementa la correlación entre ellos.

Seguidamente pasamos a describir la generalización de la detección óptima incorrelada, comentada anteriormente, en función de los coeficientes de correlación condicional, bajo el criterio Bayesiano, utilizando las funciones de expansión de densidad de probabilidad de Bahadur-Lazarsfeld, para diseñar la central de fusión de decisiones, y el funcionamiento asintótico de los sistemas de detección distribuida bajo ruido gaussiano correlado, donde se estudian dos modelos de correlación para las observaciones en la detección distribuida de una señal constante conocida sobre ruido gaussiano correlado, tanto en el caso de un sistema de detección distribuido como centralizado.

Consecutivamente se estudia la detección distribuida óptima bajo el criterio de Neyman-Pearson en sistemas correlados bajo las mismas condiciones utilizadas para la optimización de tipo bayesiana, introduciendo técnicas de azar en la central de fusión, concluyendo que se han proporcionado nuevos resultados teóricos en la detección distribuida óptima, bajo nuevas condiciones necesarias para la optimización y una serie de análisis del número de puntos fijos que pueden hacer falta al utilizar el procedimiento de Gauss-Seidel para intentar mejorar la regla de fusión, así como nuevos algoritmos para facilitar la búsqueda de los esquemas de detección distribuida bajo el criterio NP óptimo.

Posteriormente se estudia la cuantización binaria óptima bayesiana bajo ruido gaussiano correlado, para la detección de cambios en la medida de una pareja de variables dependientes aleatorias gaussianas, centrándose en comprender qué tipo de procesamiento se debe realizar en los sensores para conseguir un rendimiento óptimo, con reglas de tipo AND, OR y XOR, dividiendo el espacio de todos los problemas posibles de ruido gaussiano en tres regiones: “buena”, donde se pueden utilizar las mismas reglas óptimas utilizadas bajo independencia condicional, utilizando un único intervalo de las regiones de decisión; “mala”, donde el esquema óptimo puede no utilizar intervalos únicos de las regiones de decisión; y “fea”, que está dominada por la regla de decisión tipo XOR, no siendo nunca

óptima, de forma que, sin esta región “fea”, cualquiera de las tres reglas de decisión puede dominar.

Finalmente se reexamina el problema del diseño de reglas de fusión para la detección distribuida con un acercamiento Bayesiano a la fusión de decisiones utilizando modelos jerárquicos, utilizando muestreadores de tipo Gibbs para la realización de la fusión posterior basada en la probabilidad, permitiendo robustez, gran potencial y facilidad de adaptación, aunque una mayor carga computacional.

2.5.2 Conclusiones finales

Hemos realizado un estudio exhaustivo de los diferentes algoritmos de detección distribuida. Donde como se ha podido observar, un elemento clave es la posibilidad o no de asumir incorrelación entre las decisiones. Cuando tal cosa es posible, todos los algoritmos se simplifican, y esencialmente se vuelven equivalentes.

Al enfocar nuestra tesis hacia aplicaciones concretas, consideramos fundamental analizar si la hipótesis de incorrelación es razonable, y si no lo es, elegiremos la forma más simple de incluir su efecto en las correspondientes ecuaciones. Pensamos que muchas de las técnicas anteriormente expuestas aportan en general una mejora relativamente pequeña a los algoritmos de fusión, a cambio de incrementar notablemente su complejidad. No obstante consideramos de interés la revisión realizada, y oportuna su inclusión en este capítulo previo a las aplicaciones. Como veremos, haremos sobre todo uso del trabajo expuesto en [20], ya que aporta soluciones relativamente simples para el caso de la correlación, de fácil particularización cuando asumir incorrelación es razonable.

CAPÍTULO 3:

Aplicación a Sistemas de detección de Incendios



Capítulo 3: Aplicación a Sistemas de detección de Incendios.

3.1 Contexto

Las primeras investigaciones en detección de incendios se inician en el GTS, en la década de los noventa con una serie de experiencias piloto que dieron lugar al “Sistema Electrónico de Detección Precoz de Incendios” (SEDPII), desarrollado en la localidad Alicantina de Alcoy, con la utilización de sensores térmicos de línea [11], que a su vez permitieron realizar las primeras publicaciones sobre el tema [28], [29], [30] y [31].

Gracias a ellos y con el devenir de los años surgió la gran oportunidad de desarrollar un sistema totalmente autónomo de detección de focos de incendios forestales que dio lugar al proyecto final de carrera “Sistema de procesado para la Detección Automática de Incendios” realizado por el autor de esta tesis.

En la actualidad se presta servicio en el “Cerro Carpio” del término municipal de Sinarcas con un sistema piloto denominado “Detección Electrónica y Localización de Focos de Incendio” (DELFIN) [12] y en el Parque Natural de la Devesa de “El Saler”, en el término municipal de Valencia, denominado “Detección de Incendios mediante Sensores Térmicos” (DISTER) [13], proyectos financiados por la Generalitat Valenciana y el Ayuntamiento de Valencia respectivamente. Ambos sistemas están funcionando a pleno rendimiento en cuanto a prevención y detección de incendios en ambientes hostiles de funcionamiento. Fruto de estos trabajos se han realizado algunas publicaciones [32], [33], [34], [35], [36].

Cabe destacar que, tras el éxito de la implantación de estos sistemas, se concedió al GTS en el 2003 un proyecto del Ministerio de Ciencia y Tecnología [37], para la mejora y desarrollo de los algoritmos de procesado utilizados y fruto del cual se ha desarrollado en el 2004 otro proyecto final de carrera relacionado con el tema que lleva por título “Aplicación para la adquisición y el procesado de imágenes térmicas para la detección de focos de incendio”. En el marco de dicho proyecto de investigación [37] se desarrolla esta parte de la tesis doctoral aquí presentada.

3.2 Antecedentes.

El incremento de temperatura generado por la aparición de un fuego en un cierto lugar de un área extensa bajo vigilancia altera tanto la intensidad como el espectro de la radiación infrarroja emitida, lo que puede ser aprovechado mediante la disposición de un sensor adecuado. En este principio se fundamentan los sistemas de detección y monitorización de fuegos forestales que utilizan sensores colocados en satélites para captar imágenes infrarrojas del área cubierta (véase la referencia [38] como revisión bastante completa y actualizada de esta tecnología). Habitualmente las imágenes son procesadas con algoritmos relativamente simples, basados en contrastar el nivel recogido en cada píxel con un umbral adecuadamente seleccionado.

Desde el punto de vista de detección precoz estos sistemas están bastante limitados por el excesivo retardo en la detección y la baja resolución. Retardo y resolución pueden variar bastante de unos sistemas a otros pero típicamente podemos hablar de una periodicidad de cobertura de 1 día (en el mejor de los casos varias horas) y de una resolución de 1 Km. De hecho, su utilización más habitual es en la monitorización de la evolución de fuegos extensos o en el mapeado de zonas que han sido afectadas por fuegos ya extinguidos.

Una evidente alternativa “terrestre” a los sistemas de satélite, es colocar sensores en torres o lugares con adecuada visibilidad que permitan una vigilancia continua y con resolución al menos similar a la que tendría un vigilante humano, al que se pretende sustituir. La palabra sensor se utiliza en este caso en sentido amplio, como un sistema capaz de medir la energía infrarroja en celdas de resolución rango-acimut, conceptualmente igual a como un radar convencional resuelve la energía electromagnética. Por ejemplo, el sensor puede ser un array que mueve un haz direccional mecánicamente en acimut y electrónicamente en elevación, o una cámara de infrarrojos.

En todo caso en cada barrido o “mirada” completos al entorno vigilado, dispondremos de una imagen infrarroja del mismo, existiendo una correspondencia entre cada celda de resolución y un píxel de la misma. Realizaciones o experiencias pilotos de estos sistemas existían ya (véanse [39] y [40] a modo de ejemplo), que por un lado demostraban la viabilidad de la alternativa, y por otro sugerían la posibilidad de mejoras muy significativas en las prestaciones mediante el uso del tratamiento de las señales registradas.

3.3 Investigaciones

Las investigaciones se centran en los aspectos relativos al tratamiento de las señales captadas por el correspondiente sensor. El tratamiento se hace localmente, es decir allí donde se sitúa el sensor, generándose en su caso de forma automática alarmas, que son enviadas a una estación central, junto con información adicional de la misma, tal como su situación (coordenadas) o alguna característica de interés si procede (rapidez de crecimiento del fuego, por ejemplo).

La incorporación de algoritmos avanzados de tratamiento de señal en esta aplicación, aporta un valor añadido muy importante al sistema en diferentes aspectos:

- Posibilidad de detección automática ajustando la probabilidad de falsa alarma a un valor deseado (el control de la probabilidad de falsa alarma es especialmente importante en esta aplicación, dado el coste que supone la movilización de los recursos de extinción).
- Maximización de la probabilidad de detección mediante la incorporación, en los algoritmos, de características tanto del entorno (sobre el que se contrastará la posible presencia de fuego), como del propio fuego (por ejemplo, normalmente sólo nos preocuparán incrementos de temperatura que manifiesten una evolución creciente con el tiempo).
- En relación con lo anterior y, en particular, la posibilidad de discernir fuegos descontrolados de efectos ocasionales que producen incrementos puntuales de temperatura (por ejemplo un coche atravesando la zona vigilada, una desaparición rápida de la nubosidad...).
- Un diseño adaptado a cada sub-área dentro del área bajo vigilancia, que tenga en cuenta la no homogeneidad del entorno, y de la propia resolución del sensor (en general las celdas de resolución lejanas se corresponderán con áreas de dimensiones reales mucho mayores que las cercanas).
- Un diseño adaptado a cada momento (día-noche, estado atmosférico, época del año,...)
- Simplificación de los recursos de comunicaciones necesarios, ya que estrictamente sólo es preciso enviar la alarma (cuando exista) y la posible información adicional anteriormente mencionada. Un simple mensaje corto GSM puede ser una solución razonable en muchos casos.

Todo lo anterior supone en definitiva que, mediante el tratamiento de señal, puede conseguirse en esta aplicación una efectiva sustitución del ser humano como alternativa evidente a la vigilancia presencial. Adicionalmente, se posibilita la vigilancia nocturna, dadas las características de la señal infrarroja.

3.4 Sistema global

Como fruto de las investigaciones desarrolladas en la línea de investigación de tratamiento de señales infrarrojas aplicado a la detección automática de incendios forestales, se ha constituido un sistema de vigilancia para la detección de incendios que cubre grandes extensiones de terreno, mediante la utilización de sensores infrarrojos, estratégicamente situados, capaces de detectar cambios de temperatura en la zona de estudio e informar de la detección de fuegos incontrolados, o sea de posibles focos de incendios.

Para ello se ha dispuesto un sistema basado en una serie estaciones dispersas (las llamaremos *locales* en lo sucesivo), estratégicamente situadas para cubrir la zona de cobertura deseada, y una estación *central* que recibe la información de las estaciones locales (Figura 18). Estos últimos no son únicamente sensores pasivos de infrarrojos, si no que incorporan “in situ” una etapa de procesado de la información con un detector automático de alarmas, consiguiendo así una efectiva sustitución del vigilante humano y minimizar los recursos de comunicaciones necesarios en la transmisión de la información a la estación central. Ello implica la existencia de un sistema local de procesado digital que genera las posibles alarmas de forma automática, siendo la localización de la alarma la información básica a enviar a la estación central, la cual hace un seguimiento de las alarmas producidas por las estaciones locales, representando éstas en un mapa de la zona, mediante un sistema de información geográfica (GIS).




Figura 18. Sistema global.

Por lo tanto este sistema se basa en la instalación de tantos puntos de observación como sean necesarios para cubrir el área geográfica a controlar, donde la ubicación ideal de dichos puntos de observación se define en cada caso particular atendiendo a las peculiaridades del entorno y a los requerimientos de funcionamiento y operación del sistema.

En cada uno de dichos puestos de observación se instala una cámara térmica con su correspondiente unidad de adquisición, ordenador, sistema de transmisión de primer nivel de comunicaciones (RDSI, WLAN, línea dedicada,...), comunicaciones de seguridad o de “segundo nivel” (GSM, GPRS,...), además de un

sistema de vídeo de apoyo a las intervenciones y todos los elementos necesarios para la mecanización y alimentación eléctrica de los equipos.

A su vez, en la Estación Central se instalan los controladores del sistema de infrarrojos y del sistema de vídeo, el control de las comunicaciones y el sistema de información geográfica para la gestión de alarmas. Además, se cuenta con equipos de comunicaciones de primer y segundo nivel que enlazan con cada uno de los puestos de observación y de pantallas separadas para la monitorización del sistema de gestión y de las cámaras térmicas y visibles.

Por lo tanto el sistema de detección de incendios global consta de las siguientes partes o etapas más significativas (Figura 19):

Estaciones locales, en las que podemos considerar:

- Etapa de adquisición de la información por medio de sensores de infrarrojos o termográficos.
- Etapa de tratamiento de las señales adquiridas por parte de un ordenador tipo PC, donde se procesa la información y se generan los ficheros de alarmas.
- Etapa de transmisión de la información de alarma donde se transmiten estas alarmas por un sistema vía cable y/o radio.
- Etapa en paralelo de adquisición, telecontrol y envío, a petición de la estación central, de imágenes de vídeo visibles en tiempo real.

Estación central, en la que podemos considerar:

- Etapa de recepción de alarmas por parte de la estación central de alarmas, vía cable y/o radio.
- Etapa de presentación de la información recogida en un mapa GIS de la zona de cobertura.
- Etapa de petición y telecontrol de imágenes de video.




Figura 19. Partes del sistema de detección de incendios.

En este capítulo nos vamos a centrar únicamente en la etapa de tratamiento de la señal, asumiendo que la etapa de adquisición consiste en una cámara de infrarrojos, con los correspondientes medios de digitalización, que proporciona las señales adecuadas para nuestro sistema de procesado de señal.

3.5 Subsistema de tratamiento de señal

En esta etapa del sistema se pretende tomar las imágenes adquiridas en la etapa de adquisición e ir procesándolas píxel a píxel, considerando no sólo la imagen del instante actual si no imágenes de instantes de tiempo anteriores en la forma que describimos en lo que sigue.

La imagen infrarroja procedente de la cámara está formada por una matriz de píxeles. Cada píxel puede ser asociado a una celda de resolución con sus correspondientes acimuts y rango o distancia. Denominaremos *barrido* a cada una de las imágenes (matriz de valores de nivel infrarrojo) que sucesivamente iremos procesando cada cierto intervalo de tiempo (Figura 20). El sistema de procesado debe ser capaz de decidir automáticamente, barrido a barrido, para todos y cada uno de los píxeles si existe una alarma (detección de fuego incontrolado). Detectada la alarma, ésta se enviará a la estación central indicando sus correspondientes coordenadas acimut-rango que se corresponderán con la ubicación del píxel en la matriz.

Una primera aproximación al problema de la detección automática de alarmas, es decidir que hay alarma cuando el valor del píxel de la celda de resolución en estudio supere un cierto umbral predeterminado. Si conocemos la distribución estadística del ruido, el umbral puede ser ajustado para satisfacer una cierta Probabilidad de Falsa Alarma (*PFA*), obteniendo una Probabilidad de Detección (*PD*) que depende de la relación señal a ruido (*SNR*).

Normalmente, el ruido infrarrojo (es decir el registro debido a la emisión infrarroja del propio entorno, sin considerar fuegos ni efectos ocasionales) en una zona amplia de vigilancia está altamente correlado (en pocas palabras, la temperatura en celdas cercanas y sobre todo en la misma celda en barridos sucesivos no debe variar demasiado si no aparece fuego o alguna otra circunstancia excepcional que altere la temperatura de la celda bajo análisis), por lo que podemos aprovecharnos de esta información adicional sobre el ruido para mejorar la *SNR* utilizando un predictor del nivel del ruido en la celda bajo análisis, a partir de los niveles existentes en dicha celda en barridos anteriores (Figura 20). A continuación restaremos la predicción del valor actual medido en la celda bajo análisis, mejorando así la *SNR*. Mejorar la *SNR* supone en definitiva mejorar la *PD* para una *PFA* dada.




Figura 20. Sucesión de imágenes (matrices) en diferentes barridos y predicción del ruido infrarrojo

Por otro lado, si la detección la basamos sólo en el nivel (reducido en ruido por el predictor) del píxel en el último barrido, no hay manera de distinguir entre fuegos incontrolados y aumentos de temperatura ocasionales que no deberían provocar la activación de la alarma (debidos por ejemplo a cambios bruscos del viento, de las nubes, un coche atravesando ocasionalmente la celda de resolución,...). Llamaremos a las alarmas generadas por estos efectos ocasionales, alarmas indeseadas y a su probabilidad de detección Probabilidad de Detección de Alarmas Indeseadas (PDAI).

Dos son las diferencias entre un fuego incontrolado y una alarma indeseada que podemos explotar. Por un lado, un fuego incontrolado debe manifestar un incremento continuado del nivel medido de señal en sucesivos barridos (en caso contrario podría existir un fuego, pero estaría bajo control, ya que no aumenta significativamente la temperatura con el paso del tiempo, véase la Figura 21). Por otra parte, asumiremos que los barridos sucesivos están lo suficientemente cerca en tiempo como para que el mencionado crecimiento en caso de fuego incontrolado sea lento en comparación con las variaciones de temperatura debidas a efectos ocasionales (por ejemplo aparece un nivel elevado de temperatura por un efecto ocasional, que en el siguiente barrido ha desaparecido), o debidas al ruido residual infrarrojo del entorno que queda una vez restada la predicción tal y como se indicó anteriormente. En definitiva se trataría de basar la detección, no en el nivel medido en la correspondiente celda de resolución en un solo barrido, sino considerando la evolución de las medidas en un cierto número de barridos sucesivos




Figura 21. Evolución del nivel en un píxel cualquiera desde el barrido n al n+3

Las ideas anteriores llevan a un esquema (Figura 22) a aplicar a cada una de las celdas de resolución (píxeles de la imagen infrarroja), con dos partes claramente diferenciadas: la predicción y la detección. En dicha figura el vector \mathbf{x} se forma agrupando un cierto número de niveles medidos en una misma celda en barridos sucesivos, y el vector \mathbf{w} se forma de igual manera con un cierto número de valores del mismo píxel, previos a los incluidos en \mathbf{x} o a partir de una imagen patrón, tal y como describimos más adelante.

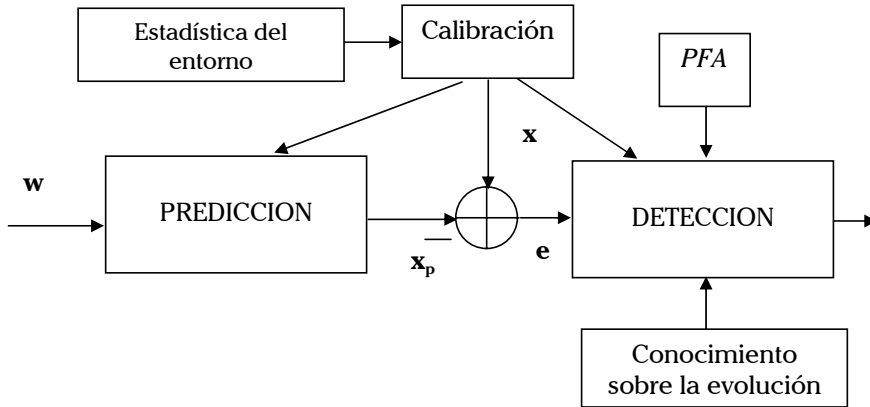


Figura 22. Esquema general del procesado

Tal y como se indica en la Figura 22 la parte relativa a predicción se diseña a partir del conocimiento (deducido de un proceso que podemos denominar calibración) sobre la estadística del ruido de fondo infrarrojo del entorno bajo vigilancia; por ejemplo, si el predictor es puramente lineal la estadística necesaria se refiere al nivel de ruido y a la correlación, si incluimos no linealidades puede ser necesario medir estadísticos de orden superior o parámetros de modelos paramétricos de la función densidad de probabilidad del ruido de fondo infrarrojo. Normalmente, la calibración debería adaptarse a cambios espaciales y temporales de dicho entorno.

Por otro lado la detección precisa también de una etapa de calibración del entorno, así las alternativas basadas en variantes del filtro adaptado precisan normalizar el nivel de ruido y decorrelarlo. Otros detectores más complejos pueden requerir un conocimiento más detallado de la estadística de dicho ruido.

Adicionalmente, debemos aprovechar todo posible conocimiento sobre la “firma” o evolución del fuego, para maximizar la probabilidad de detección de fuegos descontrolados y minimizar la detección de efectos ocasionales no correspondientes a fuegos, manteniendo una cierta probabilidad de falsas alarmas debidas al ruido de fondo del entorno.

3.6 Estudios previos

Tal y como ya se ha indicado el GTS viene trabajando en el esquema de la Figura 22. En concreto se han analizado y experimentado las siguientes alternativas:

- *Predictor lineal* [28], [29]. El predictor consiste en una matriz que transforma el vector \mathbf{w} en el vector \mathbf{x} , que puede diseñarse a partir de las ecuaciones de Wiener-Hopf y que resulta óptimo si el ruido de fondo sigue una distribución Gaussiana.
- *Predictor no-lineal basado en la estructura de Wiener* [29]. Se ha verificado con medidas reales que la hipótesis de Gaussianidad no es siempre correcta por lo que el predictor lineal deja de ser óptimo, pudiendo mejorarse la predicción mediante la incorporación de no-linealidades en la estructura de predicción. Se ha experimentado un predictor no lineal de estructura muy simple, el sistema de Wiener, alcanzándose mejoras significativas en la predicción.
- *Detector basado en el filtro adaptado al subespacio de señal* [29],[30] y [31]. El conocimiento sobre el fuego descontrolado se incorpora proyectado el vector sobre el que se va a tomar la decisión en un subespacio “paso bajo” que permite eliminar efectos ocasionales de comportamiento “paso alto”. La proyección así obtenida se utiliza como señal de referencia en un filtro adaptado convencional. Se ha comprobado la buena capacidad de rechazo de alarmas indeseadas mediante esta alternativa.
- *Detector de crecimiento* [12], [13] Se ha desarrollado un detector que permite discernir tendencias crecientes de tendencias decrecientes. La estructura es básicamente un filtro adaptado a una componente continua, precedido de una transformación lineal diferenciadora del orden adecuado en función de la rapidez de crecimiento del fuego.

En los proyectos [12], [13], se ha adaptado el esquema general de la Figura 22, introduciendo algunos de los conceptos de los estudios previos anteriormente descritos para llegar a un esquema como el de la Figura 23, la cual muestra el esquema de procesado básico para cada celda que se ha implementado y que incorpora las ideas anteriormente expuestas.

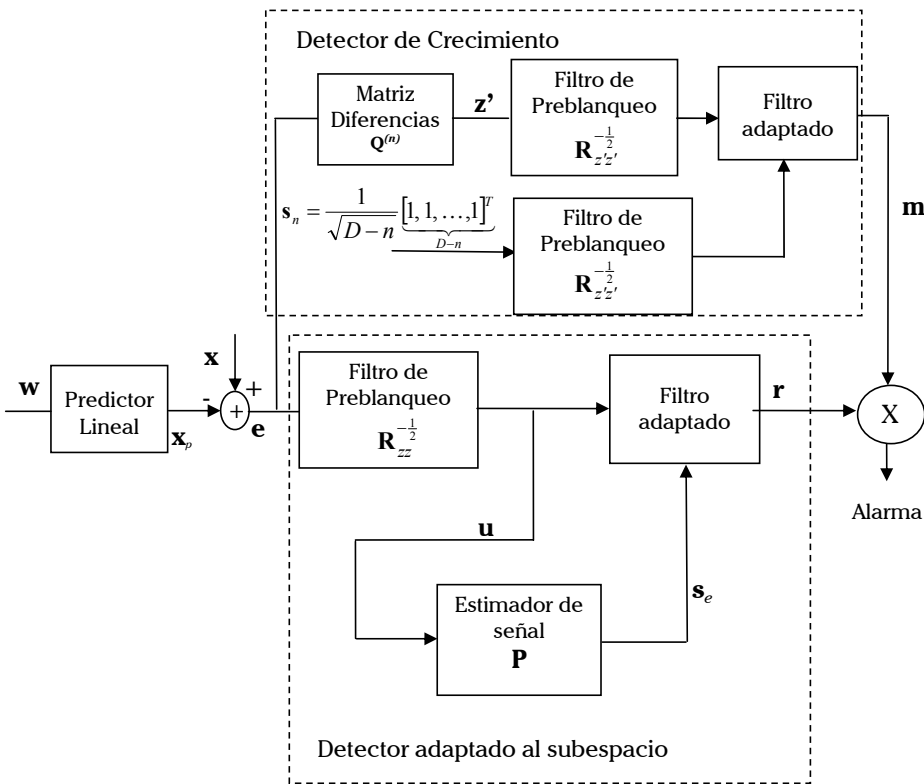


Figura 23. Subsistema de procesado aplicado a la detección automática en cada pixel Predictor y detectores de energía y de persistencia.

La detección se basa en D barridos consecutivos, cuyos niveles medidos en el píxel bajo análisis se agrupan en el vector \mathbf{x} . A este vector se le sustrae la predicción \mathbf{x}_p , realizada a partir de una Imagen Patrón representada en el esquema por el vector \mathbf{w} , que informa del ruido térmico de la escena. De esta forma se mejora la SNR del vector \mathbf{x} . Por lo tanto, antes de empezar a procesar una imagen se debe calcular esta Imagen Patrón.

Para calcularla, lo primero que se hace es obtener un número determinado de imágenes de la escena, cuando ésta está bajo unas condiciones normales, es decir, solo con ruido térmico. Una vez obtenidas se ordenan y se elimina un número determinado de píxeles en cada uno de los extremos de los vectores, esto se realiza para evitar que, si en alguna de las imágenes que hemos obtenido hay algún incremento o decremento brusco en el nivel de un píxel, no afecte a la Imagen Patrón que se está calculando. Por último se calcula la media de cada uno de los vectores resultantes, obteniendo así la Imagen Patrón de la escena.

Cabe destacar que se debe calcular esta imagen patrón cada cierto periodo de tiempo, ya que las condiciones de la escena varían con el tiempo, es decir, aunque el escenario que se está vigilando sea el mismo, las imágenes térmicas varían, por ejemplo, si se toman de día o de noche, en invierno o en verano, etc.

Obtenemos así el vector \mathbf{e} que es la entrada a los detectores automáticos (firma bajo análisis).

Una vez se ha calculado la imagen patrón, hay que calibrar el sistema. En esta etapa del procesado se calculan determinados parámetros del sistema que definirán tanto la etapa de predicción como la de detección.

Después de calibrar el sistema, hay que calcular los umbrales de cada una de las ramas del detector para unas Probabilidades de Falsa Alarma dadas.

Esencialmente, el esquema de la Figura 23 explota dos características distintivas de un posible fuego descontrolado frente al ruido de fondo infrarrojo o efectos ocasionales: su persistencia en tiempo y su crecimiento. El hecho de tener dos detectores implica ya la necesidad o el interés de recurrir a la fusión de decisiones, adicionalmente es claro que el fenómeno de persistencia es a corto plazo (de 2 a 4 segundos) y el fenómeno de crecimiento es a medio plazo (de 20 segundos o más). Esto nos llevó a la idea de considerar dos escalas de observación distintas para ambos detectores, llegando a un nuevo esquema de detección desarrollado en esta tesis y basado en la fusión de decisiones en un doble aspecto: primero fusión de decisiones en intervalos cortos de detección de persistencia para tomar una decisión final sobre la existencia o no de persistencia, y, fusión de dicha decisión con la de un detector de crecimiento actuando sobre un intervalo más largo. Se exponen a continuación los estudios realizados.

En lo sucesivo, por sencillez en la notación, llamaremos \mathbf{x} al vector de observaciones del que hemos restado ya la predicción realizada con la imagen patrón \mathbf{w} , es decir que $\mathbf{x}=\mathbf{e}$.

3.7 Aplicación de la fusión de decisiones monosensor a sistemas de detección de incendios.

3.7.1 Detectores de persistencia y crecimiento

Para definir las características distintivas de un fuego incontrolado y poder utilizarlas para realizar el diseño del detector, es conveniente imaginar qué clase de situación haría que un vigilante humano, observando un área bajo protección, se decidiese por alertar a las autoridades de que está observando un foco de incendio. En general se pueden resumir en dos posibles situaciones: que observe un cierto fenómeno térmico anormal, persistente durante un cierto periodo de tiempo, y que observe cómo ese fenómeno térmico anormal va incrementándose, en nivel, con el paso del tiempo.

En cuanto a la primera situación dónde se observe un cierto fenómeno térmico anormal durante un cierto tiempo de forma **persistente**, es claramente una señal de que se está produciendo un fenómeno no ocasional, como podría ser un vehículo pasando por la escena u otro tipo de fenómeno impulsivo. Llamamos T al tiempo que vamos a necesitar para tomar una decisión, de forma que $T=M \cdot T_s$, donde M es el número de elementos del vector de observación \mathbf{x} , y T_s es el intervalo temporal que se produce entre dos imágenes consecutivas. Este valor temporal T dependerá de las condiciones particulares de cobertura y/o requerimientos temporales en forma de retardos necesarios para la realización de la posible detección.

Una forma de implementar un detector que permita la detección de este tipo de fenómeno “a corto plazo” de persistencia es la segmentación del vector de observaciones \mathbf{x} en L fragmentos no solapados $\mathbf{z}_1, \dots, \mathbf{z}_L$ y asumir que la firma del fuego incontrolado a lo largo de cada uno de esos segmentos caerá dentro de un subespacio paso-bajo (puesto que hay persistencia) descrito por una matriz de proyección \mathbf{P} .

Para obtener esta matriz \mathbf{P} se utilizan las secuencias dominantes Slepian [41] que son las respuestas al impulso de filtros FIR paso-bajo que tienen propiedades óptimas de selectividad en frecuencia. De forma que siendo el vector \mathbf{h} la respuesta al impulso de un filtro FIR y $H(\omega)$ la respuesta en frecuencia, buscamos $H(\omega)$ que concentre la máxima energía en el intervalo $-\pi\beta < \omega < \pi\beta$ cumpliendo $\mathbf{h}^T \cdot \mathbf{h} = 1$. Siendo la solución a este problema los vectores propios de la matriz \mathbf{M} definida por:

$$\mathbf{M}(m, n) = \beta \cdot \text{sinc}(\beta\pi(m - n)) \quad (110)$$

De forma que el primer vector propio es el que concentra la máxima energía en el intervalo y el resto de valores propios van concentrando menos energía. Eligiendo los p primeros vectores propios y creando la matriz \mathbf{A} cuyas columnas dichos p vectores propios de \mathbf{M} , obtenemos la matriz \mathbf{P} de la siguiente forma:

$$\mathbf{P} = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \tag{111}$$

Donde los parámetros β y p habrá que calcularlos para que el subespacio paso-bajo que defina la matriz \mathbf{P} sea el adecuado.

Con esta matriz \mathbf{P} seremos capaces de distinguir entre las señales “paso-bajo” de las alarmas buscadas y las señales “paso-alto” de las alarmas indeseadas.

Una vez calculada la matriz \mathbf{P} se implementa un detector de filtro adaptado al subespacio descrito por esta matriz de forma que este detector compara la energía del vector \mathbf{z}_i dentro del subespacio \mathbf{P} con un umbral λ .

$$\mathbf{z}_i^T \mathbf{P} \mathbf{z}_i \begin{matrix} > \\ < \end{matrix} \begin{matrix} H_0 \\ H_1 \end{matrix} \lambda \tag{112}$$

Donde el umbral λ puede calcularse fácilmente para cumplir la *PFA* deseada ya que $\mathbf{z}_i^T \mathbf{P} \mathbf{z}_i$ tiene bajo la hipótesis H_0 , y considerando $\mathbf{z}_i: N(0, \sigma^2)$ una distribución de tipo chi-cuadrado con p grados de libertad.

$$PFA = 1 - \text{chi2cdf}(\lambda, p) \tag{113}$$

En cuanto al segundo detector que observa cómo ese fenómeno térmico anormal va incrementándose en nivel, con el tiempo, la solución propuesta es la de la utilización de un **detector de crecimiento** que se fije en si existe crecimiento en la energía del vector $\mathbf{Z}_E = [E_1, \dots, E_L]^T$ donde $E_i = \mathbf{z}_i^T \mathbf{P} \mathbf{z}_i$.

Para ello el vector \mathbf{Z}_E se pasa por una matriz de diferencias de orden n denominada $\mathbf{Q}^{(n)}$ y se introduce en un detector de filtro adaptado junto con un vector \mathbf{s}_n de componente continua y de tamaño $L-n$. Ver Figura 24.

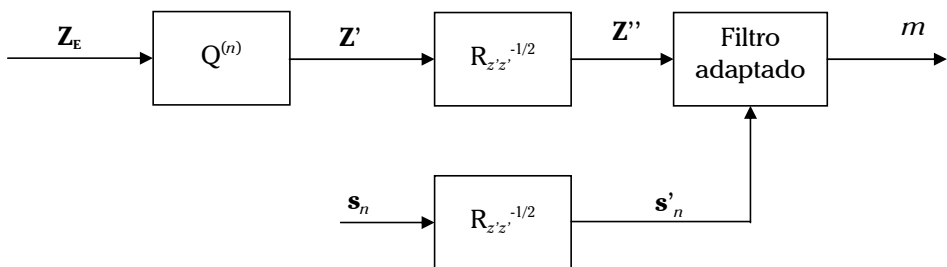


Figura 24. Esquema básico del Detector de Crecimiento “a largo plazo” propuesto

donde la matriz de diferencias se define de la siguiente manera:

$$\mathbf{Q}^{(n)} = \mathbf{Q}_{L-n+1} \cdot \mathbf{Q}_{L-1} \cdot \mathbf{Q}_L \tag{114}$$

$$\mathbf{Q}_L = \begin{bmatrix} -1 & 1 & 0 & \dots & \dots & 0 \\ 0 & -1 & 1 & \dots & \dots & 0 \\ & & \vdots & & & \\ 0 & 0 & 0 & \dots & -1 & 1 \end{bmatrix}$$

siendo \mathbf{Q}_L una matriz de $L-1$ filas x L columnas.

El vector de componente continua \mathbf{s}_n es un vector de $L-n$ filas.

$$\mathbf{s}_n = [1 \dots 1]^T \tag{115}$$

El filtro adaptado indicado en la Figura 24 corresponde con la correlación entre la $\mathbf{Z}' = \mathbf{Q}^{(n)} \cdot \mathbf{Z}_E$ y el vector de componente continua \mathbf{s}_n . El preblanqueo ($\mathbf{R}_{z'z'}^{-1/2}$) es necesario ya que \mathbf{Z}' tiene la siguiente matriz de autocorrelación:

$$\mathbf{R}_{z'z'} = E[\mathbf{Z}' \cdot \mathbf{Z}'^T] = E[\mathbf{Q}^{(n)} \cdot \mathbf{Z}_E \cdot \mathbf{Z}_E^T \cdot \mathbf{Q}^{(n)T}] = \mathbf{Q}^{(n)} \cdot \mathbf{R}_{z_E z_E} \cdot \mathbf{Q}^{(n)T} = \mathbf{Q}^{(n)} \cdot 2p \cdot \mathbf{I} \cdot \mathbf{Q}^{(n)T} \tag{116}$$

Siendo $2p$ la varianza de una variable aleatoria chi-cuadrado (χ^2) con p grados de libertad, donde hemos asumido incorrelación entre los elementos del vector de energías \mathbf{Z}_E ya que los intervalos \mathbf{z}_i no se solapan.

Normalizando en el filtro adaptado según indica la Figura 25.




Figura 25. Esquema básico del Filtro Adaptado

donde el estadístico m tiene la siguiente expresión:

$$m = \frac{\mathbf{Z}'^T \cdot \mathbf{s}'_n}{(\mathbf{s}'_n^T \cdot \mathbf{s}'_n)^{1/2}} = \frac{\mathbf{Z}'^T \cdot \mathbf{R}_{z'z'}^{-1/2} \cdot \mathbf{R}_{z'z'}^{-1/2} \cdot \mathbf{s}'_n}{(\mathbf{s}'_n^T \cdot \mathbf{R}_{z'z'}^{-1/2} \cdot \mathbf{R}_{z'z'}^{-1/2} \cdot \mathbf{s}'_n)^{1/2}} \tag{117}$$

Obtenemos, teniendo en cuenta (116) y (117) finalmente el detector de crecimiento.

$$\frac{\mathbf{Z}_E^T \mathbf{Q}^{(n)T} \cdot (\mathbf{Q}^{(n)} \mathbf{Q}^{(n)T})^{-1} \cdot \mathbf{s}_n}{(2 p \mathbf{s}_n^T \cdot (\mathbf{Q}^{(n)} \mathbf{Q}^{(n)T})^{-1} \cdot \mathbf{s}_n)^{1/2}} > \lambda_0 \tag{118}$$

Donde $\mathbf{Z}' = \mathbf{Q}^{(n)} \cdot \mathbf{Z}_E$ se puede considerar como una gaussiana multivariable de media cero ya que cada elemento de ella se obtiene como sucesivas diferencias de variables aleatorias. La primera diferencia $\mathbf{Q}_L \cdot \mathbf{Z}_E$ tendrá como funciones de densidad de probabilidad marginales aquellas que resultan de la convolución de una fdp de tipo χ^2 con otra fdp de tipo $-\chi^2$, lo cual resulta aproximadamente una distribución gaussiana, ver Figura 26.

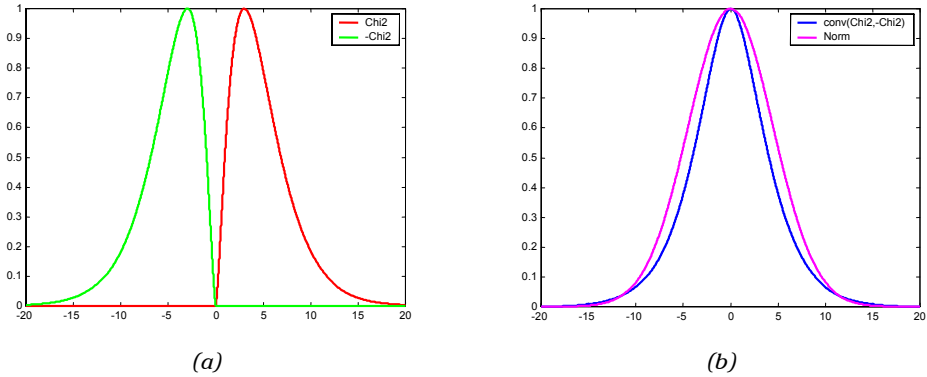


Figura 26. Gráficas comparativas entre dos distribuciones χ^2 y $-\chi^2$ con $p=5$ grados de libertad (Figura 26a) y la convolución de las dos distribuciones anteriores y una distribución normal con media cero y varianza $2 \cdot p + 2 \cdot p = 20$ (Figura 26b)

Las sucesivas diferencias incrementan esta gaussianidad siguiendo el teorema central del límite. Por lo tanto se puede considerar que el estadístico resultante de la ecuación (118) es una normal de media cero y varianza unidad $N:(0,1)$, de forma que es muy fácil la obtención de la relación entre la PFA y el umbral λ_0 , según

$$PFA = \frac{1}{2} \operatorname{erfc}(\lambda_0 \cdot \sqrt{2}) \tag{119}$$

3.7.2 Esquema general del sistema de procesado con fusión de decisiones

Finalmente vemos en la Figura 27 el esquema de detección general que explota las características tanto de persistencia como de crecimiento, utilizando para ello la fusión de decisiones en sistemas monosensor tanto de decisiones incorreladas, en el caso de la detección de persistencia, como finalmente de decisiones en principio correladas para la generación de la decisión final que fusiona la decisión de persistencia con la decisión del detector de crecimiento, como mejora del esquema básico de la Figura 22.

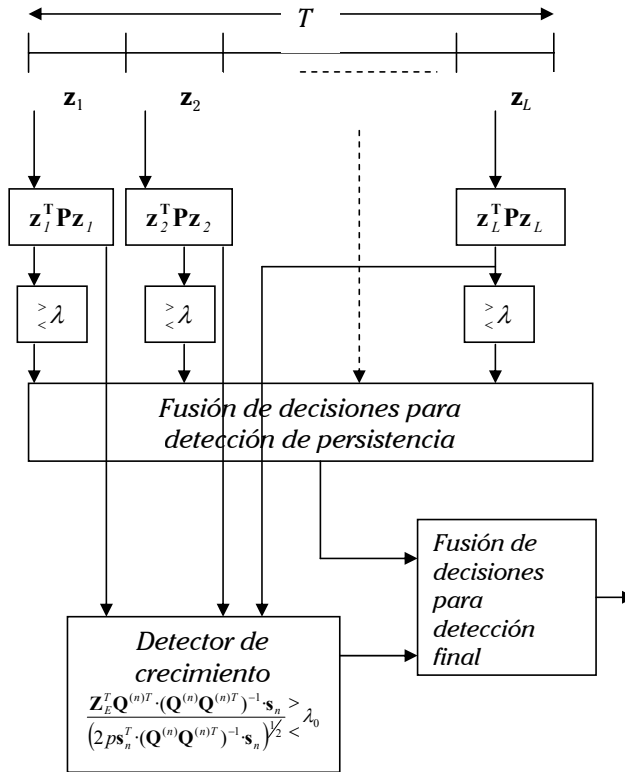


Figura 27. Esquema básico del detector automático, incorporando la detección de persistencia, la detección de crecimiento y la fusión de decisiones.

Una vez expuestos los algoritmos de cada detector, vamos a considerar las reglas de fusión.

3.7.3 Fusión de decisiones aplicada al detector de persistencia

Vamos a buscar en este apartado la regla de decisión óptima que nos permita combinar las decisiones obtenidas de cada uno de los L segmentos en los que hemos dividido el vector de observaciones \mathbf{x} .

Para ello llamaremos $\mathbf{u} = [u_1, \dots, u_L]^T$ al vector de decisiones parciales de forma que, como hemos visto en apartados anteriores, la fusión de decisiones óptima según el criterio de Neyman-Pearson sigue la regla de decisión [20], [33]:

$$R_{opt}(\mathbf{u}) = \begin{cases} 1 & \text{si } T(\mathbf{u}) > t \\ 1 \text{ con probabilidad } \gamma & \text{si } T(\mathbf{u}) = t \\ 0 & \text{si } T(\mathbf{u}) < t \end{cases} \quad (120)$$

Donde $T(\mathbf{u}) = \text{Prob}(\mathbf{u}/H_1) / \text{Prob}(\mathbf{u}/H_0)$ es la razón de verosimilitud.

Asumiremos, a partir de ahora, independencia estadística entre las decisiones, teniendo en cuenta que podemos hacer esta suposición, aunque estemos calculando estas decisiones de un mismo vector de observaciones \mathbf{x} , ya que lo estamos haciendo tomando fragmentos de éste no solapados y que \mathbf{x} corresponde a un vector de errores de predicción que pueden considerarse incorrelados y gaussianos.

Entonces teniendo en cuenta la suposición anteriormente comentada obtenemos la siguiente expresión para la razón de verosimilitud.

$$T(\mathbf{u}) = \prod_{i=1}^L \left(\frac{PD_i}{PFA_i} \right)^{u_i} \left(\frac{1-PD_i}{1-PFA_i} \right)^{1-u_i} \quad (121)$$

Donde la PD_i y la PFA_i son las probabilidades de detección y de falsa alarma del i -ésimo detector.

Normalmente estas probabilidades se pueden considerar que son constantes para cada uno de los detectores de forma que $PD_i = PD_0$ y $PFA_i = PFA_0$ para todo i y entonces obtenemos una versión simplificada de la expresión anterior quedando de la siguiente forma:

$$T(\mathbf{u}) = \prod_{i=1}^L \left(\frac{PD_0}{PFA_0} \right)^{u_i} \left(\frac{1-PD_0}{1-PFA_0} \right)^{1-u_i} \quad (122)$$

Siguiendo las indicaciones de [20] podemos ordenar $T(\mathbf{u})$ en función de los diferentes valores de \mathbf{u} . Teniendo en cuenta que en la práctica $PD_0 > PFA_0$.

$$\begin{aligned} T(\mathbf{u}_1) = T(\mathbf{0}) &= \left(\frac{1-PD_0}{1-PFA_0} \right)^L < \\ < T(\mathbf{u}_2) = \dots = T\left(\mathbf{u}_{\binom{L}{1}+1}\right) &= \left(\frac{1-PD_0}{1-PFA_0} \right)^{L-1} \frac{PD_0}{PFA_0} < \\ &\underbrace{\hspace{10em}}_{\binom{L}{1} \text{ casos con 1 uno}} \\ < T\left(\mathbf{u}_{\binom{L}{1}+2}\right) = \dots = T\left(\mathbf{u}_{\binom{L}{1}+\binom{L}{2}+1}\right) &= \left(\frac{1-PD_0}{1-PFA_0} \right)^{L-2} \left(\frac{PD_0}{PFA_0} \right)^2 < \\ &\underbrace{\hspace{10em}}_{\binom{L}{2} \text{ casos con 2 unos}} \\ &\vdots \\ &\vdots \\ < T(\mathbf{u}_L) &= \left(\frac{PD_0}{PFA_0} \right)^L \end{aligned} \quad (123)$$

Seleccionando como umbral $t = \left(\frac{1 - PD_0}{1 - PFA_0}\right)^{L-nu} \left(\frac{PD_0}{PFA_0}\right)^{nu}$ deducida de la expresión anterior (123). La regla de decisión óptima (120) puede ser expresada de la siguiente forma:

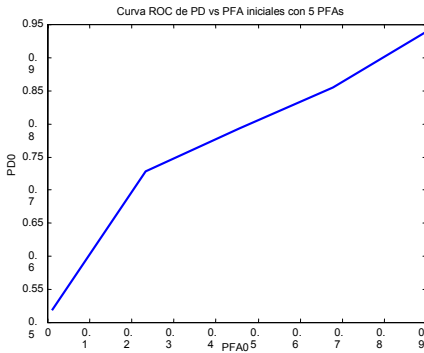
$$R_{opt}(\mathbf{u}) = \begin{cases} 1 & \text{si el número de unos en } \mathbf{u} > nu \\ 1 \text{ con probabilidad } \gamma & \text{si el número de unos en } \mathbf{u} = nu \\ 0 & \text{si el número de unos en } \mathbf{u} < nu \end{cases} \quad (124)$$

Obteniendo finalmente las siguientes expresiones para la PD y la PFA en el caso del detector de persistencia:

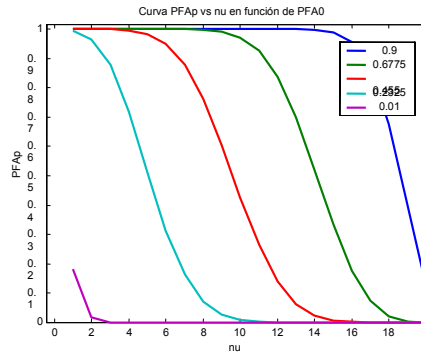
$$PD_p = \sum_{k=nu+1}^L \binom{L}{k} PD_0^k (1 - PD_0)^{L-k} + \gamma \binom{L}{nu} PD_0^k (1 - PD_0)^{L-k} \quad (125)$$

$$PFA_p = \sum_{k=nu+1}^L \binom{L}{k} PFA_0^k (1 - PFA_0)^{L-k} + \gamma \binom{L}{nu} PFA_0^k (1 - PFA_0)^{L-k} \quad (126)$$

Para ilustrar el comportamiento de las expresiones anteriores vamos a ver un ejemplo de aplicación de estas expresiones para el caso en el que tengamos un pedestal térmico permanente sobre un fondo de ruido térmico, como muestras de entrada, y los pasemos por el detector de persistencia.



a)



b)




Figura 28. Gráficas de ejemplo de aplicación del esquema básico del detector automático, incorporando la detección de persistencia y la fusión de decisiones.

En este caso se obtienen las curvas ROC de Probabilidad de Detección (PD_0) en función de la Probabilidad de Falsa Alarma (PFA_0) iniciales (ver Figura 28a) donde se ha calculado la PD para un rango de 5 PFA 's entre 0.9 y 0.01, con una SNR de 1 dB y tomando para el cálculo de cada PD 1000 vectores gaussianos y correlados de tamaño 5, sobre un pedestal de señal dependiente de la SNR , pasados por el detector de persistencia. Donde se puede observar, como es habitual, una evolución creciente de la PD_0 al aumentar la PFA_0 .

A continuación se ha calculado la PFA_p a partir de la expresión (126) obteniendo la gráfica de la Figura 28b donde se puede observar esta PFA_p en función del umbral nu que indica el número de unos en la decisión u de cada detector de persistencia, para las diferentes PFA_0 iniciales. De donde podemos deducir, a la vista de la gráfica, como la evolución de ésta es decreciente a medida que el parámetro nu aumenta para una misma PFA_0 , ya que estamos siendo más exigentes con el numero de detecciones necesarias para tomar la decisión final según la expresión (124). Además se puede observar como al disminuir la PFA_0 estas gráficas se desplazan hacia la izquierda indicando que se requieren menos detecciones para la misma PFA_p , o lo que es lo mismo, para el mismo nivel de exigencia nu se consiguen unas PFA_p menores.

De manera parecida se ha calculado la PD_p a partir de la expresión (125) obteniendo la gráfica de la Figura 28c donde se puede observar esta PD_p en función del umbral nu para las diferentes PD_0 iniciales. De donde podemos deducir, a la vista de la gráfica, como la evolución de ésta es, al igual que en el caso anterior, decreciente a medida que el parámetro nu aumenta para una misma PD_0 , ya que estamos siendo más exigentes con el número de detecciones necesarias para tomar la decisión final y por lo tanto disminuye la probabilidad de detección final. Observando el mismo efecto que anteriormente con la PFA en cuanto al desplazamiento a la izquierda de las gráficas al disminuir la PD_0 , por lo que para un mismo nivel de exigencia nu se reduce la PD_p al disminuir la PD_0 , aunque no tan drásticamente como en el caso de la PFA_p .

Finalmente se obtienen las curvas ROC del detector de persistencia (ver Figura 28d) donde se observa como al reducirse la PFA_0 se consiguen curvas mucho más esquinadas que las que se obtienen con un único detector, como el de la Figura 28a, de forma que se consiguen grandes probabilidades de detección para muy bajas probabilidades de falsa alarma, al aumentar el nivel de exigencia del detector final de la fusión de decisiones.

3.7.4 Fusión de decisiones aplicada a la decisión final

Vamos a abordar ahora el problema de la fusión de las decisiones del detector de persistencia y de la decisión del detector de crecimiento, que en general son decisiones correladas, ya que utilizan las mismas observaciones para tomar sus decisiones locales.

Llamaremos por tanto u_p a la variable aleatoria binaria que representa la decisión dada por el detector de persistencia, y u_l a la correspondiente decisión binaria aleatoria correspondiente al detector de crecimiento. Vamos primeramente a demostrar que la regla de decisión más intuitiva, es decir

$$R(\mathbf{u}) = \begin{cases} 1 & \text{si } \mathbf{u} = [1 \ 1] \\ 0 & \text{en otro caso} \end{cases} \quad \mathbf{u} = [u_p \ u_l] \quad (127)$$

resulta ser óptima si asumimos independencia entre las decisiones.

Asumiremos que el umbral del detector de persistencia ha sido fijado para tener una cierta PFA_p , y que el umbral del detector de crecimiento también ha sido fijado para tener una cierta PFA_l . Llamando entonces PD_p y PD_l a las correspondientes probabilidades de detección y aplicando el teorema 1 de [20] para evaluar el razón de verosimilitud $T(\mathbf{u})$ para el caso particular de la fusión con dos decisiones, es fácil llegar al siguiente resultado:

$$T(\mathbf{u}) = \begin{cases} \frac{1 - PD_p - PD_l + P_1(1,1)}{1 - PFA_p - PFA_l + P_0(1,1)} & \mathbf{u} = [0 \ 0] \\ \frac{PD_p - P_1(1,1)}{PFA_p - P_0(1,1)} & \mathbf{u} = [1 \ 0] \\ \frac{PD_l - P_1(1,1)}{PFA_l - P_0(1,1)} & \mathbf{u} = [0 \ 1] \\ \frac{P_1(1,1)}{P_0(1,1)} & \mathbf{u} = [1 \ 1] \end{cases} \quad (128)$$

Donde se puede observar cómo la expresión (128) está bastante limitada ya que la razón de verosimilitud depende de las probabilidades conjuntas $P_1(1,1)$ y $P_0(1,1)$ que en general son difíciles de evaluar excepto para el caso de independencia estadística entre las variables aleatorias de las decisiones u_p y u_l .

Si suponemos independencia estadística, podemos expresar estas probabilidades conjuntas de la siguiente forma:

$$P_1(1,1) = PD_p \cdot PD_l \quad P_0(1,1) = PFA_p \cdot PFA_l \quad (129)$$

De forma que si sustituimos las expresiones de (129) en (128) obtenemos la siguiente regla de decisión:

$$T(\mathbf{u}) = \begin{cases} \frac{(1 - PD_p) \cdot (1 - PD_l)}{(1 - PFA_p) \cdot (1 - PFA_l)} & \mathbf{u} = [0 \ 0] \\ \frac{PD_p \cdot (1 - PD_l)}{PFA_p \cdot (1 - PFA_l)} & \mathbf{u} = [1 \ 0] \\ \frac{(1 - PD_p) \cdot PD_l}{(1 - PFA_p) \cdot PFA_l} & \mathbf{u} = [0 \ 1] \\ \frac{PD_p \cdot PD_l}{PFA_p \cdot PFA_l} & \mathbf{u} = [1 \ 1] \end{cases} \quad (130)$$

Para completar el test óptimo necesitamos decidir el valor del umbral t y de la probabilidad γ , como en (120). Está claro que para cualquier pareja de valores $t - \gamma$ se puede implementar un test óptimo con la única restricción de que $0 \leq \gamma \leq 1$.

Utilizando la siguiente notación $T(\mathbf{u}) = T_{u_p u_l}$, y teniendo en cuenta que en la práctica $PD_p > PFA_p$ y $PD_l > PFA_l$, obtenemos las siguientes relaciones para el razón de verosimilitud:

$$T_{00} < \frac{T_{01}}{T_{10}} < T_{11} \quad (131)$$

Donde $T_{01} \leq T_{10}$ ó $T_{01} \geq T_{10}$ dependiendo de los valores particulares de PD_p , PD_l , PFA_p , PFA_l . Por ejemplo, si $PFA_p = PFA_l$ y $PD_p \geq PD_l$ entonces $T_{01} \leq T_{10}$, y viceversa.

Entonces si seleccionamos la pareja $t = T_{11}$, $\gamma = 1$, a partir de (120) obtendremos la regla de decisión óptima siguiente:

$$R_{opt}(\mathbf{u}) = \begin{cases} 1 & \text{si } T(\mathbf{u}) > T_{11} \\ 1 & \text{si } T(\mathbf{u}) = T_{11} \\ 0 & \text{si } T(\mathbf{u}) < T_{11} \end{cases} \quad (132)$$

Y las correspondientes PFA se obtienen de la siguiente forma

$$PFA = P_0(T(\mathbf{u}) > T_{11}) + 1 \cdot P_0(T(\mathbf{u}) = T_{11}) = 0 + P_0(u_p = 1) \cdot P_0(u_l = 1) = PFA_p \cdot PFA_l \quad (133)$$

Donde el primer sumando es cero teniendo en cuenta (131) y que por lo tanto $T(\mathbf{u})$ nunca puede ser mayor de T_{11} . Y el segundo sumando es el producto de las PFA 's ya que la regla de decisión de (132) es equivalente a decidir "1" cuando ambos detectores deciden "1", así como cuando $T(\mathbf{u}) = T_{11}$ y en el resto de casos se decide "0". Ésta es precisamente la regla de decisión de fusión propuesta en (127) que, por lo tanto, resulta ser óptima cuando asumimos independencia estadística.

Se pueden llegar a las mismas conclusiones seleccionando otras parejas de valores de umbral t y de probabilidad γ seleccionando $t = T_{10}$, $\gamma = 0$ si $T_{10} \geq T_{01}$, ó $t = T_{01}$, $\gamma = 0$ si $T_{01} \geq T_{10}$.

Así mismo se puede demostrar, de manera equivalente, que se cumple que las correspondientes PD se pueden obtener como el producto de las probabilidades de detección de cada detector por separado.

$$PD = P_1(T(\mathbf{u}) > t) + \gamma \cdot P_1(T(\mathbf{u}) = t) = 0 + P_1(u_p = 1) \cdot P_1(u_l = 1) = PD_p \cdot PD_l \quad (134)$$

Si no suponemos independencia estadística, no podemos expresar las probabilidades conjuntas como en (129) sino que, en un caso más general, se pueden expresar de la siguiente forma:

$$\begin{aligned} P_1(1,1) &= \alpha \cdot PD_l & PD_p \leq \alpha \leq 1 \\ P_0(1,1) &= \beta \cdot PFA_l & PFA_p \leq \beta \leq 1 \end{aligned} \quad (135)$$

Donde α y β son constantes que indican el grado de dependencia o independencia de las probabilidades conjuntas. Teniendo en cuenta que:

$$\begin{aligned} P_1(1,1) &= P_1(1/1) \cdot P_1(1) = P_1(1/1) \cdot PD_l \\ P_1(1/1) &\begin{cases} P_1(1/1) = P_1(1) = PD_p & \text{Independencia} \\ P_1(1,1) = 1 & \text{Dependencia máxima} \end{cases} \end{aligned} \quad (136)$$

$$\begin{aligned} P_0(1,1) &= P_0(1/1) \cdot P_0(1) = P_0(1/1) \cdot PFA_l \\ P_0(1/1) &\begin{cases} P_0(1/1) = P_0(1) = PFA_p & \text{Independencia} \\ P_0(1,1) = 1 & \text{Dependencia máxima} \end{cases} \end{aligned} \quad (137)$$

En este caso más general la expresión (128) queda de la forma:

$$T(\mathbf{u}) = \begin{cases} \frac{1 - PD_p - (1 - \alpha) \cdot PD_l}{1 - PFA_p - (1 - \beta) \cdot PFA_l} & \mathbf{u} = [0 \ 0] \\ \frac{PD_p - \alpha \cdot PD_l}{PFA_p - \beta \cdot PFA_l} & \mathbf{u} = [1 \ 0] \\ \frac{(1 - \alpha) \cdot PD_l}{(1 - \beta) \cdot PFA_l} & \mathbf{u} = [0 \ 1] \\ \frac{\alpha \cdot PD_l}{\beta \cdot PFA_l} & \mathbf{u} = [1 \ 1] \end{cases} \quad (138)$$

De la cual se puede deducir, de una forma similar, la expresión (131) en donde la única incertidumbre es la relación entre T_{01} y T_{10} .

Esta incertidumbre no es ningún problema ya que habitualmente se elegirá una regla de decisión del estilo a la obtenida en el caso de independencia (132), en donde se toma una decisión positiva únicamente cuando los dos decisores locales toman esta decisión, o en todo caso, la regla de decisión siguiente:

$$R(\mathbf{u}) = \begin{cases} 1 & \text{si } T(\mathbf{u}) > T_{00} \\ 0 & \text{si } T(\mathbf{u}) = T_{00} \\ 0 & \text{si } T(\mathbf{u}) < T_{00} \end{cases} \quad (139)$$

En la que la decisión final se toma si alguno de los decisores locales toma esa misma decisión. Ya que las otras combinaciones no tienen sentido, ya que harían innecesaria la presencia de uno de los dos decisores locales.

Cabe destacar el caso en el que α es 1 y β es la PFA_p , es decir que hay dependencia máxima en el caso de fijarnos en las PD , de forma que $PD_i = PD_p$, e independencia en el caso de fijarnos en las PFA 's. Entonces la expresión (138) queda de la siguiente forma:

$$T(\mathbf{u}) = \begin{cases} \frac{1 - PD_p}{(1 - PFA_p) - (1 - PFA_l)} & \mathbf{u} = [0 \ 0] \\ 0 & \mathbf{u} = [1 \ 0] \\ 0 & \mathbf{u} = [0 \ 1] \\ \frac{PD_l}{PFA_p \cdot PFA_l} & \mathbf{u} = [1 \ 1] \end{cases} \quad (140)$$

Donde claramente se cumple la expresión (131) y se ilustra el caso extremo de lo que se ha mencionado anteriormente.

$$T_{00} < T_{01} = T_{10} = 0 < T_{11} \quad (141)$$

En conclusión, aunque haya dependencia estadística, las posibles reglas de fusión óptimas son las mismas.

3.8 Comprobación de resultados mediante simulaciones

Para ilustrar los resultados de los apartados anteriores vamos a realizar una serie de simulaciones fijándonos en el esquema de la Figura 27.

Para ello y teniendo en cuentas las expresiones de PD y PFA globales calculadas en (133) y (134) como producto de las probabilidades locales, vamos a calcular las curvas que nos relacionan estas PFA s y PD s con los diferentes parámetros a considerar tanto del detector fusionado de persistencia PFA_p , PD_p , como del detector de crecimiento PFA_c , PD_c , comparándolas con las curvas teóricas que deben seguir en función de las diferentes distribuciones que siguen estos dos esquemas de detección por separado. Finalizaremos realizando un estudio global del sistema fusionando estos dos detectores en una única detección global PFA_t y PD_t .

3.8.1 Generación de curvas de PFA_p y PD_p del detector fusionado de persistencia

En el caso del detector fusionado de persistencia, hemos obtenido en (125) y (126) unas expresiones teóricas que relacionan la PFA_p y la PD_p con los parámetros del modelo a estudiar nu , L y PFA_0 . Por lo que podremos mostrar una serie de curvas donde se comparen los resultados obtenidos tanto teóricamente como prácticamente.

3.8.1.1 Obtención de curvas de PFA_p en función de los parámetros: nu , L y PFA_0 .

Para el caso del cálculo de la PFA_p supondremos que las muestras de entrada son únicamente un vector de ruido gaussiano correlado de tamaño $T=L \cdot M$ muestras correladas tomadas en L segmentos de tamaño M , fijando éste parámetro, para simplificar, a $M=6$.

A continuación se pasan por cada una de las etapas del modelo clásico de la Figura 23, es decir se separa el vector de muestras de tamaño $M=6$ en $N=1$ muestras que entran al predictor lineal utilizando las $D=5$ restantes para restarlas a la salida del predictor. A continuación se pasan por el filtro de preblanqueo y se realiza la detección de cada uno de los segmentos utilizando el estimador de la señal con la matriz \mathbf{P} y la detección por el umbral fijado a partir de la PFA_0 , como ya se indicó en el esquema de la Figura 27. Finalmente se fusionan las decisiones de los L segmentos decidiendo si hay detección o no en función de si nu detecciones han sido activadas.

Este proceso se realiza un número elevado de veces (1000) para ir obteniendo diferentes probabilidades de falsa alarma para el caso del detector de persistencia.

A continuación vamos a mostrar los resultados obtenidos en los siguientes supuestos:

- En el caso de buscar la relación entre la PFA_p y el parámetro nu utilizaremos un valor fijo de $L=20$ segmentos, variando nu desde 0 a 20 y unas PFA_0 entre 0.5 y 0.01. Figura 29a.
- En el caso de buscar la relación entre la PFA_p y el parámetro L utilizaremos un valor de $nu=6$ decisiones acertadas, variando L de 6 a 20 y unas PFA_0 entre 0.5 y 0.01. Figura 29b.
- En el caso de buscar la relación entre la PFA_p y la PFA_0 utilizaremos un valor de $nu=6$ decisiones acertadas para diferentes valores de L entre 6 y 18, variando la PFA_0 de 0,01 a 0,5. Figura 29c.

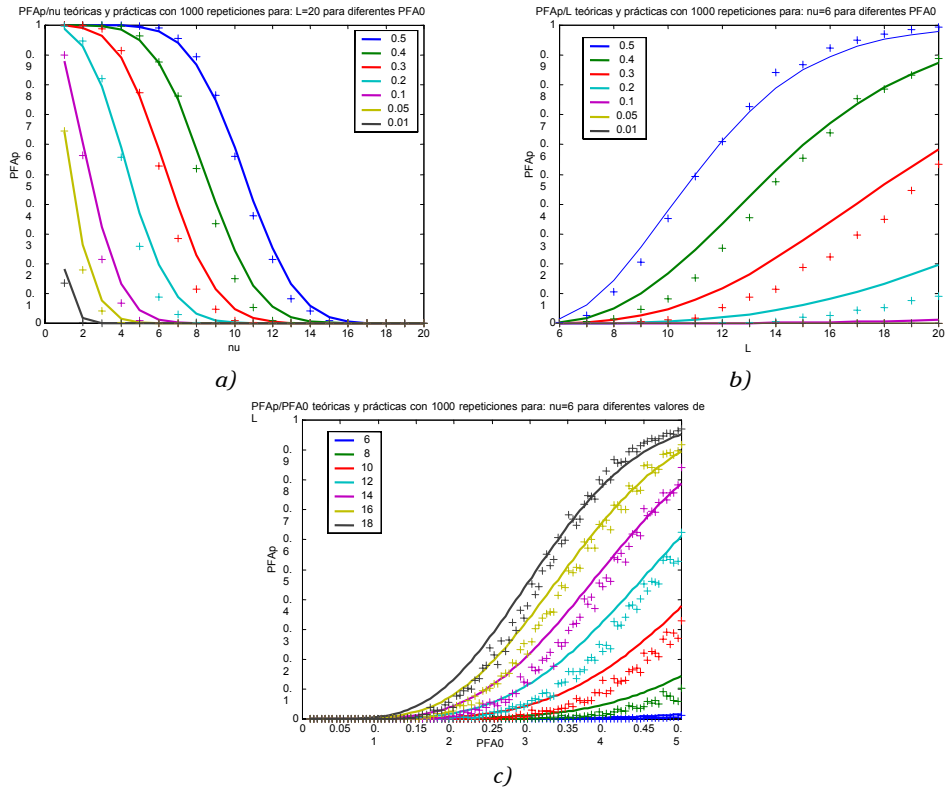


Figura 29. Gráficas teóricas y prácticas de PFA_p en función de los parámetros nu , L y PFA_0 .

Podemos observar como:

- ✓ Si aumentamos el parámetro nu entonces la PFA_p disminuye. Esto es así debido a que al aumentar nu estamos siendo más restrictivos en la fusión de decisiones y por lo tanto la PFA_p disminuirá.
- ✓ Si L aumenta entonces la PFA_p aumenta. Ya que al aumentar el número de segmentos L tenemos más decisores posibles y por lo tanto al mantener nu fijo estamos siendo menos restrictivos aumentando la PFA_p .

- ✓ Al ir disminuyendo la PFA_0 la PFA_p también disminuye. Como cabía esperar la PFA de cada uno de los decisiones por separado sigue la misma tendencia que la PFA_p global del sistema una vez fusionados todos estos decisores parciales.

Además queda patente que el modelo desarrollado en (125) es correcto ya que se observa claramente como las simulaciones siguen casi perfectamente a este modelo, si tenemos en cuenta que en este caso la línea continua representa el modelo y las cruces a los valores obtenidos mediante la actual simulación.

3.8.1.2 Obtención de curvas de PD_p en función de los parámetros: nu , L , PFA_0 , SNR y $crec$.

En este caso, al pretender calcular la probabilidad de detección, seguiremos el mismo esquema desarrollado en el apartado anterior pero utilizando, como vector de entrada, un vector de ruido gaussiano correlado de tamaño $T=L \cdot M$ muestras correladas con L segmentos de tamaño $M=6$ muestras, con un fuego creciente a lo largo de las T muestras.

Para generar este **fuego** creciente calcularemos el valor inicial de este nivel aditivo x_{ini} constante a partir del nuevo parámetro de SNR y de la variancia calculada del ruido $var(x)$ e iremos aumentando el nivel a añadir a este ruido según un modelo lineal con pendiente de crecimiento $crec$.

$$\text{fuego} = x_{ini} + crec \cdot \mathbf{v}' \quad (142)$$

Siendo $\mathbf{v} = [0, 1, 2, \dots, T-1]$

De forma que si la pendiente de crecimiento es positiva $crec > 0$:

$$x_{ini} = \sqrt{10^{\frac{SNR}{10}}} \cdot \text{var}(x) \quad (143)$$

Y si esta pendiente de crecimiento es negativa, $crec < 0$:

$$\begin{aligned} x_{fin} &= x_{ini} \\ x_{ini} &= x_{fin} - crec \cdot (T - 1) \end{aligned} \quad (144)$$

Cabe destacar en este punto que no se ha desarrollado ningún modelo teórico para obtener la PD_p en función de los parámetros del sistema ya que las PD de cada uno de los detectores son desconocidas y por lo tanto no podemos aplicar la expresión (125) teórica. Por lo tanto los resultados que vamos a desarrollar a continuación serán únicamente desarrollos por simulación sin posibilidad de contrastar con el modelo teórico como pasaba en el caso anterior.

A continuación vamos a mostrar los resultados obtenidos en los siguientes supuestos:

- En el caso de buscar la relación entre la PD_p y el parámetro nu utilizaremos un valor fijo de $L=10$ segmentos, una $SNR=1$, una pendiente de crecimiento $crec=0.01$, variando nu de 0 a 20 y unas PFA_0 entre 0.5 y 0.01. Figura 30a.
- En el caso de buscar la relación entre la PD_p y el parámetro L utilizaremos un valor de $nu=6$ decisiones acertadas, una $SNR=1$, una $crec=0.01$, variando L de 6 a 20 y unas PFA_0 entre 0.5 y 0.01. Figura 30b.
- En el caso de buscar la relación entre la PD_p y la PFA_0 utilizaremos un valor de $nu=6$ decisiones acertadas, una $SNR=1$ y una $crec=0.01$, variando la PFA_0 entre 0,01 y 0,5 para diferentes valores de L entre 6 y 18. Figura 30c.
- En el caso de buscar la relación entre la PD_p y la SNR utilizaremos un valor de $nu=6$ decisiones acertadas, $L=10$, una $crec=0.01$, variando la SNR de 0 a 20 y unas PFA_0 entre 0.5 y 0.01. Figura 30d.

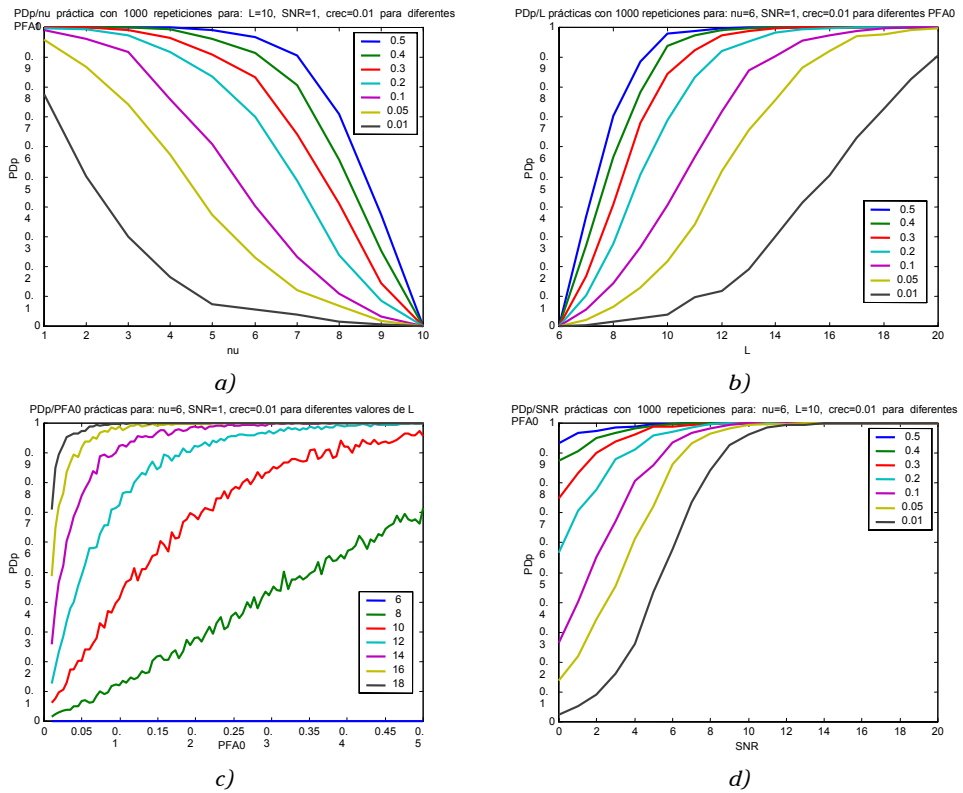


Figura 30. Gráficas prácticas de PD_p en función de los parámetros nu , L , PFA_0 y SNR .

Podemos observar como:

- ✓ Si nu aumenta la PD_p disminuye. Al igual que en el caso anterior, al aumentar nu somos más restrictivos en la fusión y perdemos en PD_p .
- ✓ Si L aumenta la PD_p aumenta. Como ya se ha comentado anteriormente si L aumenta tenemos más decisores locales y por lo tanto somos menos restrictivos en la fusión al dejar fijo el parámetro nu .
- ✓ Si la PFA_0 aumenta la PD_p aumenta. Comprobando que también sigue, en el caso de la PD_p , la misma tendencia que cada una de las PFA de los decisores locales.
- ✓ Si la SNR aumenta la PD_p aumenta. Como es lógico, al tener un mayor nivel de la señal sobre el fondo de ruido mejoramos la detección.

Cabe destacar el caso de buscar la relación entre la PD_p y la pendiente de crecimiento $crec$ en el que utilizaremos un valor de $nu=6$ decisiones acertadas, $L=10$, una $SNR=1$, variando $crec$ de $-0,1$ a $0,1$ y unas PFA_0 entre 0.5 y 0.01 . Figura 31.




Figura 31. Gráfica práctica de PD_p en función del parámetro $crec$.

Se observa como la PD_p disminuye a medida que la pendiente de crecimiento es menor tanto si la pendiente es positiva como negativa. Como cabía esperar, en el detector de persistencia no nos estamos fijando en si la persistencia es creciente o decreciente sino en si existe o no esta persistencia, de forma que a medida que la pendiente de crecimiento va aumentando mejoramos en probabilidad de detección al aumentar la SNR , independientemente de si esta mejora de señal proviene de valores mayores o menores de señal.

3.8.2 Generación de curvas de PFA_i y PD_i del detector de crecimiento

En el caso del detector de persistencia, no disponemos de expresiones teóricas que nos relacionen la PFA_i y la PD_i con los parámetros del modelo a estudiar, que en este caso serán únicamente el número de segmentos en que dividimos el vector de datos L y la probabilidad de falsa alarma teórica que utilizaremos para obtener el umbral del detector de crecimiento $PFAt$. Por lo que no podremos mostrar una serie de curvas donde comparar los resultados teóricos y prácticos, realizándose por tanto únicamente simulaciones prácticas.

3.8.2.1 Obtención de curvas de PFA_i en función de los parámetros: L y $PFAt$.

Para el caso del cálculo de la PFA_i supondremos, como en el caso anterior del cálculo de la PFA_p , que las muestras de entrada son únicamente un vector de ruido gaussiano correlado de tamaño $T=L \cdot M$ muestras correladas tomadas en L segmentos de tamaño $M=6$.

Entonces, al igual que en el caso anterior, se pasan por cada una de las etapas del modelo clásico de la Figura 23, es decir se separa el vector de $M=6$ muestras en $N=1$ muestras que entran al predictor lineal utilizando las $D=5$ muestras restantes para restarlas a la salida del predictor. A continuación se pasan por el filtro de preblanqueo y por el estimador de la señal con la matriz \mathbf{P} obteniendo el vector Z_E del esquema de la Figura 24 y calculándose el estadístico del detector de persistencia de la ecuación (118), el cual se compara con el umbral del detector de crecimiento obtenido a partir de la $PFAt$ deseada.

Este proceso se realiza un número elevado de veces (1000) para ir obteniendo diferentes probabilidades de falsa alarma para el caso del detector de crecimiento.

A continuación vamos a mostrar los resultados obtenidos en los siguientes supuestos:

- En el caso de buscar la relación entre la PFA_i y el parámetro L variaremos este parámetro L entre 6 y 20 segmentos, tomando unas $PFAt$ entre 0.5 y 0.01. Figura 32a.
- En el caso de buscar la relación entre la PFA_i y la $PFAt$ utilizaremos diferentes valores de L entre 6 y 18, variando la $PFAt$ de 0,01 a 0,5. Figura 32b.

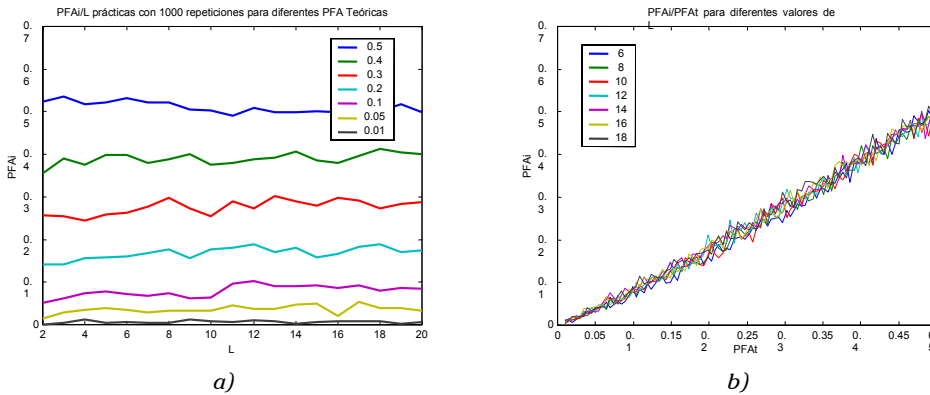


Figura 32. Gráficas prácticas de PFA_i en función de los parámetros L y PFA_t .

Donde podemos observar como:

- ✓ Al ir variando L la PFA_i permanece aproximadamente constante aunque en un valor que depende de la PFA_t con la que se esté trabajando. Esto está indicando que la detección de crecimiento es independiente del nivel de segmentación que se esté realizando ya que esta segmentación del vector de datos no afecta al crecimiento o no del vector en sí mismo.
- ✓ Por otro lado se observa como al ir aumentando la PFA_t la PFA_i también aumenta en el mismo orden. Como cabía esperar la PFA_t sigue la misma tendencia que la PFA_i del sistema independientemente del valor del parámetro L ya que básicamente son el mismo concepto.

3.8.2.2 Obtención de curvas de PD_i en función de los parámetros: L , PFA_t , SNR y $crec$.

En este caso, para calcular la probabilidad de detección, seguiremos el mismo esquema desarrollado en el apartado anterior pero utilizando, como vector de entrada, un vector de ruido gaussiano correlado de tamaño $T=L \cdot M$ muestras correladas con L segmentos de tamaño $M=6$ muestras, con un fuego aditivo de valor inicial x_{ini} dependiente de la SNR y con pendiente de crecimiento $crec$ a lo largo de las T muestras.

A continuación vamos a mostrar los resultados obtenidos en los siguientes supuestos:

- En el caso de buscar la relación entre la PD_i y el parámetro L utilizaremos una $SNR=1$, con $crec=0.01$, variando L de 6 a 20 y unas PFA_t entre 0.5 y 0.01. Figura 33a.
- En el caso de buscar la relación entre la PD_i y la PFA_t utilizaremos un valor de $SNR=1$ y una $crec=0.01$, variando la PFA_t entre 0,01 y 0,5 para diferentes valores de L entre 6 y 18. Figura 33b.

- En el caso de buscar la relación entre la PD_i y la SNR utilizaremos un valor de $L=10$, una $crec=0.01$, variando la SNR de 0 a 20 y unas PFA_t entre 0.5 y 0.01. Figura 33c.
- El caso de buscar la relación entre la PD_i y la pendiente de crecimiento $crec$ en el que utilizaremos un valor de $L=10$, una $SNR=1$, variando $crec$ de -0,1 a 0,1 y unas PFA_t entre 0.5 y 0.01. Figura 33d.

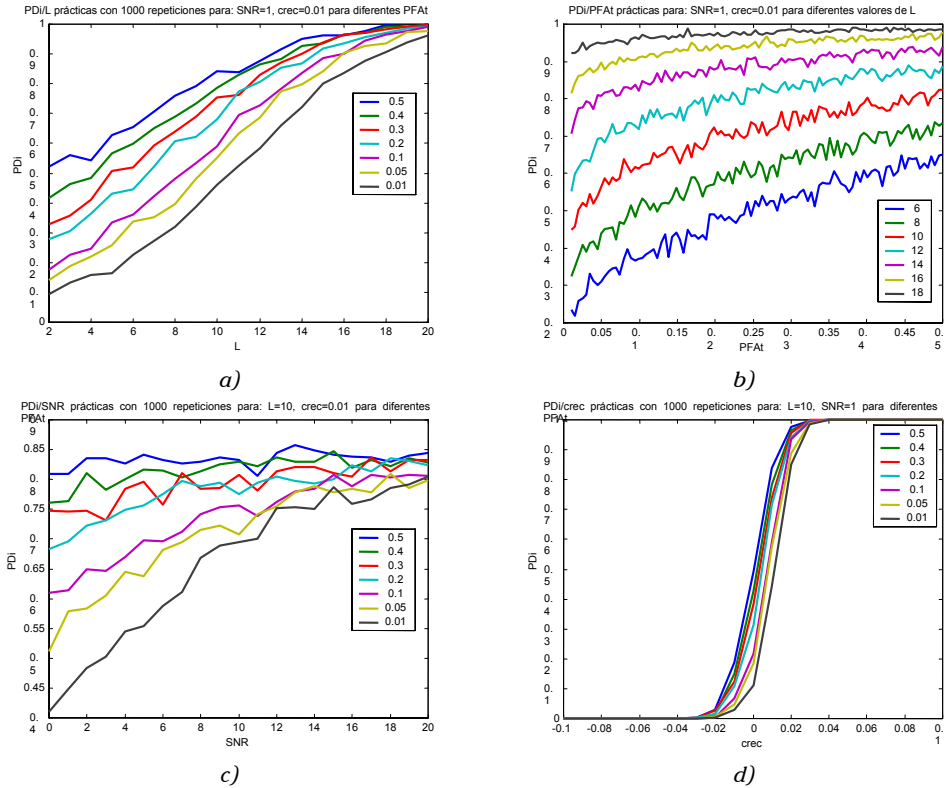


Figura 33. Gráficas de PD_i en función de los parámetros L , PFA_t , SNR y $crec$.

Podemos observar como:

- ✓ Si L aumenta la PD_i aumenta. En este caso sí que existe una dependencia de la PD_i con el número de segmentos L ya que al aumentar estos estamos aumentando el tamaño del vector de datos T y por lo tanto al introducir el fuego aditivo, éste crece a lo largo de todo el intervalo bajo estudio incrementándose las posibilidades de detectarlo al ser más largo.
- ✓ Si la PFA_t aumenta la PD_i aumenta. Como es lógico si somos menos restrictivos en probabilidad de falsa alarma aumentan las probabilidades de detección.
- ✓ Si la SNR aumenta la PD_i aumenta. Como es lógico, al tener un mayor nivel de la señal sobre el fondo de ruido mejoramos la detección.
- ✓ En este caso se observa como la PD_i aumenta a medida que la pendiente de crecimiento $crec$ va aumentando desde valores negativos a valores positivos,

es decir que el detector de crecimiento es sensible a pendientes de crecimiento únicamente positivas y no negativas como ocurría con el detector de persistencia, de ahí su denominación.

3.8.3 Generación de curvas de PFA_T y PD_T globales como fusión del detector fusionado de persistencia y del detector de crecimiento

Vamos a realizar en este punto una serie de simulaciones que nos van a permitir comprobar la veracidad de las expresiones (133) y (134) como resultado de la fusión de decisiones final como fusión de las decisiones del detector fusionado de persistencia y del detector de crecimiento.

Estas expresiones nos vienen a decir que la PFA_T global del sistema será el producto de las PFA s de las decisiones a fusionar, es decir, el producto de la PFA_p y la PFA_i y que la PD_T global del sistema será el producto de las probabilidades de detección de las decisiones a fusionar, es decir, el producto de la PD_p y la PD_i .

3.8.3.1 Obtención de curvas de PFA_T en función de los parámetros: L y PFA_0 ó PFA_t .

Para obtener las curvas de PFA_T en función de los parámetros comunes a las PFA s a fusionar PFA_p y PFA_i vamos a realizar las siguientes operaciones: primero vamos a volver a realizar las simulaciones de la PFA_p y la PFA_i para cada parámetro a controlar en este caso L y la PFA_0 ó PFA_t , con el resto de parámetros iguales, como ya se han mostrado en los apartados anteriores. A continuación aplicaremos la ecuación (133) para obtener la PFA_T teórica como producto de las PFA s obtenidas mostrándola en línea continua, y finalmente, obtendremos de nuevo otra simulación donde se obtenga la PFA_T práctica según el esquema completo de la Figura 27, que mostraremos con asteriscos, de forma que posteriormente sea factible la comparación entre la PFA_T teórica en línea continua y la PFA_T práctica con asteriscos.

Para el caso del cálculo de la PFA_T práctica supondremos que las muestras de entrada son únicamente un vector de ruido gaussiano correlado de tamaño $T=L \cdot M$ muestras correladas tomadas en L segmentos de tamaño $M=6$, para simplificar.

A continuación se pasan por cada una de las etapas del modelo clásico de la Figura 23, es decir se separa el vector de $M=6$ muestras en $N=1$ muestras que entran al predictor lineal utilizando las $D=5$ muestras restantes para restarlas a la salida del predictor. A continuación se pasan por el filtro de preblanqueo y se realiza la detección de cada uno de los segmentos utilizando el estimador de la señal con la matriz P , obteniendo el vector Z_E del esquema de la Figura 24.

Seguidamente, por un lado se pasa este vector por la detección por el umbral del detector de persistencia fijado a partir de la PFA_0 , como ya se indicó en el esquema de la Figura 27 y se fusionan las decisiones de los L segmentos decidiendo si hay detección o no en función de si nu detecciones han sido

correctas. Y por otro lado se calcula el estadístico del detector de persistencia de la ecuación (118), el cual se compara con el umbral del detector de crecimiento obtenido a partir de la PFA_t deseada.

Finalmente se fusionan estas dos decisiones de forma que se decide que hay detección si y sólo si ha habido detección en el detector de persistencia y simultáneamente en el detector de crecimiento.

Este proceso se realiza un número elevado de veces (1000) para ir obteniendo diferentes probabilidades de falsa alarma.

3.8.3.1.1 Para el caso de la obtención de la PFA_T en función del parámetro L .

Se obtienen los siguientes resultados bajo los supuestos:

- Utilizaremos un valor de $nu=6$ decisiones acertadas en el detector de persistencia.
- Variando el número de segmentos L entre 6 y 20, en los dos detectores.
- Con unas PFA locales de: PFA_0 (PFA de cada uno de los detectores de persistencia (Figura 34a)) ó PFA_t (PFA del detector de crecimiento (Figura 34b)) entre 0.5 y 0.01. (Figura 34c)

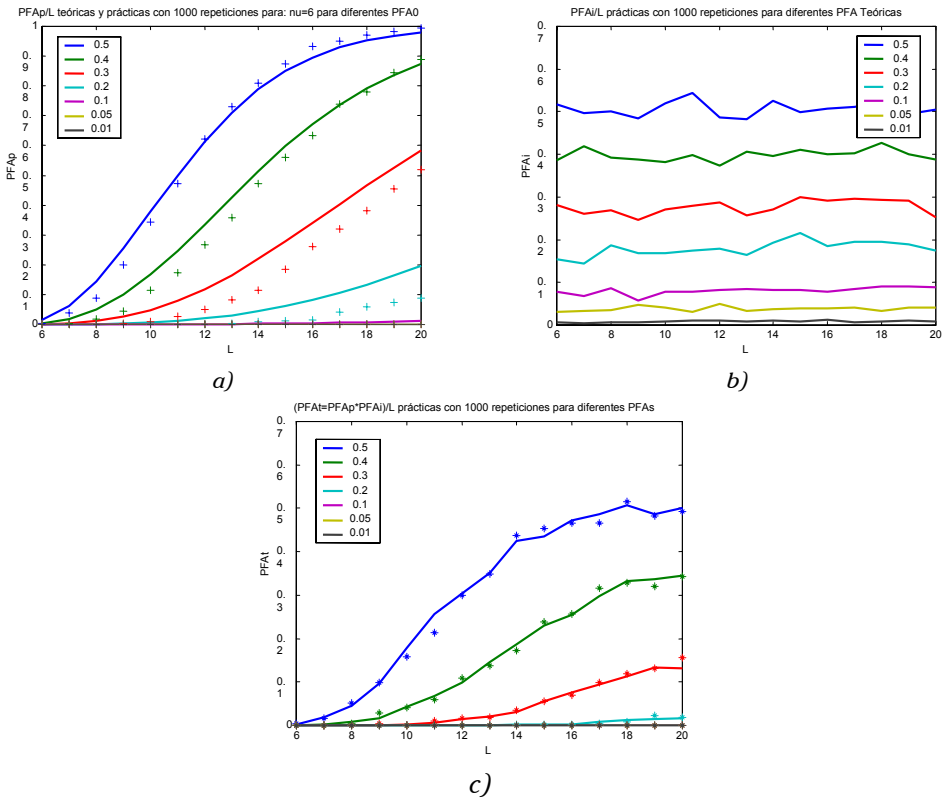


Figura 34. Gráficas de PFA_p , PFA_i y PFA_T teórica (línea continua) y práctica (asteriscos) en función del parámetro L .

Donde se puede observar (Figura 34c) como:


- Si el número de segmentos L aumenta entonces la PFA_T aumenta. Ya que, por un lado al aumentar el número de segmentos L tenemos más decisores de persistencia posibles y por lo tanto al mantener nu fijo estamos siendo menos restrictivos aumentando la PFA_p , (Figura 34a) y por otro lado, al ir variando L la PFA_i permanece aproximadamente constante aunque en un valor que depende de la PFA_t con la que se esté trabajando, por lo que la detección de crecimiento es independiente del nivel de segmentación que se esté realizando ya que esta segmentación del vector de datos no afecta al crecimiento o no del vector en sí mismo (Figura 34b).
- Si se compara la línea continua de PFA_T teórica en función del parámetro L como producto de la PFA_p y la PFA_i con la secuencia de asteriscos de PFA_T práctica obtenida, se puede observar claramente que estos últimos siguen prácticamente y casi perfectamente a la PFA_T teórica, por lo que se verifican los estudios realizados y que dan lugar a la ecuación (133). (Figura 34c).

3.8.3.1.2 Para el caso de la obtención de la PFA_T en función del parámetro de PFA local.


Se obtienen los siguientes resultados bajo los supuestos:

- Utilizaremos un valor de $nu=6$ decisiones acertadas.
- Para diferentes valores de segmentos L entre 6 y 18, en los dos detectores.
- Variando las PFA locales de: PFA_0 (PFA de cada uno de los detectores de persistencia (Figura 35a)) ó PFA_t (PFA del detector de crecimiento (Figura 35b)) entre 0.01 y 0.5. (Figura 35c)

PFA_p/PFA₀ teóricas y prácticas con 1000 repeticiones para: nu=6 para diferentes valores de L



PFA_i/PFA_t para diferentes valores de L






Figura 35. Gráficas de $PFAP$, $PFAi$ y PFA_T teórica (línea continua) y práctica (asteriscos) en función de los parámetros de PFA s locales.

Donde se puede observar (Figura 35c) como:

- Por un lado al ir disminuyendo la PFA_0 la PFA_p también disminuye ya que como cabía esperar la PFA de cada uno de los decisores por separado sigue la misma tendencia que la PFA_p del detector fusionado de persistencia (Figura 34a), y por otro lado se observa como al ir aumentando la PFA_t la PFA_i también aumenta y en el mismo orden, ya que la PFA_t sigue la misma tendencia que la PFA_i del detector de crecimiento independientemente del valor del parámetro L ya que básicamente son el mismo concepto (Figura 35b).
- Finalmente si se compara la línea continua de PFA_T teórica en función de las PFA locales como producto de la PFA_p y la PFA_i con la secuencia de asteriscos de PFA_T práctica obtenida, se puede observar claramente que estos últimos siguen prácticamente a la PFA_T teórica. (Figura 35c).

Se puede concluir que la probabilidad de falsa alarma de la fusión de las decisiones (PFA_T) de los detectores de persistencia fusionados (PFA_p) y del detector de crecimiento (PFA_i), es igual al producto de las probabilidades de falsa alarma por separado de estas dos decisiones fusionadas, por lo que se verifican los estudios realizados y que dan lugar a la ecuación (133).

3.8.3.2 Obtención de curvas de PD_t en función de los parámetros: L , PFA , SNR y $crec$.

En el caso de realizar las simulaciones para obtener las curvas de PD_T en función de los parámetros comunes a las probabilidades de detección a fusionar PD_p y PD_i vamos a realizar, al igual que en el caso anterior, las mismas operaciones: primero vamos a volver a realizar las simulaciones de la PD_p y la PD_i para cada parámetro a controlar en este caso los parámetros: L , PFA_0 ó PFA_t , SNR y $crec$, con el resto de parámetros comunes para poder realizar las comparaciones oportunas. Seguidamente aplicaremos la ecuación (134) para obtener la PD_T teórica como

producto de las probabilidades de detección obtenidas, y finalmente, obtendremos de nuevo otra simulación donde se obtenga la PD_T práctica según el esquema completo de la Figura 27, de forma que posteriormente sea factible la comparación entre la PD_T teórica en línea continua y la PD_T práctica con asteriscos.

En este caso, para calcular la PD_T práctica, seguiremos el mismo esquema desarrollado en el apartado anterior pero utilizando, como vector de entrada, un vector de ruido gaussiano correlado de tamaño $T=L \cdot M$ muestras correladas con L segmentos de tamaño $M=6$ muestras, con un fuego aditivo de valor inicial x_{ini} dependiente de la SNR y con pendiente de crecimiento $crec$ a lo largo de las T muestras.

A continuación se pasan por cada una de las etapas del modelo clásico de la Figura 23, es decir se separa el vector de $M=6$ muestras en $N=1$ muestras que entran al predictor lineal utilizando las $D=5$ restantes para restarlas a la salida del predictor. A continuación se pasan por el filtro de preblanqueo y se realiza la detección de cada uno de los segmentos utilizando el estimador de la señal con la matriz P , obteniendo el vector Z_E del esquema de la Figura 24.

Seguidamente, por un lado se pasa este vector por la detección por el umbral del detector de persistencia fijado a partir de la PFA_0 , como ya se indicó en el esquema de la Figura 27 y se fusionan las decisiones de los L segmentos decidiendo si hay detección o no en función de si nu detecciones han sido correctas. Y por otro lado se calcula el estadístico del detector de persistencia de la ecuación (118), el cual se compara con el umbral del detector de crecimiento obtenido a partir de la PFA_t deseada.

Finalmente se fusionan estas dos decisiones de forma que se decide que hay detección si y solo si ha habido detección en el detector de persistencia y simultáneamente en el detector de crecimiento.

Este proceso se realiza un número elevado de veces (1000) para ir obteniendo diferentes probabilidades de falsa alarma.

3.8.3.2.1 Para el caso de la obtención de la PD_T en función del parámetro L .

Se obtienen los siguientes resultados bajo los supuestos:

- Utilizaremos un valor de $nu=6$ decisiones acertadas en el detector de persistencia.
- Se añadirá un fuego aditivo con una SNR de 1 dB para calcular el valor inicial y una pendiente de crecimiento $crec$ de 0,01.
- Variando el número de segmentos L entre 6 y 20, en los dos detectores.
- Con unas PFA locales PFA_0 y PFA_t entre 0.5 y 0.01.

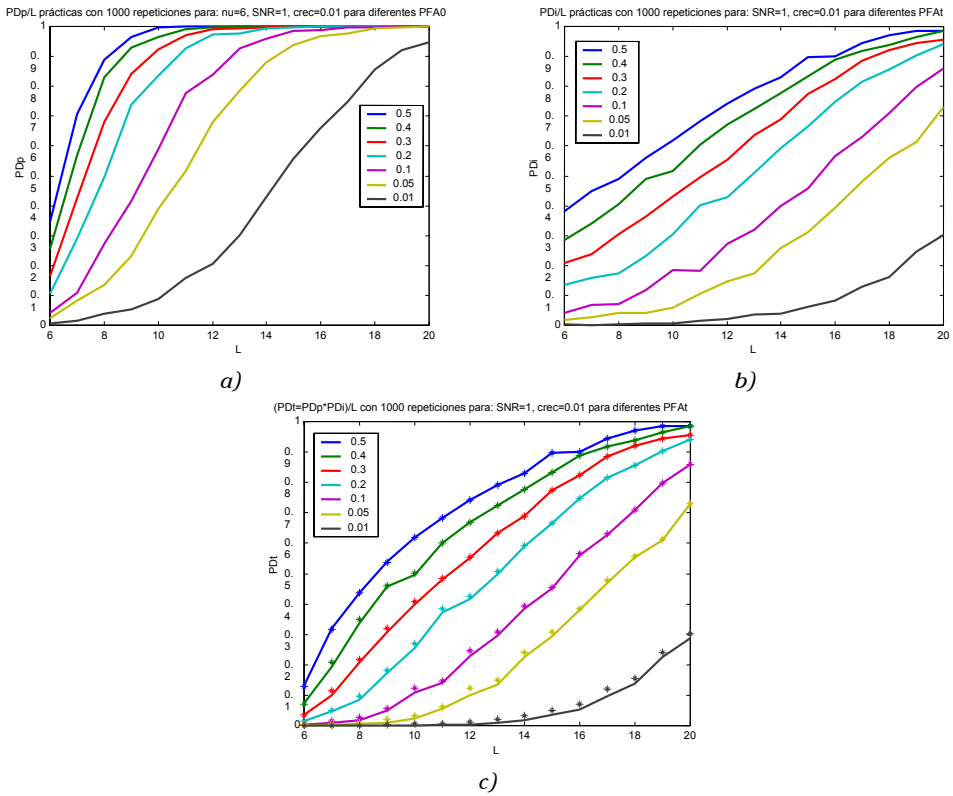


Figura 36. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función del parámetro L .

Donde se puede observar como:

- ✓ Si el número de segmentos L aumenta entonces la PD_T aumenta. Pues, por un lado al aumentar el número de segmentos L tenemos más decisores de persistencia posibles y por lo tanto al mantener nu fijo estamos siendo menos restrictivos aumentando la PD_p , (Figura 36a) y por otro lado, al ir variando L la PD_i también va aumentando ya que en este caso si que existe una dependencia de la PD_i con el número de segmentos L debido a que al aumentar estos estamos aumentando el tamaño del vector de datos T y al introducir el fuego aditivo, éste crece a lo largo de todo el intervalo bajo estudio incrementándose las posibilidades de detectarlo al ser más largo. (Figura 36b).
- Si se compara la línea continua de PD_T teórica en función del parámetro L como producto de la PD_p y la PD_i con la secuencia de asteriscos de PD_T práctica obtenida, se puede observar claramente que estos últimos siguen prácticamente y perfectamente a la PD_T teórica, por lo que se verifican los estudios realizados y que dan lugar a la ecuación (134). (Figura 36c).

3.8.3.2.2 Para el caso de la obtención de la PD_T en función del parámetro de PFA local.

Se obtienen los siguientes resultados bajo los supuestos:

- Utilizaremos un valor de $nu=6$ decisiones acertadas, para el detector de persistencia fusionado.
- Un mismo fuego aditivo con $SNR=1$ y $crec=0,01$.
- Para diferentes valores de segmentos L entre 6 y 18, en los dos detectores.
- Con unas PFA locales PFA_0 y PFA_t entre 0.5 y 0.01.




Figura 37. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función de los parámetros de PFAs locales.

Donde se puede observar como:

- Por un lado, en el detector de persistencia, al ir aumentando la PFA_0 la PD_p también aumenta ya que el ser menos restrictivos en probabilidad de falsa alarma, en cada una de las decisiones por separado, implica una mayor probabilidad de una correcta detección. (Figura 37a).
- Por otro lado, en el detector de crecimiento se observa el mismo fenómeno que en el caso anterior ya que al ir aumentando la PFA_t la PD_i también aumenta aunque en este caso no tan rápidamente. (Figura 37b).

➤ Finalmente, también en este caso, si se compara la línea continua de PD_T teórica en función de las PFA locales como producto de la PD_p y la PD_i , con la secuencia de asteriscos de PD_T práctica obtenida, se puede observar claramente que estos últimos siguen perfectamente a la PD_T teórica, por lo que se verifican los estudios realizados y que dan lugar a la ecuación (134). (Figura 37c).

3.8.3.2.3 Para el caso de la obtención de la PD_T en función del parámetro de SNR.

Se obtienen los siguientes resultados bajo los supuestos:

- Utilizaremos un valor de $nu=6$ decisiones acertadas, para el detector de persistencia fusionado.
- Un número de segmentos medio de $L=10$. Para los dos detectores.
- Un mismo fuego aditivo con pendiente de crecimiento fija de $crec=0,01$.
- Para diferentes valores de SNR entre 0 y 20.
- Con unas PFA locales PFA_0 y PFA_t entre 0.5 y 0.01.

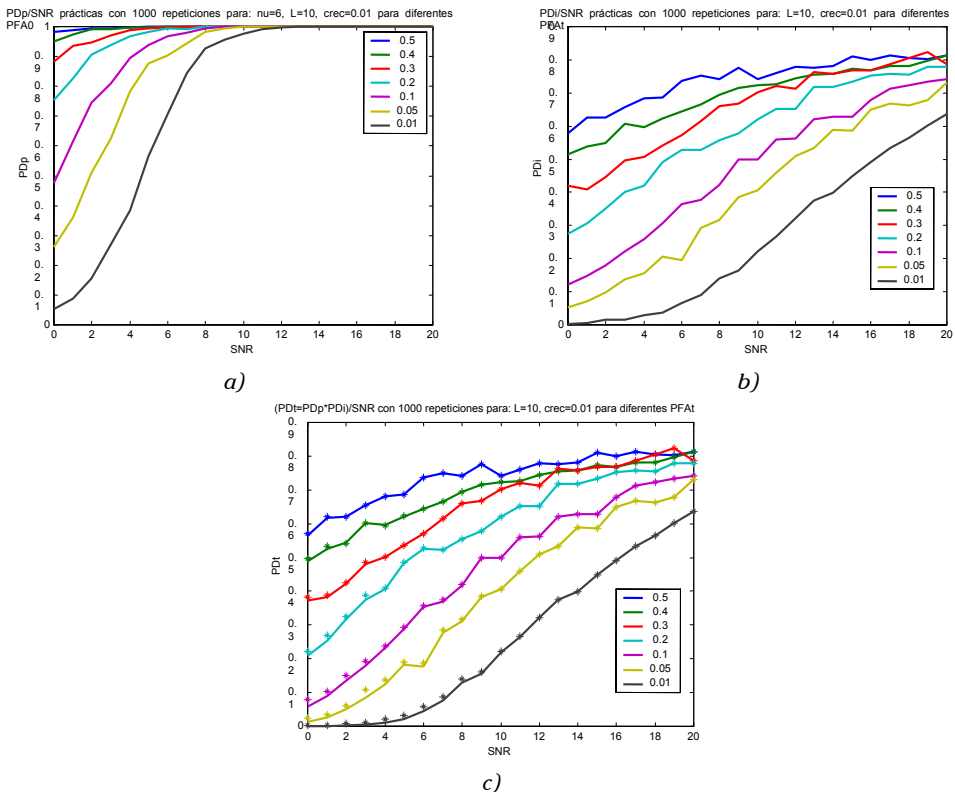


Figura 38. Gráficas de PD_p , PDI y PD_T teórica (línea continua) y práctica (asteriscos) en función del parámetro de SNR.



Donde se puede observar como:

- Por un lado, en el detector de persistencia, al ir aumentando la SNR la PD_p aumenta, como es natural ya que si el fuego tiene un mayor nivel sobre el ruido es lógico que se consiga un mayor grado de detección. (Figura 38a).
- Por otro lado, en el detector de crecimiento se observa el mismo fenómeno que en el caso anterior ya que al ir aumentando la SNR la PD_i también aumenta aunque en este caso no tan rápidamente. (Figura 38b).
- Finalmente, también en este caso, si se compara la línea continua de PD_T teórica en función de la SNR como producto de la PD_p y la PD_i , con la secuencia de asteriscos de PD_T práctica obtenida, se puede observar claramente que estos últimos siguen perfectamente a la PD_T teórica, por lo que se siguen verificando los estudios realizados y que dan lugar a la ecuación (134). (Figura 38c).

3.8.3.2.4 Para el caso de la obtención de la PD_T en función del parámetro $crec$.

Se obtienen los siguientes resultados bajo los supuestos:

- Utilizaremos un valor de $nu=6$ decisiones acertadas, para el detector de persistencia fusionado.
- Un número de segmentos medio de $L=10$. Para los dos detectores.
- Un mismo fuego aditivo con relación señal a ruido SNR de 1 dB.
- Para diferentes pendientes de crecimiento tanto positivas como negativas $crec$ entre -0,1 y 0,1.
- Con unas PFA locales PFA_0 y PFA_t entre 0.5 y 0.01.






Figura 39. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función del parámetro de pendiente de crecimiento $crec$.

Finalmente se observa como en el caso del detector de persistencia, la PD_p disminuye a medida que la pendiente de crecimiento es menor, en valor absoluto. Ya que en este caso nos estamos fijando únicamente en la existencia o no de persistencia y no en el tipo de ésta. (Figura 39a)

Sin embargo en el caso del detector de crecimiento se observa como la PD_i aumenta a medida que la pendiente de crecimiento $crec$ va aumentando desde valores negativos a valores positivos, es decir que el detector de crecimiento es sensible a pendientes de crecimiento únicamente positivas y no negativas como ocurría con el detector de persistencia, de ahí su denominación. (Figura 39b)

Además, como es lógico, a medida que la pendiente de crecimiento va aumentando mejoramos en probabilidad de detección al aumentar la SNR .

Finalmente y como en los casos anteriores, si se compara la línea continua de PD_T teórica en función de la pendiente $crec$ como producto de la PD_p y la PD_i , con la secuencia de asteriscos de PD_T práctica obtenida, se puede observar claramente que estos últimos siguen perfectamente a la PD_T teórica. (Figura 39c).

Se puede concluir que la probabilidad de detección de la fusión de las decisiones (PD_T) de los detectores de persistencia fusionados (PD_p) y del detector de crecimiento (PD_i), es igual al producto de las probabilidades de detección por separado de estas dos decisiones fusionadas, por lo que se verifican los estudios realizados y que dan lugar a la ecuación (134).

3.9 Comprobación de resultados con experiencias reales

Como ya se ha comentado en la introducción al presente capítulo, ha sido posible la implementación de los desarrollos algorítmicos implementados por el grupo de tratamiento de la señal (GTS) en diferentes sistemas reales y en funcionamiento, a lo largo del tiempo, en algunas zonas de la comunidad valenciana.

Por otro lado el GTS sigue trabajando en este tema gracias a la concesión del proyecto CICYT del Ministerio [37] por lo que todas las mejoras aportadas en la presente tesis están siendo introducidas en los sistemas mencionados, y especialmente en el sistema DISTER [13] que está funcionando y siendo utilizado en la actualidad por los bomberos de la ciudad de Valencia.

3.9.1 El sistema DISTER

Una vez desarrollado el sistema DELFIN [12], se cumplió el objetivo fundamental de la experiencia piloto, que era la definición de un sistema de detección automática de incendios que tuviera comprobada su viabilidad tanto técnica como económica.

En ese momento surge la posibilidad de gestar íntegramente por el departamento de comunicaciones lo que finalmente sería el sistema DISTER, que se beneficia de la experiencia piloto del DELFIN del que se propone mantener la arquitectura y conceptos básicos pero introduce algunas novedades, mencionando las más significativas a continuación:

- ✚ Utilización de cámaras de infrarrojos de última generación. Ésta es una tecnología que avanza muy rápidamente, por lo que se recomienda utilizar cámaras infrarrojas de mayores prestaciones, siendo su coste similar e incluso inferior a las utilizadas en esta experiencia piloto.
- ✚ El control de las cámaras debe mejorarse, mediante un sistema de motores específico para este tipo de aplicaciones.
- ✚ Conveniencia de considerar dos niveles de comunicaciones. El primer nivel será el habitual y debe permitir la transmisión de imágenes de media-alta calidad. El segundo, de emergencia, puede basarse en GSM, GPRS. Nótese que éste es el único considerado en la experiencia piloto.

Vamos a describir a continuación cómo se han desarrollado los diferentes subsistemas del sistema en la solución implementada en el Parque Natural de la Albufera, ubicado en la localidad de “El Saler” en el Término Municipal de Valencia, gracias al convenio de colaboración entre el Ayuntamiento de Valencia y la Universidad Politécnica de Valencia, a través del Departamento de Comunicaciones.

El sistema DISTER es capaz de detectar e interpretar cambios de temperatura en las zonas del Marjal del lago de La Albufera y la Devesa, dentro del Parque Natural de El Saler, y generar alarmas de detección de fuegos incontrolados, es decir, de posibles focos de incendios.

Para ello, el sistema se ha instalado en tres emplazamientos o estaciones remotas que cubren la zona de detección con un total de cuatro cámaras térmicas de altas prestaciones, y una estación central ubicada en el Centro de Comunicaciones del Parque Central de Bomberos de Valencia (CECOM), que recibe la información de las estaciones remotas, estando operativo en la campaña de verano de 2002 hasta la actualidad. (Ver Figura 40)




Figura 40. Zona vigilada en la instalación del DISTER en El Saler.

Cada uno de los puestos de observación se compone de cámara térmica con su correspondiente unidad de adquisición, procesador, sistema de transmisión RDSI, comunicaciones de seguridad mediante GSM, y un sistema de apoyo a las intervenciones de video en tiempo real. (Figura 41).

Se han instalado 4 estaciones remotas, dos fijas (con sensor térmico sin motor) y otras dos con sensor térmico giratorio. Éstas son:

- Estación remota en Gola 4F. Fija, mirando hacia el Norte, hacia el pueblo de El Saler y la ciudad de Valencia.
- Estación remota en Gola 4M. Móvil, haciendo un barrido Norte-Sur por el Oeste, divisando la Devesa de la Albufera
- Estación remota en Gola 10. Móvil, haciendo un barrido Norte-Sur por el Este, divisando las zonas más cercanas al mar mediterráneo.

- Estación remota de El Perellonet. Fija, mirando hacia el Norte, hacia el marjal de El Saler.



Figura 41. Ejemplo de instalación en una estación local móvil y detalle de cámara termográfica Flir Thermovision 320V.

Las estaciones remotas realizan, entre otras funciones:

- La adquisición y procesado de las imágenes termográficas. Es el núcleo del sistema y se encarga de la captura de las secuencias de imágenes infrarrojas, su procesado y la determinación de puntos susceptibles de alarma de incendio.
- Intercambio de información con los elementos de control de los motores, ajustes en las cámaras térmicas y el interfaz con los módulos de comunicaciones.
- La transmisión de alarmas, sincronización y comandos de control. Con sistemas RDSI sobre línea telefónica y GSM de seguridad.
- Se dispone además de tres enlaces de vídeo desde cada uno de los puestos remotos que permiten recibir imágenes térmicas y de vídeo en tiempo real, así como telecontrolar las cámaras remotas desde el puesto de mando de la Central. (Figura 42)

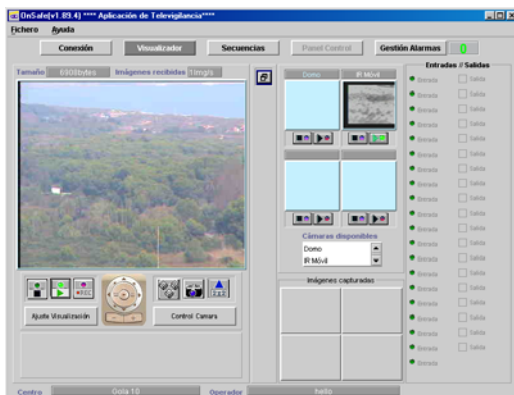


Figura 42. Aspecto de la pantalla de control del sistema de apoyo de vídeo y detalle de cámara de vídeo motorizada tipo Domo.

En la estación Central (CECOM del Parque Central de Bomberos) se han instalado los controladores del sistema de infrarrojos y del sistema de vídeo, el control de las comunicaciones y el sistema de información geográfica para la gestión de alarmas y control de recursos sobre la cartografía digital. Además, se cuenta con equipos de comunicaciones RDSI y GSM que enlazan con cada uno de los puestos de observación, y de pantallas separadas para la monitorización del sistema de gestión y de las cámaras térmicas y visibles (Ver Figura 43)

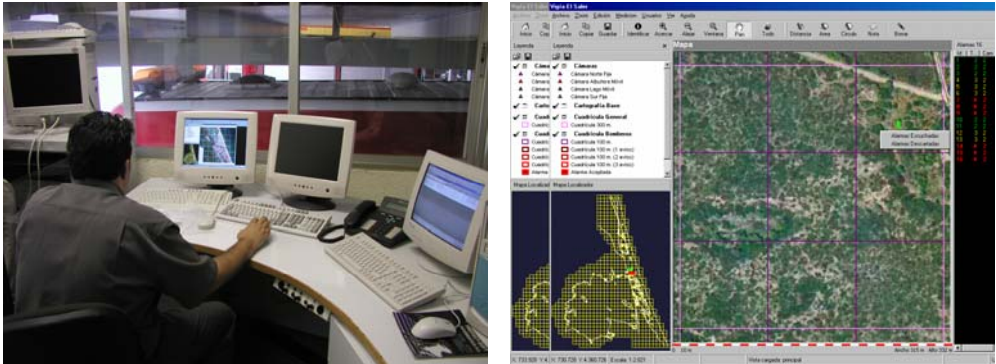


Figura 43. Estación de control en el CECOM del Parque de Bomberos de Valencia y aspecto de la pantalla del sistema de gestión de la Estación Central.

Este sistema maneja cartografía digitalizada e imágenes de la zona a controlar. El sistema de control puede incorporar numerosas funciones de gestión y vinculación con otro tipo de programas y bases de datos, que ayudan a la toma de decisiones y al manejo del sistema por parte de los operadores de Central.

El sistema mantiene la conexión con todos los elementos de los puestos de observación, recibe y posiciona alarmas sobre la cartografía.

También se dispone de la posibilidad de mantener archivos con históricos de funcionamiento del sistema, que se utilizarán en posteriores análisis o informes sobre cada una de las incidencias gestionadas.

El operador dispone de funciones de apoyo a la gestión mediante identificadores de cámara, numeración dinámica, posicionamiento automático y reconocimiento de elementos sobre la pantalla.

3.9.2 Experiencias destacables del funcionamiento del sistema DISTER

A continuación se van a describir algunas experiencias destacables del funcionamiento del sistema DISTER durante los primeros años de funcionamiento.

Comenzando con algunas pruebas con fuegos reales que se realizaron al instalar el sistema en la zona de la Devesa de El Saler para comprobar la viabilidad del sistema y sus márgenes de coberturas.

Continuando con algunos ejemplos de detecciones reales que experimentó el sistema y que sirvieron para generar confianza en los usuarios finales del sistema, es decir en el cuerpo de bomberos de la ciudad de Valencia

Finalizando con la evaluación de algunos datos del funcionamiento del sistema durante los dos primeros años de actividad, haciendo especial hincapié en las incidencias más destacables y curiosas del funcionamiento habitual del sistema.

Para poder entender claramente las diversas figuras que se van a mostrar a continuación pasamos a describir cada tipo de alarma y el código de colores utilizado.

- *Alarmas “tipo 1”*. El valor a comparar con el umbral es la **energía** de la firma. No permite discriminar los efectos ocasionales, pero si frente al ruido de fondo. De color **azul claro**.
- *Alarmas “tipo 2”*. El valor a comparar con el umbral es la energía de la firma pero dentro de un determinado **subespacio** que favorece la existencia de persistencia. Permite discriminar efectos ocasionales no persistentes, y mejora también la discriminación frente al ruido de fondo. De color **azul oscuro** (en la imagen procesada) y **verde** (en el GIS).
- *Alarmas “tipo 3”*. Detectan **crecimiento**, el valor a comparar es una medida del crecimiento en la firma. Permite discriminar efectos ocasionales no crecientes, y mejora también la discriminación frente al ruido de fondo. De **color amarillo**.

Adicionalmente el sistema está diseñado para poder aprovechar las características de ciertos tipos de cámaras termográficas que permiten generar automáticamente lo que denominaremos *alarmas “tipo 4”*, que no son más que simples alarmas de nivel de píxel, es decir que no actúan sobre la firma. Por lo tanto son alarmas que sólo se disparan cuando el nivel del píxel es muy elevado y que pueden garantizar la detección (aunque con bastante retardo ya que debe alcanzarse un nivel muy alto) en aquellos casos en que por cualquier circunstancia no se disparen las anteriores. De **color rojo**.

3.9.2.1 Pruebas con fuegos reales

Inicialmente vamos a comentar una serie de pruebas que se realizaron con fuegos reales controlados con diferentes condiciones de distancia, tipo de fuego, etc... A continuación veremos dos casos de incendios reales que el sistema detectó y por lo tanto ayudó a que los servicios de emergencia pudiesen actuar a tiempo. Finalizaremos con un pequeño extracto de algunas de las incidencias más destacables durante estas últimas temporadas de funcionamiento.

Estas pruebas fueron realizadas en el verano de 2002 con la colaboración de los Bomberos del Ayuntamiento de Valencia

En concreto se realizaron cuatro pruebas de fuego real controlado con las siguientes características:

1ª Prueba: En el Parque Central de Bomberos de Valencia.

- Distancia de 200 m.
- Material: Bidón con rastrojos y maleza
- Combustible: Gasolina.
- Forma de hacer el fuego: Se prende rápidamente el bidón.
- Detección inmediata del fuego. (Ver Figura 44).
- Con alarmas tipo 1 y 2 inicialmente, 3 en el momento álgido en el que se prende el fuego, y tipo 4 durante el tiempo en el que el bidón está ardiendo, como se ve en la imagen térmográfica en B/N con el color rojo de la última de las alarmas.



Figura 44. Imagen IR. Detección de fuego controlado en Parque de Bomberos.

2ª Prueba: Desde Gola 4M mirando a depuradora (Nor-Oeste).

- Distancia de 500 m.
- Material: Palés de 1 m².
- Combustible: Gasolina.
- Forma de hacer el fuego: fuego de pequeñas dimensiones y con crecimiento paulatino (simulando un fuego real)
- Detección del humo ya que no hay visión directa con el fuego debido a que la llama la tapan unos árboles altos. (Ver Figura 45).
- Con alarmas tipo 1 y 2 de persistencia del cambio.
- Sin alarma tipo 3 y 4 debido a la presencia únicamente de humo sin suficiente temperatura como para disparar éstas.

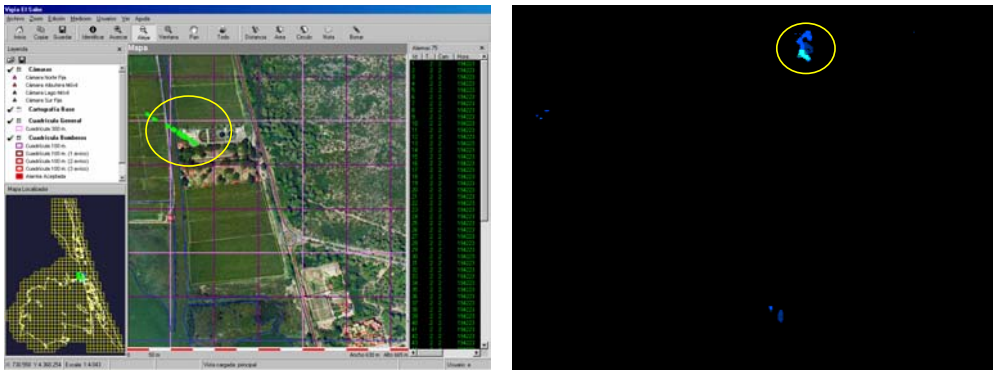


Figura 45. Imágenes GIS y procesada. Detección de fuego controlado desde Gola 4M.

3ª Prueba: Desde Gola 10 mirando a zona de aparcamientos.

- Distancia de 455 m.
- Material: Palés de 1 m².
- Combustible: Gasolina.
- Forma de hacer el fuego: fuego de pequeñas dimensiones y con crecimiento paulatino (simulando un fuego real)
- Detección inmediata de fuego en apenas unos 4 segundos. (Ver Figura 46).
- Con alarmas tipo 1, 2 y 3 de forma seguida.
- Sin alarma tipo 4 ya que el calor no es suficiente para llegar a disparar la alarma de temperatura de la cámara.




Figura 46. Imágenes visible, térmica, GIS y procesada. Detección de fuego controlado desde Gola 10.

4ª Prueba: Desde Gola 10 mirando a zona polideportiva en pueblo de “El Saler”

- Distancia de 4 Km.
- Material: Palés de 1 m²
- Combustible: Gasolina
- Forma de hacer el fuego: fuego de pequeñas dimensiones y con crecimiento paulatino (simulando un fuego real)
- Detección únicamente con tipo 1 del humo, debido a la gran distancia a la imposibilidad de tener visión directa con el objetivo.

3.9.2.2 Ejemplos de detección. Casos reales con intervención

Incendio del 1 de Noviembre de 2002.

- Zona de Perellonet.
- Distancia: 542 m
- Área quemada: 2.370 m² (0,23 Ha)
- Proceso y tiempos de la detección:
 - Primera alarma tipo 2 a las 17:39:10 horas.
 - Primera alarma tipo 3 a las 17:40:25 horas.
 - Primera alarma tipo 4 a las 17:41:23 horas.
 - Última alarma tipo 4 a las 18:07:18 horas, tras la intervención del cuerpo de bomberos.

La estación de detección situada en el edificio de Torre Ulises, Perellonet, tiene en su área de cobertura numerosos elementos que generarían alarmas de calor con un sistema convencional: vehículos en la carretera, actividad nocturna en las zonas de ocio, edificios, personas, zonas de picnic, playa, etc.

Como ya se ha expuesto, y se muestra en las imágenes siguientes, la mayor parte de esos potenciales focos de calor se eliminan en el proceso de la información que se hace en el propio puesto de detección, mientras que el resto aparecen como alarmas de movimiento o permanencia (tipos 1 y 2). Únicamente cuando se produce un crecimiento del foco de calor se transmite alarma de tipo 3, y en caso de superar un umbral elevado de temperatura se enviaría un código de tipo 4.

El caso que se muestra a continuación, corresponde a una quema de rastros no autorizada. Dicha quema fue detectada por el sistema y dio pie a una actuación de Bomberos sin mayores consecuencias. (Figura 47)

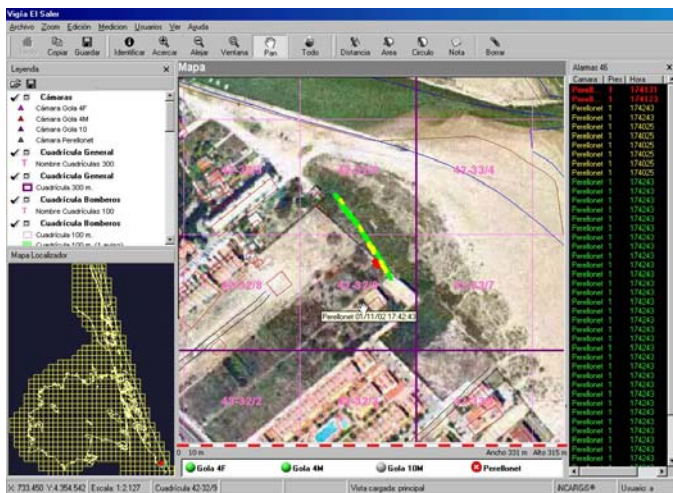


Figura 47. Imagen del sistema de detección GIS en el momento de recibirse la alarma en CECOM

Incendio del 9 de Enero de 2003.

- Zona vigilada por la cámara de Gola 4f.
- Distancia: 978 m
- Área quemada: 1.600 m² (0,16 Ha)
- Proceso y tiempos de la detección: (Ver Figura 48).
 - Primera alarma tipo 3 a las 14:52:33 horas.
 - Primera alarma tipo 2 a las 14:53:17 horas. (humo)
 - Primera alarma tipo 4 a las 14:53:45 horas.
 - Última alarma tipo 3 a las 14:54:29 horas, tras la intervención del cuerpo de bomberos.

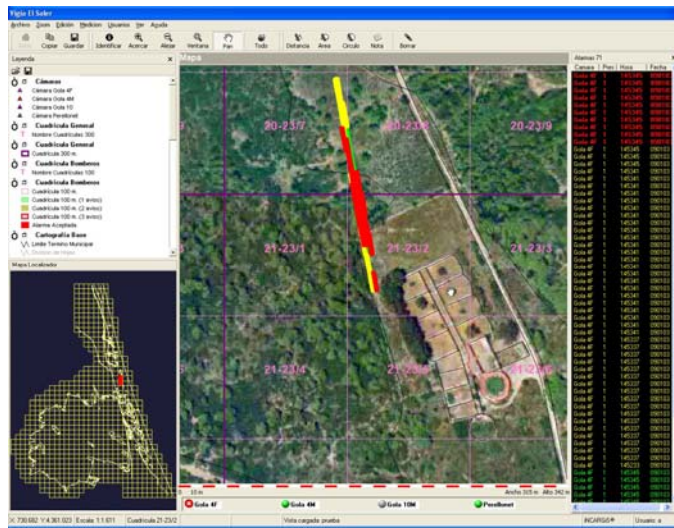


Figura 48. Secuencia de detección GIS. Incendio 9 Enero 2003 desde Gola 4F

3.9.2.3 Evaluación de datos de funcionamiento del sistema

Desde Junio de 2002 a Marzo de 2003, el sistema estuvo funcionando en periodo de pruebas para corregir diversos problemas de los diferentes subsistemas. Durante este periodo se detectaron los dos fuegos reales anteriormente mencionados a unos 542 m (Perellonet) y a unos 978 m (Gola 4F) que requirieron la intervención de los bomberos con total éxito. No pasaron inadvertidos fuegos significativos pero el sistema produjo muchas falsas o indeseables alarmas.

Durante la operación del sistema en la campaña de verano de 2002, el sistema DISTER registró los siguientes datos globales:

Número de imágenes térmicas analizadas:

- 18.000 imágenes por cámara y día
- Contando 4 cámaras y 90 días de campaña, 6.480.000 imágenes

Número de alarmas tipo 2 (permanencia) procesadas

- 5.300 por cámara y día

Número de alarmas tipo 3 (fuego, crecimiento) generadas

- 240 por cámara y día

Número de alarmas tipo 3 gestionadas en la Central

- 1'27 por hora

Número de alarmas tipo 4 (exceso de umbral) generadas

- Ninguna

A partir de enero de 2003 el sistema produjo las siguientes incidencias destacables:

	Desde	Lugar	Comentario	Tipo
6 de Enero a las 14:27 – 14:47 h	Gola 4M: 2,3 y 4	Zona chalets	Detección posible barbacoa	2 y 4
9 Enero a las 14:52h – 15:18	Gola 4F	A 978 m al Norte	Detección de incendio	2, 3 y 4
12 de Enero sobre las 17:31 h	Gola 4M: 3	Zona chalets	Detección posible barbacoa	2 y 4
13 de Enero sobre las 16:47 – 17:45 h	Gola 4M: 3 y 4	Zona chalets	Detección posible barbacoa	2 y 4
14 de Enero sobre las 17:35h	Gola 4M: 3 y 4	Zona chalets	Detección posible barbacoa	2 y 4
27 y 28 Enero a las 13:15	Gola 4M: 5	Viveros (Ver Figura 49).	Detección quema controlada con bidón de gasolina de residuos vegetales	4
20 Febrero a 8h	Gola 10: 4	Mar Este (Ver Figura 50)	Falsa alarma debida al sol	4

Tabla II. Incidencias destacables de DISTER de Enero a Marzo de 2003



Figura 49. Fotos del OnSafe visibles y térmica de la detección del Bidón gasolina con residuos vegetales desde Gola 4M. 27 y 28 de Enero 2003.

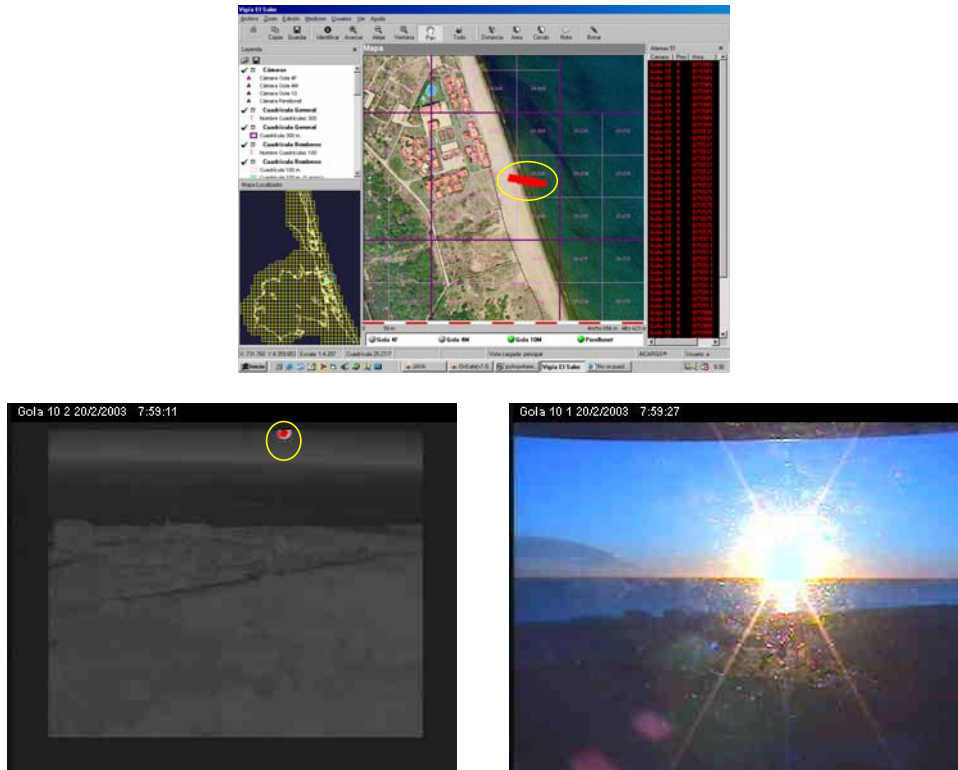


Figura 50. Fotos GIS y OnSafe visibles y térmica de falsa alarma debida al sol en Gola 10. 20 de Febrero 2003.

A partir del 1 de Marzo de 2003, el sistema se puede considerar que está en perfecto funcionamiento y en modo normal de operación, produciéndose las siguientes incidencias destacables:

	Desde	Lugar	Comentario	Tipo
19 de Marzo a las 18:38h	Gola 4M: 4	Zona depuradora	Detección de posible incendio (Ver Figura 51)	2, 3 y 4
28 y 29 de Marzo sobre las 20:22 h		Zona no protegida de El Palmar	Incendio no detectado por estar fuera de cobertura	
1 de Mayo a las 14:31 h	Gola 4M: 2	Zona chalets frente a albufera	Detección de barbacoa (ver Figura 52)	4
12 de Mayo a las 18:00 h	Perellonet	Sobrevolando el campo de golf del Perellonet	Detección de globo aerostático (ver Figura 53)	2 y 3
21 de Mayo a las 9 h	Perellonet	Playa norte de Perellonet	Detección de origen desconocido (ver Figura 54)	2, 3 y 4
24 de Junio a las 00:20 h	Perellonet	Playa norte de Perellonet	Detección de Hogueras de San Juan (ver Figura 55)	4

Tabla III. Incidencias destacables de DISTER de Marzo a Diciembre de 2003


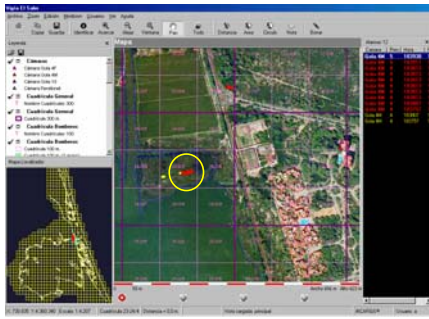


Figura 51. Fotos GIS y Procesadas de detección desconocida en Gola 4M. 19 de Marzo 2003.



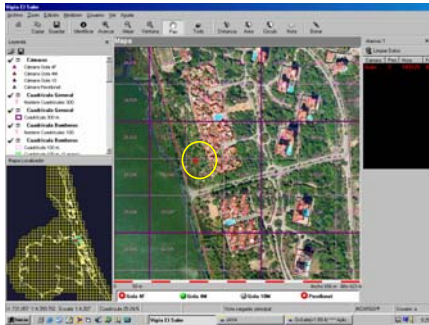


Figura 52. Fotos GIS, Onsafe visible y procesadas de detección de barbacoa en Gola 4M. 1 de Mayo 2003.


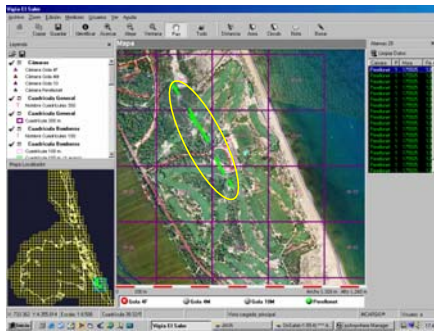


Figura 53. Fotos GIS, Onsafe visible y térmica y procesada de detección de globo aerostático en Perellonet. 12 de Mayo 2003.


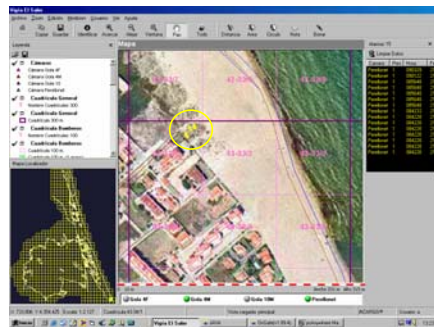


Figura 54. Fotos GIS y procesada de detección desconocida en Perellonet. 21 de Mayo 2003.

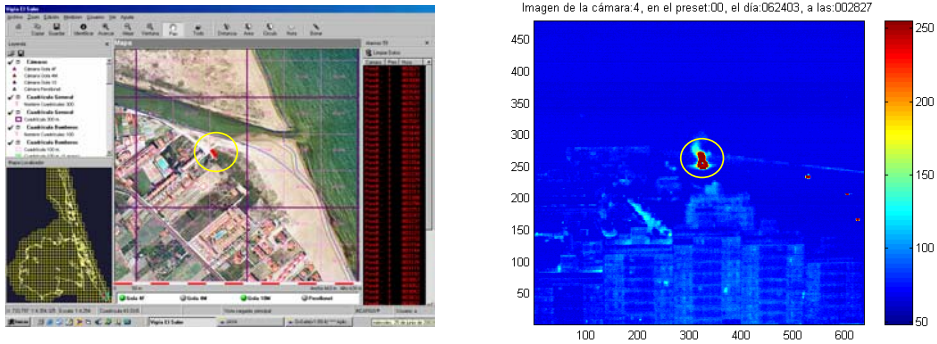


Figura 55. Fotos GIS y procesada de detección hogueras de San Juan en Perellonet. 24 de Junio 2003.

A continuación se muestra un resumen de los resultados del sistema durante este periodo, donde se denomina falsas alarmas a aquellas alarmas de origen desconocido y alarmas indeseadas a aquellas de origen conocido pero que se han podido verificar que no son fuegos reales.

- Número de falsas alarmas: 14
- Número de alarmas indeseadas: 2
- Número de fuegos reales detectados: 4
- Número de fuegos reales no detectados: 0

Una posible estima de la probabilidad de falsa alarma obtenida se puede calcular a partir de la siguiente fórmula:

$$PFA = \frac{\text{Número de falsas alarmas}}{\text{Número total de pixels procesados}} \tag{145}$$

Teniendo en cuenta que las imágenes termográficas tienen una resolución de 320x240 píxeles, y que una imagen se procesa aproximadamente cada 2 segundos, existiendo 4 cámaras en funcionamiento, tenemos:

$$\begin{aligned} \text{Número total de pixels procesados} &= \\ \text{Número total de imágenes procesadas} \times 320 \times 240 &= \\ = \frac{\text{Nº de segundos efectivos por detección}}{2} \times 4 \text{ cámaras} \times 320 \times 240 &= \\ = \frac{\text{Nº total de segundos en un día} \times \text{Nº días} \times (UT_1 + UT_2)}{2} \times 4 \times 320 \times 240 & \end{aligned} \tag{146}$$

Donde UT1 y UT2 son, respectivamente, los porcentajes de utilización del tiempo disponible para cada detección de cada cámara fija y de cada escaneado de las cámaras móviles. En nuestro caso:

- $UT_1 = 110/120$. Ya que en las cámaras fijas se utilizan unos 10 s para el recalibrado cada 120 s entre recalibrados.

- $UT_2 = 45/60$. Ya que en cada barrido de las cámaras móviles se utilizan estos mismos 10 s para cada recalibrado cada 60 s más 5 s para mover la cámara a la siguiente orientación.

Entonces utilizando (145) y (146) podemos estimar la $PFA = 7.2 \times 10^{-12}$ mientras que los detectores de persistencia y el detector de crecimiento se ajustan para tener una probabilidad de falsa alarma final de $PFA = PFA_p \cdot PFA_l = 10^{-13}$.

Consecuentemente, la PFA estimada puede ser considerada como un buen valor sobre todo si se considera que el periodo de tiempo utilizado es demasiado pequeño para realizar estimas del orden de 10^{-13} . Por otro lado, muchas de las supuestas falsas alarmas probablemente pueden ser alarmas indeseadas debidas a efectos ocasionales, que no hemos sido capaces de determinar en vez de debidas al ruido térmico de fondo.

Finalmente, cabe destacar que una alarma de cualquier tipo no siempre requiere la intervención de los cuerpos de bomberos, ya que estos también disponen del sistema de video vigilancia para enfocar la zona donde ha aparecido la alarma y tomar la decisión final.

3.10 Conclusiones

Para finalizar este capítulo 3 vamos a resumir las principales conclusiones a las que hemos llegado tras aplicar la fusión de decisiones a los sistemas de detección de incrementos de temperatura para la detección de incendios forestales. Realizando previamente una síntesis de las tareas realizadas.

3.10.1 Síntesis del capítulo

Como se ha comentado en la introducción, la aplicación aquí considerada se basa en la línea de investigación del grupo que estudia el tratamiento de señales infrarrojas aplicado a la detección automática de incendios forestales, en los que se ha estado trabajando en diversas experiencias piloto como son los proyectos SEDPII, DELFIN y DISTER, y en el proyecto nacional de I+D+I del Ministerio de Ciencia y Tecnología “Aplicación para la adquisición y el procesado de imágenes térmicas para la detección de focos de incendios”, que se basan en la detección precoz y automática de incrementos de temperatura, con cámaras termográficas, para la detección de incendios forestales en grandes extensiones geográficas de terreno.

Las investigaciones se han centrado en los aspectos relativos al tratamiento de las señales captadas por cada uno de los sensores (por lo tanto monosensor) que, en este caso, se trata de cámaras térmicas, sensibles únicamente a los cambios de temperatura de los objetos bajo vigilancia. Incorporando algoritmos avanzados de tratamiento de la señal que permiten la posibilidad de una detección automática para una cierta *PFA* dada, maximizando la *PD* gracias a la incorporación del conocimiento de las características del entorno de trabajo y del tipo de señal a buscar. Introduciendo la posibilidad de discernir entre focos de incendios y otras fuentes de señal no problemáticas, con un diseño adaptado a cada sub-área bajo vigilancia y a cada momento temporal, al introducir el concepto de calibración y preblanqueo.

Se ha descrito brevemente el sistema global desarrollado con las distintas etapas de adquisición, procesado, transmisión y recepción, telecontrol y presentación de la información, haciendo hincapié en la etapa de tratamiento de la señal, que es donde se han incorporado los algoritmos implementados, la cual básicamente es la etapa clave del sistema que permite adquirir las imágenes térmicas, procesarlas y proporcionar una señal simple de ceros y unos, donde se indica si ha habido detección en un píxel concreto de la imagen. Esta información requiere del conocimiento del píxel, no solo del instante actual, sino de instantes pasados y futuros, así como de la evolución temporal de estos píxeles, para poder decidir correctamente si la detección está provocada por un posible foco de incendio o simplemente es una alarma indeseada provocada por un incremento de temperatura puntual.

Por lo tanto, el esquema propuesto consta de unas etapas de predicción y calibración previas a la etapa de detección, ajustado a una cierta PFA y con el conocimiento a priori de la evolución temporal común de un fuego. Cabe destacar que el esquema propuesto surge tras una serie de trabajos o estudios previos desarrollados por el GTS a lo largo del tiempo, entre los que resalta el estudio del predictor lineal, el estudio del detector no lineal basado en la estructura de Wiener, y los detectores basados en el filtro adaptado al subespacio de señal, y el detector de crecimiento [30].

Se generan tres tipos posibles de alarmas en función de si es un simple comparador de energía (tipo 1), si esta energía pertenece al subespacio definido por la matriz de persistencia (tipo 2) o si finalmente, la energía en el subespacio tiene una evolución creciente con el tiempo (tipo 3). Pueden gestionarse de muy distintas formas, y esta cuestión es la que sirve como punto de partida e interés para introducir los algoritmos de fusión de decisiones, utilizando detección distribuida en sistemas monosensor.

Consiguientemente, se han aplicado las técnicas de fusión de decisiones a la detección distribuida en sistemas monosensor, mejorado el esquema inicial previo en dos aspectos fundamentalmente:

- En el caso de la fusión de decisiones aplicada al detector de persistencia, se ha buscado la regla de decisión óptima según el criterio de Neyman-Pearson, asumiendo independencia estadística (**in correladas**), lo cual se puede suponer ya que, aunque estemos trabajando con un único sensor, lo hacemos tomando fragmentos del vector de observaciones no solapados. Se obtienen finalmente las expresiones de la PD_p y la PFA_p en el caso del detector de persistencia, en función de la PD_o y la PFA_o de cada detector y del parámetro nu de exigencia en el número de detecciones. Para ilustrar los resultados obtenidos se obtuvieron una serie de gráficas de las que se puede concluir la obtención de curvas ROC normales con una evolución creciente de la PD al aumentar la PFA , mejorando la PD_p al utilizar la fusión respecto a las PD_o de cada detector individual.
- En el caso de la fusión de decisiones aplicada a la decisión final, se aborda el problema de la fusión de las decisiones fusionadas del detector de persistencia y la decisión del detector de crecimiento, que en general son decisiones **correladas**, ya que utilizan el mismo vector de observaciones para decidir. Se ha buscado la fusión óptima conociendo las reglas de decisión y las correlaciones locales, según el criterio de Neyman-Pearson, obteniendo las razones de verosimilitud y las PD_i y PFA_i globales.

Para verificar los resultados se han realizado una serie de simulaciones prácticas, generando multitud de curvas simuladas, tanto de la PFA_p y PD_p del detector fusionado de persistencia, como de la PFA_i y PD_i , del detector de crecimiento, como finalmente de la PFA_i y PD_i globales. Se han verificado, en todos los casos, el comportamiento teórico con el práctico simulado.

Finalmente, se han comprobado los resultados con experiencias reales de funcionamiento del sistema, concretamente del sistema DISTER, implementado por el departamento en el parque natural de la Albufera, en la localidad de El Saler, en el término municipal de Valencia. Comentándose las experiencias destacables de funcionamiento, tanto de las pruebas con fuegos reales controlados realizadas para verificar el perfecto funcionamiento del sistema, como de los ejemplos de detección reales con intervención por parte del cuerpo de bomberos. Finalizando con una evaluación de los datos reales de funcionamiento del sistema durante un largo periodo de tiempo de actividad continuada, indicando las incidencias más destacables tanto de detección como de posibles falsas alarmas provocadas por fenómenos no previstos.

3.10.2 Conclusiones finales

Sobre los aspectos teóricos

Hemos comprobado que la detección distribuida permite incorporar diferentes tipos de diferencias entre el ruido infrarrojo de fondo y la firma infrarroja que puede generar un incendio descontrolado. Por una parte el comportamiento de persistencia de calor en intervalos cortos (unos pocos segundos) permite separar efectos ocasionales, que en dichos intervalos de observación pueden generar una brusca subida del nivel de señal infrarroja, pero seguida de una brusca bajada. Analizar la persistencia en un número determinado de intervalos cortos, fusionando las correspondientes decisiones lleva a una decisión global de persistencia a medio plazo (5 o 6 intervalos de unos pocos segundos). Por otra parte el incremento de temperatura a medio y largo plazo característico de un fuego descontrolado es explotado mediante un detector de crecimiento. La fusión de ambos detectores lleva al detector final.

De acuerdo con los principios que han dado origen a esta tesis, el diseño óptimo de los detectores de persistencia y de crecimiento es relativamente sencillo y se basa en el uso del filtro adaptado o su variante de filtro adaptado en subespacio. Resulta en particular de interés destacar la forma relativamente simple de incorporar conocimiento genérico sobre la señal a detectar mediante el uso de filtros adaptados en subespacio. “Sintonizando” adecuadamente el subespacio, podemos adaptar esquemas similares al propuesto a otras aplicaciones de vigilancia, como las basadas en detección de movimiento.

En cuanto al ajuste de los detectores hemos desarrollado las ecuaciones requeridas para ajustar la *PFA*, respetando el criterio N-P en todos los pasos, es decir garantizando máxima *PD* final.

Finalmente, en cuanto a la fusión de decisiones correladas, como en principio lo son la de persistencia final y la de crecimiento, hemos verificado que, al tratarse sólo de dos decisiones, las alternativas de fusión sólo afectan a la decisión a adoptar cuando uno de los dos detectores genera un 0 y el otro un 1. Si la regla elegida es decidir un 1, sólo cuando ambos detectores deciden 1, el detector final es óptimo con independencia de la presencia o no de correlación.

Sobre las simulaciones

Hemos verificado con simulaciones las expresiones teóricas calculadas para el control de la *PFA* y la *PD* de las mejoras introducidas al incorporar la fusión de decisiones tanto incorreladas a corto plazo en el detector de persistencia, como correladas con la fusión de decisiones global del detector de persistencia y el detector de crecimiento, generando multitud de curvas simuladas que han demostrado este control al ser capaces de seguir fielmente las curvas teóricas.

Sobre las experiencias con señales reales

Hemos verificado que el comportamiento del sistema de detección de incendios ha sido correcto en los experimentos realizados. Especialmente destacable ha sido la monitorización del sistema durante un largo periodo de tiempo, lo que ha permitido comprobar su fiabilidad en cuanto a detección de fuegos reales, a la par que el control existente sobre las falsas alarmas, cuya tasa se ha aproximado razonablemente a la ajustada a partir de las ecuaciones. Muchas más experiencias se requieren en entornos variados para refinar progresivamente el sistema y hacerlo realmente fiable. En este sentido es ventajoso aprovechar el tener un sistema en funcionamiento, ya que de su propio funcionamiento podemos ir deduciendo las mejoras sucesivas.

CAPÍTULO 4:

Aplicación a sistemas de inspección ultrasónica



Capítulo 4: Aplicación a sistemas de inspección ultrasónica.

4.1 Contexto

Este capítulo se centra en un ámbito de amplio desarrollo en el GTS: ensayos no destructivos mediante ultrasonidos. Entre los diferentes retos que tal ámbito impone al tratamiento de señales, está el de la detección (automática o no automática) de ecos provenientes de reflectores en un fondo de ruido granular. En su versión más simple el ruido granular puede considerarse formado por la superposición de múltiples “pequeños” ecos debidos a la microestructura no homogénea de los materiales bajo análisis. La presencia de ruido granular se produce cuando la longitud de onda es sólo algunas veces mayor que el tamaño medio de grano, por lo tanto a mayor frecuencia, mayores niveles de ruido granular cabe esperar. Reducir la frecuencia, para reducir dicho ruido no es factible si a su vez los reflectores buscados son pequeños, ya que perdemos resolución.

El GTS ha abordado diferentes problemas de detección de ecos ultrasónicos en presencia de ruido granular. De especial interés es la línea de investigación aplicada a la restauración de edificios históricos. Un problema concreto es la determinación del estado de los interfaces entre capas internas de paredes y cúpulas.

Una posibilidad es utilizar la técnica ultrasónica pulso-eco, para “perfilar” las capas. Esta aplicación será considerada al final de este capítulo. Esta línea ha sido financiada por la propia UPV, en su programa de proyectos interdisciplinares, y se ha trabajado en colaboración con el Departamento de Restauración y Conservación de Bienes Culturales y el Instituto de Restauración del Patrimonio, ambos de la UPV.

4.2 Introducción

La detección de ecos ultrasónicos sobre ruido de grano es un problema clásico en el área de los ensayos no destructivos de materiales. El modelo simple de ruido de grano considera la existencia de muchos ecos aleatorios debidos a la compleja micro estructura de los materiales.

Bajo condiciones normales, el hecho de que los ecos producidos por el ruido de grano tengan una distribución aleatoria implica un modelo para la superposición de ecos típico de un proceso estocástico no estacionario con una distribución de probabilidad de tipo gaussiana [42] o no gaussiana [43], [44].

Esta no estacionariedad es debida principalmente a la dependencia de la atenuación con la frecuencia [42], [45], mientras que la gaussianidad o no gaussianidad dependen del número efectivo de fuentes de ecos (dispersores) que contribuyen a la señal registrada en un momento determinado [43], o a la posible presencia de irregularidades en la distribución espacial de las fuentes de ecos [44].

Para ser más específicos vamos a plantear el problema en los siguientes términos. Queremos determinar la presencia de un posible eco de un pulso ultrasónico $p(n)$ en un segmento de la señal ultrasónica y muestreada $r(n)$. Por lo que tenemos dos posibles hipótesis de partida:

$$\begin{aligned} H_0 \quad r(n) &= p(n) + g_0(n) \\ H_1 \quad r(n) &= g_1(n) \end{aligned} \quad \begin{array}{l} n = n_s, \dots, n_s + N - 1 \end{array} \quad (147)$$

Donde $n_s, n_s + N - 1$ son respectivamente las muestras inicial y final que delimitan el segmento, de forma que N es la longitud del segmento, y $g_i(n)$ corresponde con las muestras de ruido de grano bajo la hipótesis i (teniendo en cuenta que en general la presencia del reflector produciendo el eco $p(n)$ puede reducir la varianza del ruido de grano).

Determinar la presencia de $p(n)$ implica realizar cierto proceso $f[\cdot]$ sobre el segmento de la siguiente forma:

$$z(n_s) = f[\mathbf{r}], \quad \mathbf{r} = [r(n_s) \dots r(n_s + N - 1)]^T \quad (148)$$

Finalmente, si vamos desplazando el valor n_s a lo largo de la señal registrada iremos obteniendo la secuencia $z(n_s)$, la cual es la secuencia de salida que se obtiene tras el procesado de la secuencia de entrada $r(n)$.

Dependiendo de la aplicación podemos requerir la detección de la presencia de $p(n)$ de una manera no automática (por ejemplo por inspección visual de las salidas procesadas $z(n_s)$), pero habitualmente, requeriremos una detección automática.

En el primer caso, el objetivo más usual es maximizar el factor de mejora de la relación señal a ruido "signal to noise ratio enhancement" ($SNRE$) que se define de la siguiente forma:

$$SNRE = \frac{SNR_{out}}{SNR_{in}} \quad SNR_{out} = \frac{E[z(n_s)/H_0]}{E[z(n_s)]^2/H_1} \quad SNR_{in} = \frac{E[r(n_s)/H_0]}{E[r(n_s)]^2/H_1} \quad (149)$$

Donde $E[\cdot]$ significa valor medio.

En el segundo caso la salida $z(n_s)$ se compara con un umbral t para tomar una decisión muestra a muestra entre las dos hipótesis de la ecuación (147)

$$\begin{cases} \text{Si } z(n_s) > t & \text{decide } H_0 \\ \text{Si } z(n_s) < t & \text{decide } H_1 \end{cases} \quad (150)$$

Maximizar la probabilidad de detección (PD) para una probabilidad de falsa alarma dada (PFA), o minimizar la probabilidad de error (PE) precisa una adecuada selección de la función de procesado $f[\cdot]$, la cual no es necesariamente la misma que maximiza $SNRE$. Ambas opciones se pueden unificar actuando sobre la secuencia de entrada para generar una nueva secuencia de salida $r_{out}(n_s)$, en la forma:

$$r_{out}(n_s) = \begin{cases} r(n_s) & \text{si } z(n_s) > t \\ 0 & \text{si } z(n_s) < t \end{cases} \quad (151)$$

Este proceso lo podemos describir gráficamente con el diagrama de bloques de la Figura 56, para cada n_s .




Figura 56. Esquema de detección automática básica

Puede comprobarse fácilmente (ver por ejemplo [50], página 111) que $SNRE$ correspondiente a $r_{out}(n_s)$ cuando se compara con $r(n_s)$ queda de la siguiente forma:

$$SNRE = \frac{\frac{E[r_{out}(n_s)/H_0]}{E[r_{out}(n_s)]^2/H_1}}{\frac{E[r(n_s)/H_0]}{E[r(n_s)]^2/H_1}} = \frac{PD}{PFA^{0.5}} \quad (152)$$

Por lo tanto si (150) implementa un detector de Neyman-Pearson (maximizando la PD para una PFA dada), podemos maximizar $SNRE$ para todos los posibles posprocesados del tipo dado en la ecuación (151).

El problema básico a resolver es el diseño óptimo de la función de procesado $f[\cdot]$. Diseño que dependerá del conocimiento a priori que podamos asumir sobre el eco del pulso ultrasónico y sobre el ruido de grano. La situación clásica, ya trabajada principalmente en [50], es aquella dónde se asume:

- Un perfecto conocimiento del pulso buscado $\mathbf{p} = [p(n_s) \dots p(n_s + N - 1)]^T$
- Tanto $\{g_0(n)\}$ como $\{g_1(n)\}$ son localmente estacionarios, de media cero y gaussianos dentro de un cierto intervalo $[n_s, n_s + N - 1]$ y poseen el mismo (conocido) espectro de potencia $S_g(\omega)$.

Entonces la solución óptima es el detector de filtro adaptado [51]¹ dado por la expresión:

$$z(n_s) = f(\mathbf{r}) = \mathbf{r}^T \mathbf{C}_g^{-1} \mathbf{p} \quad (153)$$

Donde \mathbf{C}_g es la matriz de covarianza del ruido de grano correspondiente al espectro de potencia $S_g(\omega)$, donde $R_{gg}(m) = E[g(n)g(n+m)]$.

$$\mathbf{C}_g = E[\mathbf{g}\mathbf{g}^T] = \begin{bmatrix} R_{gg}(0) & R_{gg}(1) & \cdots & R_{gg}(N-1) \\ R_{gg}(1) & R_{gg}(0) & \cdots & R_{gg}(N-2) \\ \vdots & \vdots & \ddots & \vdots \\ R_{gg}(N-1) & R_{gg}(N-2) & \cdots & R_{gg}(0) \end{bmatrix} \quad (154)$$

Bajo H_1 , $z(n_s)$ es una variable aleatoria gaussiana de media nula, por lo que ajustar la PFA es muy sencillo.

Sin embargo, en muchas aplicaciones prácticas de los ensayos no destructivos de materiales con ultrasonidos, las hipótesis asumidas para que la ecuación (153) aunque sean óptimas, están lejos de poder cumplirse. Esto es porque:

- El vector \mathbf{p} es una versión distorsionada, debido a los efectos de la propagación, y a la propia reflexión en el posible eco del pulso original enviado al material. Por lo tanto no se puede asumir, en general, un conocimiento (o una posible estima) del vector \mathbf{p} .
- Por otro lado el espectro del ruido de grano $S_g(\omega)$ (y la matriz de covarianza \mathbf{C}_g) dependen en general de la profundidad [45], y pueden ser estimadas, hasta cierto punto, si se dispone de probetas del material de trabajo. Sin embargo la presencia de reflectores implica variaciones en la vecindad de éstos, lo que reduce el número de dispersores, por lo que $\{g_2(n)\}$ puede tener una menor varianza que $\{g_1(n)\}$.
- Finalmente, la hipótesis de gaussianidad no tiene por qué ser una hipótesis correcta si estamos trabajando con materiales con grano grueso [43], si trabajamos con materiales con una distribución regular de los dispersores [44].

Los algoritmos de split-spectrum (SSP) ofrecen una alternativa práctica a los detectores de filtro adaptado para los casos donde las hipótesis mencionadas fallan (ver Figura 57). Básicamente estos algoritmos aprovechan las diferentes sensibilidades del ruido de grano a distintas frecuencias, cuando se filtra con filtros paso banda a lo largo del ancho de banda del ruido de grano. Se asume por otra

¹ Nosotros vamos a asumir que no existen múltiples ecos dentro del intervalo $[n_s, n_s+N-1]$ este problema es abordado por ejemplo en [46], [47] y [48]. Evitamos esta posibilidad seleccionando un valor para N pequeño, aproximadamente igual a la duración del pulso. Con valores tan pequeños de N , otras técnicas basadas en implementaciones indirectas del filtro óptimo de Wiener [49] no son factibles.

parte que la presencia de un eco aislado \mathbf{p} debido a un reflector dado no es tan sensible a la sintonización frecuencial, obteniéndose una amplitud razonablemente constante en cada una de las salidas de los filtros.




Figura 57. Esquema básico de los algoritmos de split-spectrum

Utilizando la notación anterior y asumiendo que utilizamos L filtros paso banda, la expresión general para el procesamiento de SSP queda de la siguiente forma:

$$z(n_s) = f(\mathbf{r}) = f_{nl}(\mathbf{H}\mathbf{r}) = f_{nl}(\mathbf{v}), \quad (155)$$

Donde las filas \mathbf{h}_i , $i=1\dots N$ de la matriz \mathbf{H} ($L \times N$) se corresponden con las respuestas al impulso (de duración N) de los filtros paso banda (donde los L elementos de \mathbf{v} son las salidas de los L filtros paso banda), y $f_{nl}(\cdot)$ es una función no lineal cuyas alternativas típicas son:

- $z(n_s) = f_{nl}(\mathbf{v}) = \min_i |v_i|$, algoritmo de minimización [52], [53], [54], [55], [56].
- $z(n_s) = f_{nl}(\mathbf{v}) = \text{orden del estadístico}(v_i)$, algoritmo de estadísticos ordenados [54], [57].
- $z(n_s) = f_{nl}(\mathbf{v}) = \text{número de valores positivos en el vector } \mathbf{v}$, “polarity thresholding” [50], [53], [56], [58], [59].

Los algoritmos de SSP basados en la ecuación (155) pueden producir mejoras significativas en PD y en $SNRE$, tal y como se definió en la ecuación (152), cuando se comparan con el simple umbralizado de las muestras originales. Además no requieren el conocimiento de \mathbf{p} o de $S_g(\omega)$.

Sin embargo, encontrar el umbral t adecuado en la ecuación (150), requiere el conocimiento de la función de densidad de probabilidad (pdf) de $z(n_s)$, la cual depende de la pdf conjunta de los elementos de \mathbf{v} bajo la hipótesis H_1 . Por otro lado, la PD a conseguir dependerá de la pdf conjunta de los elementos de \mathbf{v} bajo la hipótesis H_0 .

Los análisis realizados de la relación PD - PFA para los algoritmos SSP [52], [58] y [59] asumen una distribución gaussiana incorrelada y multivariable bajo ambas hipótesis, de forma que.

$$\begin{aligned} \mathbf{v} &: N(\mathbf{m}, \sigma_{Hg}^2 \mathbf{I}) & H_0 \\ \mathbf{v} &: N(\mathbf{0}, \sigma_{Hg}^2 \mathbf{I}) & H_1 \end{aligned} \quad (156)$$

Donde $\mathbf{m} = [m, \dots, m]^T$ es el vector de medias debidas al asumido desplazamiento m producido en las salidas de cada filtro por la presencia del pulso buscado \mathbf{p} , y σ_{Hg}^2 es la varianza debida a la componente de ruido \mathbf{Hg} en el vector $\mathbf{v} = \mathbf{Hr} = \mathbf{Hp} + \mathbf{Hg}$.

La asunción del modelo de la ecuación (156) para el análisis de la *PD-PFA*, en los algoritmos SSP, implica cierta contradicción. Si el modelo (156) es adecuado, entonces el detector óptimo que maximiza la *PD* es el filtro adaptado a \mathbf{m} descrito por las ecuaciones: $z(n_s) = [1 \dots 1]^T \mathbf{v} = \mathbf{1}^T \mathbf{Hr} = \sum_{i=1}^L \mathbf{h}_i^T \mathbf{r} = r(n_s)$, es decir, debemos simplemente comparar la señal original con un umbral.

Sin embargo, dado que los algoritmos SSP han demostrado su interés en numerosas aplicaciones, deberemos cuestionar el modelo tan simple de la ecuación (156), y ver si, asumiendo un modelo más adecuado, podemos proponer nuevos algoritmos basados en la filosofía SSP, pero solventando algunos de los inconvenientes mencionados. Por ello continuamos en la siguiente sección con el modelo vectorial del ruido de grano.

4.3 Modelo vectorial de ruido de grano

La suposición de gaussianidad de (156), es una hipótesis razonable en muchos casos ya que el teorema central del límite indica que la componente de ruido de grano en $\mathbf{v} = \mathbf{Hr}$ puede ser aproximadamente una gaussiana multivariable, incluso en los casos en que \mathbf{r} puede no ser una gaussiana multivariable. Por otro lado, vamos a ver cómo la incorrelación entre los elementos de \mathbf{v} es una presunción adecuada en la práctica.

Denominaremos $\mathbf{g} = [g(n_s) \dots g(n_s + N - 1)]^T$ a la contribución del ruido de grano en el vector \mathbf{r} . Considerando que \mathbf{g} es un vector de media cero y matriz de covarianza \mathbf{C}_g . De forma que la media y la varianza del vector correspondiente a la salida del filtro serán como se muestra en las siguientes expresiones: (donde el superíndice H indica transposición y conjugación)

$$\begin{aligned} E_{Hg} &= E[\mathbf{Hg}] = \mathbf{HE}[\mathbf{g}] = \mathbf{0} \\ \mathbf{C}_{Hg} &= E[\mathbf{Hgg}^H \mathbf{H}^H] = \mathbf{HE}[\mathbf{gg}^H] \mathbf{H}^H = \mathbf{HC}_g \mathbf{H}^H \end{aligned} \quad (157)$$

Entonces consideraremos a partir de ahora que los filtros paso banda (BPF de la Figura 57) son implementados utilizando la transformada discreta de Fourier (DFT), es decir $\mathbf{H}(x, y) = \frac{1}{N} e^{-j\omega_x(y-1)}$; $\omega_x = \frac{2\pi k}{N}$ $k = k_1 \dots k_L$, $x = 1 \dots L$, e $y = 1 \dots N$.

Donde en este caso $\mathbf{H}\mathbf{H}^H = \mathbf{I}$, y las diferentes componentes del vector $\mathbf{H}\mathbf{g}$ estarán incorreladas cuando el ruido de grano también lo esté ($\mathbf{C}_g = \sigma_g^2 \mathbf{I}$). Pero, en general, puede aparecer en las componentes del vector $\mathbf{H}\mathbf{g}$ cierta correlación, que, en principio, deberá ser tenida en cuenta para un correcto diseño y análisis del algoritmo de split-spectrum. Sin embargo, como veremos a continuación, si utilizamos la DFT se puede seguir asumiendo incorrelación.

Utilizando la DFT como alternativa a los BPF, el esquema de la Figura 57 se convierte en el esquema utilizado de la Figura 58, donde no es necesario hacer la FFT, filtrar y hacer la IFFT, ya que con trabajar directamente con los valores de la DFT es suficiente.




Figura 58. Esquema básico inicial de trabajo

Los desarrollos que vamos a mostrar a continuación se basan en el uso directo del modelo de superposición.

Consideraremos que el vector \mathbf{g} está formado por una superposición de ecos, donde cada eco es una versión atenuada y retrasada del pulso básico $\mathbf{q} = [q(n_s) \dots q(n_s + N - 1)]^T$. Este pulso básico se puede definir como el eco que deberíamos obtener de un reflector ideal localizado a la profundidad $d = \frac{cn_s T}{2}$, donde T es el periodo de muestreo, c es la velocidad de propagación en el material.

Se debe tener en cuenta que \mathbf{p} puede ser en general diferente de \mathbf{q} , ya que un reflector no ideal puede tener su propia función de transferencia, además también se ha de tener en cuenta que el parámetro N es demasiado pequeño como para evitar variaciones significativas del pulso básico a lo largo del intervalo de trabajo, $n_s \dots n_s + N - 1$ debido a los efectos de propagación. Por ejemplo, si la velocidad de propagación es de 3000 m/s, y la frecuencia de muestreo es de 10 MHz, $N=21$ muestras corresponde con un intervalo de profundidad de $\frac{3 \cdot 10^3 \cdot 21 \cdot 10^{-7}}{2} \cong 3 \times 10^{-3} m$, la cual es una distancia pequeña en muchas aplicaciones prácticas de test de materiales. Podemos por lo tanto escribir:

$$\mathbf{g} = \sum_{m=-(N-1)}^{N-1} \alpha_m \mathbf{q}_m \tag{158}$$

Donde $\{\alpha_m\}$ son variables aleatorias independientes e idénticamente distribuidas de media cero, y el elemento i -ésimo de \mathbf{q}_m viene dado por la expresión:

$$\mathbf{q}_m(i) = \begin{cases} \alpha_m(i-m) & \max(1, m+1) \leq i \leq \min(N, N+m) \\ 0 & \text{rest} \end{cases} \quad (159)$$

De forma que la componente de ruido de grano a la salida del filtro paso banda queda de la siguiente forma:

$$\mathbf{H}\mathbf{g} = \sum_{m=-(N-1)}^{N-1} \alpha_m \mathbf{H}\mathbf{q}_m \quad (160)$$

Asumiremos, sin pérdida de generalidad, que el intervalo de análisis está centrado en cero ($n_s = -\frac{N-1}{2}$). Asumiremos también las siguientes hipótesis:

$$\begin{aligned} \mathbf{H}\mathbf{q} &= [1 \dots 1]^T = \mathbf{1} \\ \mathbf{H}\mathbf{q}_m &= \mathbf{D}_m \mathbf{H}\mathbf{q} \quad \mathbf{D}_m = \text{diag}(\mathbf{e}_m) \quad \mathbf{e}_m = [e^{-j\omega_1 m} \dots e^{-j\omega_L m}]^T, \end{aligned} \quad (161)$$

Donde $\omega_1 \dots \omega_L$ son las pulsaciones de sintonía de los filtros paso banda.

La primera hipótesis indica que el pulso básico genera un nivel constante en todas las salidas de los filtros. La segunda hipótesis, implícitamente asume que los filtros paso banda son estrechos, por lo que al retrasar la entrada como se indica en la ecuación (159), se produce un cambio en la fase en la correspondiente pulsación de sintonía ω_i . Entonces:

$$\mathbf{H}\mathbf{g} = \sum_{m=-(N-1)}^{N-1} \alpha_m \mathbf{D}_m \mathbf{1} = \sum_{m=-(N-1)}^{N-1} \alpha_m \mathbf{e}_m \quad (162)$$

Donde la media de $\mathbf{H}\mathbf{g}$ debería ser cero como en (157), si la media de α_m es cero.

$$E[\mathbf{H}\mathbf{g}] = \sum_{m=-(N-1)}^{N-1} E[\alpha_m] \mathbf{e}_m = 0 \quad (163)$$

Y la matriz de covarianza queda:

$$\mathbf{C}_{H\mathbf{g}} = E[\mathbf{H}\mathbf{g}\mathbf{g}^H \mathbf{H}^H] = \sum_{m=-(N-1)}^{N-1} \sum_{l=-(N-1)}^{N-1} E[\alpha_m \cdot \alpha_l] \mathbf{e}_m \mathbf{e}_l^H = \sigma_\alpha^2 \sum_{m=-(N-1)}^{N-1} \mathbf{e}_m \mathbf{e}_m^H = \sigma_\alpha^2 \sum_{m=-(N-1)}^{N-1} \mathbf{M}_m \quad (164)$$

Donde $\sigma_\alpha^2 = E[\alpha^2]$. De forma que la covarianza entre el elemento x y el elemento y del vector de salidas del filtro paso banda \mathbf{Hg} , será la suma de los elementos correspondientes a la fila x y a la columna y en \mathbf{M}_m $m = -(N-1)..(N-1)$:

$$\begin{aligned} \mathbf{C}_{Hg}(x, y) &= \sigma_\alpha^2 \sum_{m=-(N-1)}^{N-1} \mathbf{M}_m(x, y) = \sigma_\alpha^2 \sum_{m=-(N-1)}^{N-1} e^{-j(\omega_x - \omega_y)m} = \\ &= \sigma_\alpha^2 \frac{\text{sen}\left[(\omega_x - \omega_y)\left(\frac{4N-1}{2}\right)\right]}{\text{sen}\frac{\omega_x - \omega_y}{2}} \cong \sigma_\alpha^2 \frac{\text{sen}[(\omega_x - \omega_y)(2N)]}{\text{sen}\frac{\omega_x - \omega_y}{2}} \end{aligned} \quad (165)$$

En particular tenemos que:

$$\text{var}(\mathbf{Hg}) = \mathbf{C}_{Hg}(x, x) = N\sigma_\alpha^2 \quad (166)$$

Y que:

$$\mathbf{C}_{Hg}(x, y) = 0, \quad \text{si } \omega_x - \omega_y = \frac{\pi}{2N}k \text{ para cada entero } k \quad (167)$$

Cuando utilizamos la DFT $\omega_x - \omega_y = \frac{2\pi k_x}{N} - \frac{2\pi k_y}{N} = \frac{\pi}{2N}4(k_x - k_y)$, encontramos la condición (167) y la incorrelación puede ser asumida.

En este análisis no hemos considerado el efecto del enventanado implícito en (159), ya que un enventanado en el dominio temporal implica una convolución en el dominio de la frecuencia, por lo que la transformada de Fourier del pulso básico \mathbf{q} se deberá convolucionar con la transformada de Fourier $\text{sen}\left[\omega\left(N + \frac{1}{2}\right)\right] / \text{sen}\frac{\omega}{2}$ de una ventana rectangular de duración N , la cual tiene un lóbulo principal de anchura $\frac{2\pi}{N+1/2} \cong \frac{2\pi}{N}$. Se introduce por tanto cierta correlación entre frecuencias debidas a los efectos de la convolución, aunque este efecto es sólo significativo para pulsaciones más cercanas que $\frac{2\pi}{N}$. Por lo tanto, la incorrelación puede ser una hipótesis razonable cuando utilizamos la DFT. Por todo esto, a partir de ahora consideraremos que $\mathbf{C}_{Hg} \cong \sigma_{Hg}^2 \mathbf{I}$.

Cuando el pulso \mathbf{p} , debido a un posible reflector, aparece en \mathbf{r} , se obtiene, a la salida del vector del filtro paso banda, la siguiente expresión:

$$\mathbf{v} = \mathbf{Hr} = \mathbf{Hp} + \mathbf{Hg} \quad (168)$$

Si asumimos gaussianidad, \mathbf{v} estará distribuido de la siguiente forma:

$$\mathbf{v} : N(\mathbf{Hp}, \sigma_{Hg}^2 \mathbf{I}) \quad (169)$$

El modelo (169) coincide con el modelo (156) si $\mathbf{H}\mathbf{p}=\mathbf{m}$, Por lo tanto, si las hipótesis de gaussianidad e incorrelación son adecuadas, podemos cuestionarnos qué aspectos no están incluidos en el modelo (156). Obviamente el primero es que no se consideran diferentes formas posibles de $\mathbf{H}\mathbf{p}$. Para un caso genérico, el detector óptimo, que maximiza la PD , será el detector de filtro adaptado.

$$z(n_s) = f(\mathbf{r}) = (\sigma_{Hg}^2)^{-1} \mathbf{r}^T \mathbf{H}^T \mathbf{H} \mathbf{p} \quad (170)$$

que es la misma solución de (153) $z(n_s) = f(\mathbf{r}) = \mathbf{r}^T \mathbf{C}_g^{-1} \mathbf{p}$ donde se ha sustituido la inversa de la matriz de covarianzas \mathbf{C}_g^{-1} por la matriz $(\sigma_{Hg}^2)^{-1} \mathbf{H}^T \mathbf{H}$ (de forma que únicamente deberemos estimar la varianza del ruido de grano a la salida del filtro, en vez de estimar \mathbf{C}_g como antes). Sin embargo, todos los problemas asociados con el conocimiento (o el modelo) de \mathbf{p} , o con los cambios en la varianza del ruido de grano debidos a la presencia de \mathbf{p} , quedan igual, es decir, existen dos aspectos que debilitan el modelo (156):

- El vector de medias desplazadas \mathbf{m} es un modelo demasiado simple para la presencia de un posible pulso.
- Los estadísticos del ruido de grano, en particular la variancia, deberían ser diferentes para cada hipótesis, ya que la presencia de un posible defecto altera la vecindad de él, reduciendo las contribuciones de los granos.

Debido a estos aspectos, se considera en [57] una situación más general donde la presencia de \mathbf{p} produce un cambio en la forma de la distribución de \mathbf{v} que no es un simple cambio como en (156), ya que ahora se analiza la posibilidad de seleccionar un estadístico de cualquier orden (por ejemplo la mediana o el máximo de la magnitud).

La selección de un valor diferente al mínimo es conveniente para evitar “observaciones nulas” debidas al hecho de que uno o más de los filtros estén sintonizados en una banda donde el contenido del espectro del pulso pueda ser nulo. Por otro lado el orden del estadístico óptimo depende mucho de la distribución de \mathbf{v} bajo la hipótesis H_1 (cuando el pulso está presente), el cual no es fácil de estimar en la práctica. De manera similar, el algoritmo “polarity thresholding” no es adecuado para aquellos casos donde un pulso dado \mathbf{p} puede generar cambios de diferente signo en la salida del banco de filtros, lo cual no es muy atípico ya que \mathbf{p} depende mucho del reflector en concreto y puede adquirir diferentes formas.

En todos estos métodos no está implícita la consideración de una posible reducción de la varianza del ruido de grano cuando el pulso está presente. Vamos a proponer, a continuación, una arquitectura general de algoritmos de SSP, basados en la utilización de detectores distribuidos. Mostraremos cómo y en qué sentido, los algoritmos propuestos pueden ser considerados óptimos cuando la varianza del ruido de grano se reduce en presencia del pulso buscado \mathbf{p} y no es posible tener un conocimiento “a priori” de este pulso buscado \mathbf{p} . Además, supondremos como

modelo para \mathbf{p} (y por lo tanto para $\mathbf{H}\mathbf{p}$) que \mathbf{p} tiene toda su energía distribuida a lo largo de todos o muchos (para evitar el problema de la observación nula) de los 1-D subespacios generados por cada fila de \mathbf{H} .

La idea general es implementar un esquema robusto que pueda funcionar bajo diferentes modelos de los efectos que produce la presencia de \mathbf{p} y en el que podamos ajustar fácilmente el nivel de *PFA* deseado. Para hacer esto, vamos a implementar un detector automático a la salida de cada filtro, y posteriormente fusionaremos las decisiones distribuidas, obteniendo una decisión menos dependiente del modelo escogido.

4.4 Algoritmos de split-spectrum basados en detección distribuida

4.4.1 Esquema propuesto

Hemos concluido, tras el análisis anterior, que es conveniente considerar los algoritmos de split-spectrum teniendo en cuenta:

- Las diferentes formas que puede tener el vector $\mathbf{H}\mathbf{p}$, incluyendo el problema de la “observación nula”, donde los valores del vector $\mathbf{H}\mathbf{p}$ pueden ser cero o cercanos a cero.
- La posible reducción de la varianza del ruido de grano gracias a la presencia del eco buscado \mathbf{p} .

Vamos a considerar un modelo diferente al descrito en (156):

$$\begin{aligned} \mathbf{v} &: N(\mathbf{H}\mathbf{p}, \sigma_{Hg1}^2 \mathbf{I}) & H_0 \\ \mathbf{v} &: N(\mathbf{0}, \sigma_{Hg2}^2 \mathbf{I}) & H_1 \end{aligned} \quad \sigma_{Hg1}^2 \ll \sigma_{Hg2}^2 \quad (171)$$

Donde la varianza del ruido de grano se reduce significativamente cuando el pulso está presente.

Este modelo se puede convertir en un modelo en términos de la señal original (ecuación (147)), en la forma:

$$\begin{aligned} \mathbf{r} &: N(\mathbf{p}, \mathbf{C}_{g0}) & H_0 \\ \mathbf{r} &: N(\mathbf{0}, \mathbf{C}_{g1}) & H_1 \end{aligned} \quad \begin{aligned} \mathbf{C}_{g0} &= \sigma_{g0}^2 \mathbf{D}_g \\ \mathbf{C}_{g1} &= \sigma_{g1}^2 \mathbf{D}_g \end{aligned} \quad \sigma_{g0}^2 \ll \sigma_{g1}^2 \quad (172)$$

Donde la \mathbf{D}_g es una matriz normalizada respecto a su diagonal principal a 1, asumiendo, por ejemplo, que el color del ruido de grano es el mismo bajo las dos hipótesis, de forma que la varianza del ruido de grano es lo único que cambia.

El detector óptimo correspondiente al modelo (172) es dependiente del conocimiento que tengamos de \mathbf{p} . Si fuese posible un perfecto conocimiento de \mathbf{p} , el estadístico óptimo (ver Apéndice A) a utilizar en la ecuación (150) quedaría de la siguiente forma.

$$z(n_s) = -(\mathbf{r} - \mathbf{p})^T \mathbf{C}_{g1}^{-1} (\mathbf{r} - \mathbf{p}) = -\left\| \mathbf{C}_{g1}^{-1/2} (\mathbf{r} - \mathbf{p}) \right\|^2 \quad (173)$$

El cual es un simple detector de energía residual, tras la cancelación de la señal y el preblanqueo.

El detector (173) explota el hecho de que bajo la hipótesis H_0 , mucha de la energía es debida a la presencia del pulso \mathbf{p} (ya que $\sigma_{g^0}^2 \ll \sigma_{g^1}^2$).

Cuando no es posible un conocimiento preciso del pulso \mathbf{p} podemos buscar soluciones que exploten ciertas propiedades de \mathbf{p} . Por ejemplo, si asumimos que $\mathbf{C}_{g^1}^{-1/2}\mathbf{p}$ pertenece al subespacio formado por la matriz de proyección \mathbf{P} , podremos estimar $\mathbf{C}_{g^1}^{-1/2}\mathbf{p}$ mediante la proyección del vector de observaciones preblanqueado $\mathbf{C}_{g^1}^{-1/2}\mathbf{r}$ sobre el citado subespacio, por lo que el nuevo estadístico quedaría de la siguiente forma:

$$z(n_s) = -\left\| \mathbf{C}_{g^1}^{-1/2}\mathbf{r} - \mathbf{P}\mathbf{C}_{g^1}^{-1/2}\mathbf{r} \right\|^2 = -\left\| (\mathbf{I} - \mathbf{P})\mathbf{C}_{g^1}^{-1/2}\mathbf{r} \right\|^2 = -\left[\left\| \mathbf{C}_{g^1}^{-1/2}\mathbf{r} \right\|^2 - \left\| \mathbf{P}\mathbf{C}_{g^1}^{-1/2}\mathbf{r} \right\|^2 \right] \quad (174)$$

Básicamente, los algoritmos de split-spectrum asumen, implícitamente, que toda la energía de un pulso ultrasónico aislado (o un pulso con muy poco ruido de grano) se distribuye a lo largo de subespacios 1-D descritos por cada uno de los filtros paso banda de \mathbf{h}_i , por lo que una parte muy importante de la energía total del pulso se encuentra presente en la salida de cada uno de los filtros (o por lo menos en un gran número de ellos). Por lo tanto podemos tomar una decisión en cada salida del filtro utilizando el siguiente estadístico inspirado en (174)

$$z_i(n_s) = -\left[E_i - \left\| \mathbf{P}_i\mathbf{C}_{g^1}^{-1/2}\mathbf{r} \right\|^2 \right] \quad (175)$$

donde $\mathbf{P}_i = \frac{\mathbf{h}_i\mathbf{h}_i^H}{\mathbf{h}_i^H\mathbf{h}_i}$ es la matriz de proyección en el subespacio de 1-D descrito por \mathbf{h}_i ,

y E_i es la porción de energía del vector $\mathbf{C}_{g^1}^{-1/2}\mathbf{r}$, que cae dentro del citado subespacio. El problema con la ecuación (175) es la necesidad del conocimiento de E_i . Este problema puede ser superado si se asume que E_i es una constante (independiente del vector particular \mathbf{r}), por lo que podremos comparar directamente la energía en el subespacio $\left\| \mathbf{P}_i\mathbf{C}_{g^1}^{-1/2}\mathbf{r} \right\|^2 = \mathbf{r}^H \mathbf{C}_{g^1}^{-1/2} \frac{\mathbf{h}_i\mathbf{h}_i^H}{\mathbf{h}_i^H\mathbf{h}_i} \mathbf{C}_{g^1}^{-1/2}\mathbf{r}$ con un umbral.

Utilizando esta última interpretación de los algoritmos de split-spectrum, se propone el esquema de la Figura 59, en el que, en vez de tomar una única decisión como en la ecuación (150), se generan decisiones distribuidas en las salidas de cada filtro paso banda, las cuales se fusionan para tomar la decisión final.

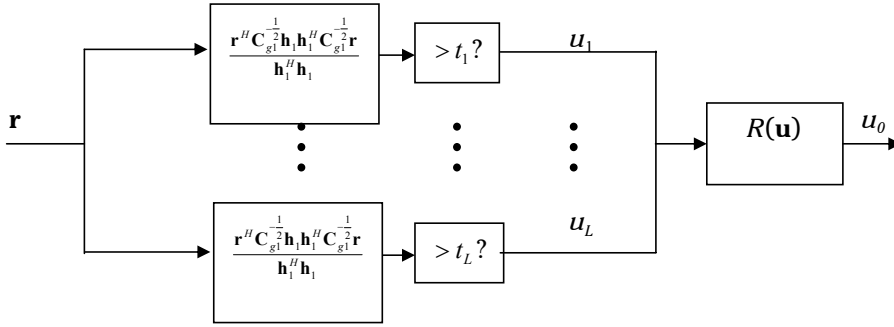


Figura 59. Esquema del algoritmo del split-spectrum basado en detección distribuida (SSDD)

En cada salida del filtro obtenemos una decisión binaria u_i (0 ó 1). A continuación, todas las decisiones distribuidas se fusionan para tomar la decisión final u_0 (0 ó 1), utilizando una regla de fusión óptima $R(u_1 \dots u_L)$ que maximice la *PD* final.

Este procedimiento es el que denominamos algoritmo de split-spectrum basado en la detección distribuida (SSDD) que, siguiendo con la notación utilizada hasta ahora, (ver por ejemplo (151)) queda formulada de la siguiente forma:

$$r_{out}(n_s) = \begin{cases} r(n_s) & \text{si } R(\mathbf{u}) = 1 \\ 0 & \text{si } R(\mathbf{u}) = 0 \end{cases} \quad (176)$$

En el Apéndice B demostraremos como, bajo la hipótesis H_1 , y cuando utilizamos la DFT para implementar los filtros paso banda, la energía en el subespacio sigue una distribución de tipo chi-cuadrado centrado con dos grados de libertad.

$$2 \cdot \frac{\mathbf{r}^H \mathbf{C}_{g1}^{-1/2} \mathbf{h}_i \mathbf{h}_i^H \mathbf{C}_{g1}^{-1/2} \mathbf{r}}{\mathbf{h}_i^H \mathbf{h}_i} : \chi_2^2 \quad (177)$$

Tenemos por tanto un modo fácil de buscar el umbral adecuado t_i en cada salida del filtro para obtener la probabilidad de falsa alarma PFA_i deseada, lo que implica finalmente una forma sencilla para encontrar la probabilidad de falsa alarma final PFA_{final} tras la fusión (ver (186)).

Se ha de tener en cuenta que comparar la energía en el subespacio con el umbral t_i es equivalente al denominado “filtro adaptado al subespacio” (FAS) (ver por ejemplo [51], página 145), que es la solución óptima que maximiza la PD_i para una PFA_i dada, bajo la suposición de que la señal a detectar pertenece al correspondiente subespacio. Esta suposición es la primera restricción que se requiere en el esquema propuesto, es decir, que \mathbf{p} tenga parte de su energía dentro de todos o varios de los subespacios 1-D representados por los vectores \mathbf{h}_i (o lo que es lo mismo que \mathbf{p} tenga parte de su energía dentro de todos o algunos de los anchos de banda de los filtros paso banda).

4.4.2 La regla de decisión

Una vez diseñados los decisores locales, debemos considerar el diseño de la regla de fusión óptima. Tras las discusiones hechas en las secciones anteriores, está claro que bajo la hipótesis H_1 , las componentes del vector de decisión \mathbf{u} están incorreladas. Consideraremos sin embargo que cuando está presente \mathbf{p} en el vector de decisiones \mathbf{u} se introduce cierta correlación sobre las componentes de \mathbf{u} , lo que mediremos con un único parámetro, el coeficiente de correlación ρ entre cada dos componentes de \mathbf{u} , definido como:

$$\rho = \frac{E[u_i u_j / H_0] - E[u_i / H_0] E[u_j / H_0]}{\sqrt{E[(u_i - E[u_i])^2 / H_0] E[(u_j - E[u_j])^2 / H_0]}} \quad \forall i, j \quad (178)$$

La regla de decisión óptima para modelos generales de decisores correlados proviene de [20]. Si llamamos m al parámetro que nos indica el número de ceros que tendrá el vector de decisiones \mathbf{u} , podemos escribir la regla de decisión óptima bajo el criterio de N-P[20] de la siguiente forma:

$$R(\mathbf{u}) = R(m) = \begin{cases} 1, & \text{si } \Lambda(m) \geq \lambda \\ 0, & \text{si } \Lambda(m) < \lambda \end{cases} \quad (179)$$

Donde $\Lambda(m)$ es la razón de verosimilitud.

Entonces considerando el caso particular de decisiones incorreladas bajo la hipótesis H_1 y correladas a pares bajo la hipótesis H_0 , particularizando las expresiones generales dadas en la ecuación (79) de [20], ($\rho^{H_0} = \rho$ y $\rho^{H_1} = 0$) donde se asume que todos los detectores locales están diseñados para tener la misma $PFA_i = PFA \forall i$, y que también tienen la misma $PD_i = PD \forall i$, obtenemos la siguiente expresión:

$$\Lambda(m) = \frac{P(m / H_0)}{P(m / H_1)} = \begin{cases} \frac{\sum_{i=0}^m (-1)^i \binom{m}{i} PD \prod_{k=0}^{L-m+i-2} \frac{\rho(k+1-PD)+PD}{1+k\rho}}{PFA^{L-m} (1-PFA)^m}, & 0 \leq m \leq L-2 \\ \frac{PD + \sum_{i=1}^{L-1} (-1)^i \binom{L-1}{i} PD \prod_{k=0}^{i-1} \frac{\rho(k+1-PD)+PD}{1+k\rho}}{PFA^{L-m} (1-PFA)^m}, & m = L-1 \\ \frac{1-L \cdot PD + \sum_{i=2}^L (-1)^i \binom{L}{i} PD \prod_{k=0}^{i-2} \frac{\rho(k+1-PD)+PD}{1+k\rho}}{PFA^{L-m} (1-PFA)^m}, & m = L \end{cases} \quad (180)$$

Donde el umbral λ ha de ser elegido para satisfacer una PFA , final dada, cuya expresión es (ver ecuación (83) de [20], teniendo en cuenta que hay un error ya que falta el factor $\binom{L}{m}$):

$$PFA_{final}(\lambda) = PFA^L \sum_{m=0}^L R(m) \binom{L}{m} \left(\frac{1-PFA}{PFA} \right)^m \quad (181)$$

Siendo la PD final obtenida (máxima) (ver ecuación (82) de [20], teniendo en cuenta de nuevo el mismo error que en la ecuación anterior, al faltar el factor $\binom{L}{m}$):

$$PD_{final}(\lambda) = PD \sum_{m=0}^L R(m) \binom{L}{m} \sum_{i=0}^m (-1)^i \binom{m}{i} \prod_{k=0}^{L-m+i-2} \frac{\rho(k+1-PD)+PD}{1+k\rho} \quad (182)$$

En principio, la implementación de la regla de decisión (179), requiere el conocimiento de ρ para calcular $\Lambda(m)$ y resolver la ecuación no lineal (181) para buscar el umbral adecuado λ . Sin embargo, si $\Lambda(m)$ es una función no creciente con m , la regla de fusión óptima (179) se puede redefinir de la siguiente forma:

$$R(\mathbf{u}) = R(m) = \begin{cases} 1, & \text{si } m \leq m_0 \\ 0, & \text{si } m > m_0 \end{cases} \quad (183)$$

Donde m_0 es un número entero tal que $\Lambda(m_0) \geq \lambda \geq \Lambda(m_0 + 1)$. Siendo fácilmente demostrable que $\Lambda(m)$ es una función no creciente con m para el caso incorrelado ($\rho = 0$), ya que, utilizando (180) se obtiene la siguiente expresión:

$$\begin{aligned} \Lambda(m)_{\rho=0} &= \frac{\sum_{i=0}^m (-1)^i \binom{m}{i} PD \prod_{k=0}^{L-m+i-2} PD}{PFA^{L-m} (1-PFA)^m} = \frac{PD^{L-m} \sum_{i=0}^m (-1)^i \binom{m}{i} PD^i}{PFA^{L-m} (1-PFA)^m} = \\ &= \frac{PD^{L-m} (1-PD)^m}{PFA^{L-m} (1-PFA)^m} \end{aligned} \quad (184)$$

Que es una función decreciente con m si, como es habitual, $PD > PFA$.

Cuando $\rho = 1$, existe una correlación total bajo la hipótesis H_0 y se obtiene la siguiente expresión:

$$\Lambda(m)_{\rho=1} = \frac{\sum_{i=0}^m (-1)^i \binom{m}{i}}{PFA^{L-m} (1-PFA)^m} = \begin{cases} 1 & \text{si } m=0 \\ PFA^L & \text{si } m \neq 0 \end{cases} \quad (185)$$

La cual es también una función no creciente con m .

En el caso general, cuando $0 < \rho < 1$, no tenemos una demostración analítica, pero se puede verificar implementando directamente (180) que si $PD > PFA$, $\Lambda(m)$ es una función decreciente con m . Por lo que la regla de fusión (183) implementa un test uniformemente más potente [51] sobre el parámetro ρ . De forma que cada umbral m_0 corresponde con la PFA_{final} dada (de (181))

$$PFA_{final}(m_0) = PFA^L \sum_{m=0}^{m_0} \binom{L}{m} \left(\frac{1-PFA}{PFA} \right)^m \quad (186)$$

Y la PD_{final} obtenida (máxima) será (de (182)):

$$PD_{final}(m_0) = PD \sum_{m=0}^{m_0} \binom{L}{m} \sum_{i=0}^m (-1)^i \binom{m}{i} \prod_{k=0}^{L-m+i-2} \frac{\rho(k+1-PD)+PD}{1+k\rho} \quad (187)$$

A partir de las dos ecuaciones anteriores (186) y (187), se pueden obtener una serie de curvas para evaluar la influencia de los diferentes parámetros involucrados en la $PFA_{final}(L, m_0, PFA)$ y en la $PD_{final}(L, m_0, PD, \rho)$. Nosotros hemos seleccionado tres tipos de curvas que se muestran a continuación en la Figura 60, Figura 61 y Figura 62, las cuales consideramos significativas desde el punto de vista de enfatizar los efectos de la fusión de decisiones en el algoritmo *SSDD*.

En la Figura 60 representamos la PFA_{final} en función del parámetro m_0 , que indica el máximo número de detectores individuales a favor de la hipótesis H_1 para tomar una decisión final apoyando la hipótesis H_0 , es decir el número de detectores que podemos no tener en cuenta en la decisión final o el número de ceros permitidos para tomar la decisión correcta, para un número total de filtros $L=20$, y para diferentes valores de la probabilidad de falsa alarma individual $PFA \leq 0.5$.




Figura 60. PFA_f en función del parámetro m_0 (máximo número de ceros permitidos para decidir H_0) para diferentes valores de PFA en cada detector individual.

Como cabía esperar, la PFA_{final} tiene un comportamiento monótonamente creciente al aumentar el parámetro m_0 (para cada PFA individual, de cada detector) y el mismo comportamiento con la PFA (dado un m_0 concreto). Podemos remarcar que es posible obtener valores muy pequeños de PFA_{final} incluso para una PFA individual grande, simplemente eligiendo adecuadamente el parámetro m_0 (reduciéndolo), de forma que al permitir una gran PFA , por ejemplo, tomando un valor pequeño para el umbral de la salida de cada filtro $t_i \equiv t$, garantizamos un valor alto de probabilidad de detección individual en cada detector PD , sin perjuicio de obtener una PFA_{final} suficientemente pequeña.

En la Figura 61 representamos la dependencia de la PD_{final} con el coeficiente de correlación ρ cuando $m_0 = 10$ y $L = 20$, para diferentes valores de $PD \geq 0.5$ individuales de cada detector.




Figura 61. PD_f en función de ρ para diferentes valores de PD en cada detector. Con $L=20$ y $m_0=10$.

Observamos como, para una PD dada, la máxima PD_{final} se obtiene para el caso incorrelado $\rho = 0$, decreciendo monótonamente en función de la PD : obviamente $PD_{final} = PD$ en el caso de máxima correlación $\rho = 1$, debido a que los L detectores trabajan, en este caso, como si fuesen un único detector.

Otra conclusión interesante que podemos destacar, del estudio de las curvas obtenidas, es que la PD_{final} nunca es menor que la PD individualizada de cada detector si se cumple que $PD \geq 0.5$, lo cual implica que, cuando los detectores individuales satisfacen la condición de tener una $PFA \leq 0.5$ y una $PD \geq 0.5$ (una restricción asumible en la mayoría de los casos), la fusión de decisiones generará valores pequeños de PFA_{final} , dejando los valores de PD_{final} a unos niveles razonables, simplemente eligiendo adecuadamente el parámetro m_0 .

Este hecho se puede observar mejor en la Figura 62, donde se muestran diferentes curvas de características operativas del receptor (curvas ROC) para diferentes valores de $PD \geq 0.5$, dejando constantes los parámetros $L=20$, $\rho = 0.5$, y $PFA = 0.3$ (un valor sensiblemente alto). Donde cada punto en cada curva representada en la Figura 62 se ha obtenido variando el parámetro m_0 y obteniendo la correspondiente $PD_{final}(m_0)$ y $PFA_{final}(m_0)$.




Figura 62. Curvas ROC

Respecto a la existencia de otro tipo de algoritmos de split-spectrum, el esquema propuesto presenta diversas novedades.

- La inclusión del filtro de preblanqueo, el cual es un requisito para optimizar los detectores individuales, y por lo tanto para tener la posibilidad de elegir una PFA deseada, maximizando, la PD . A su vez, este preblanqueo introduce dos efectos simultáneos:
 - La normalización de la varianza del ruido de grano.
 - La expansión de la potencia media del ruido de grano a lo largo de todo el ancho de banda, lo que también modifica la distribución de la energía del pulso buscado a lo largo del ancho de banda.
- La introducción de la detección distribuida, que permite, de una forma sencilla, la obtención de la deseada PFA_{final} , y que, por otro lado, no requiere un especial conocimiento del pulso buscado.

En este sentido, el algoritmo propuesto $SSDD$ funciona correctamente con una gran variedad de pulsos, sin restricciones en función de la polaridad (como en el caso de los algoritmos de “polarity thresholding”) u otro tipo de condiciones limitantes, excepto la condición de que debe tener suficiente energía en al menos m_0 de los 1-D subespacios descritos por cada \mathbf{h}_i .

Finalmente se ha de tener en cuenta que el algoritmo $SSDD$ puede ser considerado como un algoritmo de minimización (si $m_0=0$) o un algoritmo de estadístico de orden (para un valor de $0 \leq m_0 \leq L-1$ arbitrario) incluyendo el preblanqueo y la detección automática.

4.4.3 Compitiendo con el detector trivial.

El esquema propuesto tiene como ventajas, si lo comparamos con la solución óptima del filtro adaptado (153), que no requiere el conocimiento del pulso \mathbf{p} y que explota el hecho práctico de que $\sigma_{g0}^2 \ll \sigma_{g1}^2$, como hemos visto en el apartado anterior. Sin embargo, bajo ciertas condiciones especiales, la solución del filtro adaptado nos lleva a una solución sencilla que denominaremos detector trivial. El detector trivial se corresponde con el caso especial en el que $S_g(\omega) \propto |P(\omega)|^2$, es decir, cuando la densidad espectral de potencia del ruido de grano es proporcional a la densidad espectral de energía del pulso buscado (un caso similar se puede ver en [50], página 117, donde $S_g(\omega) \propto |P(\omega)|$ y se utiliza el filtro adaptado con cada una de las muestras de la señal original, sin preblanquear). Expresaremos $\mathbf{p} = A \cdot \mathbf{s}$, donde la restricción espectral $S_g(\omega) \propto |P(\omega)|^2$ implica que $\mathbf{C}_{g1}^{-1/2} \mathbf{s} = [1 \ 0 \dots 0]^T$. De forma que, como el detector de filtro adaptado es un test uniformemente más potente respecto al parámetro A , podremos escribir el correspondiente estadístico de la siguiente forma:

$$z(n_s) = |\mathbf{r}^T \mathbf{C}_g^{-1} \mathbf{s}| = \left| \mathbf{r}^T \mathbf{C}_g^{-1/2} \mathbf{C}_g^{-1/2} \mathbf{s} \right| = |r_w(n_s)| \tag{188}$$

Donde consideraremos, la magnitud del estadístico, para permitir la detección de $\mathbf{p} = A \cdot \mathbf{s}$, para $A > 0$ y $A < 0$. Entonces, la ecuación (188) indica que, en este caso, el estadístico con el que comparar el umbral serán las propias muestras (magnitud) de la secuencia original preblanqueada, y por esto la llamaremos detector trivial.

Consideremos ahora el caso en el que, bajo la hipótesis H_0 , $\sigma_{g0}^2 \cong 0$, es decir, que $\mathbf{r} \cong \mathbf{p}$, entonces, los correspondientes estadísticos tanto para el detector trivial como para el *SSDD* (utilizando la DFT para implementar los filtros) bajo la hipótesis H_0 serán:

$$\begin{aligned} \text{Detector Trivial} \quad z(n_s) &= |\mathbf{p}^T \mathbf{C}_g^{-1} \mathbf{s}| = \left| A \mathbf{s}^T \mathbf{C}_g^{-1/2} \mathbf{C}_g^{-1/2} \mathbf{s} \right| = |A| \\ \text{SSDD} \quad z_i(n_s) &= \frac{A \mathbf{s}^T \mathbf{C}_{g1}^{-1/2} \mathbf{h}_i \mathbf{h}_i^H \mathbf{C}_{g1}^{-1/2} A \mathbf{s}^T}{\mathbf{h}_i^H \mathbf{h}_i} = \frac{A^2}{N} \quad \forall i \end{aligned} \tag{189}$$

Si nos fijamos ahora en la Figura 63, podremos observar la $PFA_{trivial}$, correspondiente al detector trivial, asumiendo que el umbral es el parámetro $|A|$ entre 0 y 4 es decir ajusteremos el umbral máximo para que haya detección. Además dibujamos en la Figura 63 la PFA_{final} correspondiente al algoritmo *SSDD*, asumiendo que el umbral en cada salida de cada filtro está fijado en el valor A^2/N como indica la ecuación (189) (umbral de detectabilidad), y que los N posibles detectores correspondientes a los N valores de la DFT son fusionados para obtener la decisión final (utilizando en este caso $N=L$).




Figura 63. Comparación con detector trivial. -- SSDD — trivial

Se puede verificar, tras observar la Figura 63, como la PFA_{final} es independiente del número de detectores N utilizados. Por otro lado, se comprueba cómo para valores de falsa alarma por debajo de 0.2, el algoritmo *SSDD*, tiene un mejor comportamiento que el detector trivial. Teniendo en cuenta que ésta es la situación “más favorable” para el detector trivial (sería el detector óptimo si $\sigma_{g0}^2 = \sigma_{g1}^2$), y el caso “menos favorable” para el detector *SSDD*, ya que el preblanqueo extiende la energía del pulso a lo largo de todo el ancho de banda.

Sin embargo, la Figura 63 también nos indica que el nivel del pulso buscado debe ser lo suficientemente grande como para obtener unos valores razonablemente pequeños de PFA_{final} . El problema en este caso, con el algoritmo *SSDD*, es que el asumido “perfecto” preblanqueo, ensancha la energía del pulso a lo largo de los N canales de los filtros, lo que implica la necesidad de elegir un umbral suficientemente pequeño (menor que A^2/N), para ser capaces de detectar el pulso en la salida de cada filtro, lo cual genera una gran PFA en la salida de cada filtro, que aunque finalmente realicemos la fusión de las N decisiones, no permite obtener el deseado bajo nivel de PFA_{final} . En otras palabras, el algoritmo *SSDD* asume que, la presencia del pulso, inyecta suficiente energía, en cada uno de los subespacios, pero es necesario un mínimo de energía en cada subespacio, para garantizar la detección, sin tener unos valores de PFA_{final} demasiado grandes.

Todo esto sugiere la conveniencia de algún tipo de normalización en el algoritmo inicial *SSDD* para poder realizar la detección, con la única dependencia de la distribución de la energía del pulso en el subespacio, y no tanto del nivel de esta energía del pulso en los citados subespacios. Entonces llegamos al segundo algoritmo implementado, el *SSDD* normalizado o *NSSDD*, donde cada valor de energía de la salida de cada filtro se divide por el máximo de los valores, es decir:

$$z_i(n_s) = \frac{\mathbf{r}^T \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{h}_i \mathbf{h}_i^H \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{r}^T}{\max_j \mathbf{r}^T \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{h}_j \mathbf{h}_j^H \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{r}^T} \quad (190)$$

En el apéndice C se demuestra como, para un valor de L (número de filtros) grande, la PFA en cada salida de cada filtro se puede obtener con la siguiente expresión:

$$PFA(t_i) = L \cdot \sum_{k=0}^{L-1} (-1)^k \binom{L-1}{k} (t_i + 1 + k)^{-1} \quad (191)$$

Donde t_i es el correspondiente umbral a comparar con $z_i(n_s)$.

Utilizando esta ecuación (191) y la ecuación (186) se han generado las curvas que se muestran en la Figura 64, correspondientes a la PFA_{final} en función del umbral t_i para diferentes valores de m_0 y $L=20$.




Figura 64. PFA_{final} con normalización, para diferentes valores de $m_0=0,2,5,10$, y $L=20$

Considerando, de nuevo, el caso ideal de la ecuación (189) tenemos que bajo la hipótesis H_0

$$NSSDD \quad z_i(n_s) = \frac{\frac{A^2}{N}}{\frac{A^2}{N}} = 1 \quad \forall i \quad (192)$$

Por lo que la detección del pulso se garantiza siempre que el umbral $t_i < 1$, independientemente del nivel del pulso buscado A .

Por otro lado, si se comparan la Figura 63 y la Figura 64, se puede observar la mejora sustancial del algoritmo *NSSDD* respecto al detector trivial y el *SSDD*.

4.5 Experimentos con señales simuladas

A continuación vamos a aplicar los algoritmos propuestos anteriormente, utilizando para ello, inicialmente, señales simuladas para verificar el comportamiento y control de la PFA y la PD para, posteriormente, pasar a probar los algoritmos con una serie de señales reales utilizando para ello muestras de señales ultrasónicas, obtenidas en dos experiencias distintas.

4.5.1 Control de la PFA

Inicialmente vamos a verificar el comportamiento de nuestros algoritmos, tanto el SSDD como NSSDD, comprobando que somos capaces de realizar un control exhaustivo de la PFA, verificando de esta manera la expresión teórica obtenida en la ecuación (186), mediante una serie de simulaciones prácticas.

Para ello, lo primero que vamos a hacer es simular el pulso buscado mediante una función sinc (Figura 65) de amplitud $A=0.5$ y ancho de banda $W=2 \cdot \pi \cdot 0.2$, modulada por un seno de frecuencia digital $fd=0.3$, de 50 muestras, cuyo espectro $P(f)$ es un rectángulo centrado en fd de ancho de banda W .

$$p = A \cdot \text{sinc}(W \cdot n) \cdot \sin(2 \cdot \pi \cdot fd \cdot n) \tag{193}$$




Figura 65. Gráficas de la función sinc recortada, utilizada para simular el pulso buscado, tanto en el tiempo como en la frecuencia.

A continuación utilizamos este pulso simulado p para calcular la matriz de autocorrelaciones C_{g1} , que posteriormente utilizaremos para realizar el preblanqueo, asumiendo el caso de perfecta coherencia entre ruido de grano y señal $S_g(w) \propto |P(w)|^2$

$$\mathbf{C}_{g1} = \begin{bmatrix} R_{pp}(0) & R_{pp}(1) & \cdots & R_{pp}(nm) \\ R_{pp}(1) & R_{pp}(0) & \cdots & R_{pp}(nm-1) \\ \vdots & \vdots & \cdots & \vdots \\ R_{pp}(nm) & R_{pp}(nm-1) & \cdots & R_{pp}(0) \end{bmatrix} \quad (194)$$

Siendo nm el número de muestras a utilizar en el enventanado y por lo tanto, el número de puntos con los que calcular la DFT.

Este parámetro es bastante crítico ya que nos da una idea del tamaño mínimo del pulso buscado a utilizar y nos condiciona el número de detectores a usar L , ya que este parámetro se obtiene como:

$$L = (fd + W/2) \cdot nm + 1 - (fd - W/2) \cdot nm + 1 = W \cdot nm \quad (195)$$

A continuación obtenemos a partir de la PFA deseada en cada detector parcial, el umbral con el que compararemos cada una de las salidas de los detectores, utilizando para ello en el SSDD una distribución de tipo chi-cuadrado de 2 grados de libertad y en el NSSDD la ecuación (191) demostrada en el Apéndice C.

Generaremos entonces un ruido blanco gaussiano \mathbf{w} que haremos pasar por un filtro cuya respuesta al impulso $h[n]$ sea el propio pulso buscado simulado calculado anteriormente \mathbf{p} , de forma que generemos un ruido coloreado \mathbf{rc} por el pulso buscado el cual normalizaremos en varianza obteniendo el ruido simulado de grano \mathbf{rc}_w .

$$\mathbf{rc} = conv(\mathbf{w}, \mathbf{p}) \rightarrow \mathbf{rc}_w = \frac{\mathbf{rc}}{\sqrt{\sum_i p_i^2}} \quad (196)$$

Para finalmente utilizar múltiples realizaciones de este ruido de grano simulado \mathbf{rc}_w , para evaluar los algoritmos SSDD o NSSDD y obtener las curvas de la Figura 66 y la Figura 67. Para ello tomaremos los N puntos de este ruido de grano simulado \mathbf{rc}_w , lo enventanaremos con ventanas de tamaño nm y solape del 99% (es decir que solo cambiará una muestra entre ventana y ventana) obteniendo los vectores \mathbf{r} , de tamaño nm .

A continuación cada uno de estos vectores \mathbf{r} los pasaremos por el filtro de preblanqueo, obteniendo \mathbf{rb} .

$$\mathbf{rb} = \mathbf{C}_{g2}^{-1/2} \mathbf{r} \quad (197)$$

calculando entonces la DFT módulo al cuadrado \mathbf{z}' utilizando para ello la FFT de tamaño $TamFFT=nm$.

$$\mathbf{z}' = \left| \left(\text{fft}(\mathbf{rb}) \right)^2 \right| \quad (198)$$

y recortando la salida de la FFT, primero quedándonos con la parte positiva, y posteriormente buscando las muestras que corresponden con el intervalo frecuencial buscado. Obtenemos así el vector \mathbf{z}'' , que tiene un tamaño igual a L , número de detectores a utilizar en la fusión de decisiones posterior. Finalmente normalizamos por el número de puntos de la FFT $TamFFT=nm$ y por un factor de 2, para ajustarnos a lo indicado en la ecuación (177)

$$\mathbf{z} = \frac{2 \cdot \mathbf{z}''}{TamFFT} \tag{199}$$

En el caso del *NSSDD*, en este momento introducimos la normalización, dividiendo el vector de \mathbf{z} , por el valor máximo de este mismo vector, sobre el que se toman las decisiones.

Ahora ya podemos pasar el vector obtenido por la fusión de decisiones, es decir, por cada uno de los L detectores y comparar con el umbral calculado anteriormente para tener una *PFA* deseada. Existiendo detección final en el caso de que como mucho m_0 detectores individuales no hayan detectado.

De esta forma se obtienen las gráficas de la Figura 66, para el caso del algoritmo *SSDD* y las gráficas de la Figura 67, para el caso del algoritmo *NSSDD*, considerando en ambos casos la fusión con $L=7$ canales seleccionados alrededor de la pulsación central $\omega = 2\pi f_d = 2\pi 0.3$, para diferentes valores de m_0 . Representando los valores de la PFA_f en función de la PFA de cada uno de los detectores individuales, tanto prácticos como teóricos.




Figura 66. Curvas teóricas y simuladas de PFA_f , utilizando el algoritmo *SSDD*




Figura 67. Curvas teóricas y simuladas de PFAf, utilizando el algoritmo NSSDD

Para cada valor de las curvas se han utilizado 10 señales simuladas de $N=8000$ muestras cada una, a partir de las que se han generado vectores de observaciones \mathbf{r} correspondientes a intervalos de $nm=50$ muestras.

En las dos figuras, se muestran, por un lado, en línea continua los valores teóricos obtenidos de la aplicación directa de la ecuación (181), y por otro lado, utilizando distintos tipos de marcas, los resultados obtenidos aplicando las simulaciones comentadas anteriormente. Se comprueba que las simulaciones siguen perfectamente a los resultados teóricos demostrados en los apartados anteriores, por lo que se verifica claramente el correcto funcionamiento de los algoritmos y el pertinente control de la PFA.

Por otro lado se puede observar que las gráficas son las típicas esperadas, en las que al aumentar la PFA de cada uno de los detectores individuales, aumenta la PFA_{final} de la fusión de decisiones. Y por otro lado se observa como al ir aumentando el factor m_0 de decisiones a descartar para tomar la decisión final, la PFA_{final} va aumentando proporcionalmente. Por lo que interesará utilizar el menor valor m_0 posible, siempre que la PD sea la adecuada.

4.5.2 Análisis de la detección

En la Figura 68 podemos observar las curvas ROC de PD en función de PFA obtenidas mediante simulaciones de los detectores $SSDD$, $NSSDD$ y trivial. Las cuales han sido obtenidas asumiendo el caso especial del punto 4.4.3 donde se asume que $S_g(\omega) \propto |P(\omega)|^2$ y un perfecto preblanqueo. Este es un primer análisis de las propiedades de detección de los algoritmos que completaremos con simulaciones más completas en el siguiente apartado.

Para medir la PFA , se han generado 10.000 vectores de 20 muestras cada uno, de ruido blanco gaussiano de varianza $\sigma_{g1}^2=1$ y media cero. De forma similar, para medir la PD se han procesado 10.000 vectores de 20 muestras cada uno, de ruido blanco gaussiano de media cero y varianza $\sigma_{g0}^2=0.01$ a los que se les ha añadido el vector a detectar $[1.5 \ 0 \ \dots \ 0]$ (pulso con preblanqueo perfecto y $A=1.5$). El parámetro m_0 de la fusión de decisiones se ha fijado a 0 tanto en el $SSDD$ como en el $NSSDD$, y $N=L=20$.




Figura 68. Curvas ROC correspondiente a los tres algoritmos con $m_0=0$, $N=L=20$, $\sigma_{g1}^2=1$, $\sigma_{g0}^2=0.01$ y $A=1.5$, asumiendo preblanqueo perfecto

Al observar los resultados obtenidos, se puede ver claramente como el algoritmo que obtiene mejores resultados es el $NSSDD$ seguido del trivial y finalmente el $SSDD$, lo que puede llamar la atención ya que, en principio, si se recuerda la Figura 63, se esperan unos resultados similares o mejores al comparar el algoritmo $SSDD$ con el trivial. Sin embargo, la Figura 63, se obtuvo asumiendo que los pulsos a detectar estaban perfectamente limpios de ruido de grano ($\sigma_{g0}^2 \equiv 0$). Por lo que, parece claro, de los resultados obtenidos en la Figura 68, que la presencia de una pequeña cantidad de ruido de grano bajo la hipótesis H_0 , provoca una rápida degradación del rendimiento del algoritmo $SSDD$, aunque hay que tener en cuenta que en el algoritmo $SSDD$ lo primero que hacemos es comparar con el

umbral la energía a la salida de cada canal, de forma que si los umbrales son muy altos, el pulso no se detecta independientemente de la posible forma uniforme de la energía del pulso a lo largo de cada uno de los canales sintonizados. Esta información si se preserva en el algoritmo *NSSDD* al normalizar (antes de comparar con el umbral) la energía de salida de cada filtro, por lo que se obtienen unos resultados mucho mejores en este caso.

4.5.3 Detección con señales simuladas

Una vez comprobado el control sobre la *PFA*, analizada la detección y obtenidas las curvas *ROC* suponiendo preblanqueo perfecto, vamos a realizar una serie de pruebas, con señales simuladas, de las capacidades de detección de los algoritmos *SSDD*, *NSSDD* y trivial. Para posteriormente pasar a realizar pruebas con señales reales en aplicaciones ultrasónicas.

Vamos a realizar, con concreto, varios tipos de pruebas:

- Una primera prueba donde utilizaremos la misma señal sinc del apartado anterior, para simular el pulso buscado, sobre un fondo de ruido coloreado.
- Una segunda prueba donde, aprovecharemos el conocimiento de un pulso real ultrasónico de 5 MHz, para generar la señal como ruido blanco coloreado por este pulso.
- Una tercera prueba donde podremos observar gráficamente los resultados que se obtienen al procesar una serie de señales de ruido coloreado con distintos pulsos sinc distribuidos aleatoriamente.
- A continuación pasaremos a realizar una serie de pruebas más exhaustivas en donde podremos comprobar la *PD* en función de la *PFA* final para la misma señal sinc del apartado anterior con diferentes *SNR*,
- Finalmente realizaremos las mismas pruebas exhaustivas del apartado anterior pero para el pulso real ultrasónico de 5MHz.

4.5.3.1 Detección con señales simuladas y pulso buscado con sinc simulada

Para la primera prueba, volveremos a utilizar los algoritmos de split-spectrum elaborados en este trabajo, *SSDD* y *NSSDD*, pero añadiendo al ruido coloreado por el pulso buscado o ruido de grano simulado, el propio pulso a encontrar en una zona conocida del registro, en concreto en el centro de éste.

Por lo tanto, lo primero que hacemos es simular el pulso buscado mediante la función Sinc (Figura 65) de amplitud $A=0.5$ y ancho de banda $W=0.2$, modulada por un seno de frecuencia digital $fd=0.3$ (193), para a continuación utilizar este pulso simulado para calcular la matriz de auto correlaciones \mathbf{C}_{g1} , que posteriormente se utiliza en el preblanqueo (194). Utilizando como tamaño de la FFT posterior $TamFFT=nm=50$ muestras, aunque en este caso se ha optado por utilizar un tamaño de ventana de $nm/2$, lo que nos da un número de detectores $L=7$ (195).

A continuación convertimos la PFA deseada en cada detector parcial, que en este caso es de $PFA=0.2$, en el equivalente umbral con el que compararemos cada una de las salidas de los detectores, utilizando para ello en el $SSDD$ una distribución de tipo chi-cuadrado de 2 grados de libertad, obteniendo un $umbral1=3.3$ y en el $NSSDD$ una distribución de tipo chi-cuadrado de 2 grados de libertad dividida por su máximo, obteniendo un $umbral2=0.738$, utilizando para ello la ecuación (191) demostrada en el Apéndice C.

Sobre el ruido de grano simulado añadimos el pulso a buscar, en el centro de las muestras $N/2$ del ruido generado, con un factor de solape entre el pulso y el ruido desde los extremos al centro $alfa=50\%$ y una amplitud máxima del pulso igual a $SNR=4$.




Figura 69. Ruido de grano simulado como composición del ruido coloreado y la sinc recortada p en el centro, con un factor de solape del ruido $alfa=50\%$.

A continuación introducimos esta señal simulada en el algoritmo $SSDD$ y en el $NSSDD$, donde básicamente tomaremos los N puntos de esta señal, lo inventanaremos con ventanas de tamaño $nm/2$ y solape del 99% (es decir que solo cambiará una muestra entre ventana y ventana) obteniendo así las r , de tamaño $nm/2$.

La Figura 70 muestra la suma de todas las detecciones, antes de realizar la fusión de decisiones en cada ventana de análisis para el algoritmo $SSDD$ (recuérdese que estamos trabajando con $L=7$ y que hemos insertado el pulso en el centro del registro). Nos da una idea de cómo está funcionando el algoritmo en cada ventana de análisis.




Figura 70. Sumatorio de las detecciones utilizando el algoritmo SSDD cuando el pulso es una sinc.




Figura 71. Comparativa entre la señal antes de entrar en el algoritmo SSDD con pulso sinc y la señal a la salida del algoritmo.

La Figura 71 muestra el resultado de procesar con el algoritmo SSDD, de donde se puede deducir que el algoritmo es capaz de detectar el pulso insertado en el ruido de grano simulado (en el centro de éste a $N/2$), en el caso de trabajar con una $PFA=0.2$ y una $SNR=4$.

En el caso de utilizar el algoritmo NSSDD, podemos reducir la SNR ya que se obtienen unos resultados, prácticamente independientes del nivel relativo del pulso buscado respecto al ruido de grano.

Los resultados obtenidos aplicando la misma filosofía que en el caso anterior pero reduciendo la SNR a 1 son los que se pueden ver en la Figura 72 y la Figura 73:




Figura 72. Sumatorio de las detecciones utilizando el algoritmo NSSDD cuando el pulso es una sinc.




Figura 73. Comparativa entre la señal antes de entrar en el algoritmo NSSDD r_T con pulso sinc y la señal a la salida del algoritmo.

La Figura 73 muestra el resultado de procesar con el algoritmo NSSDD, donde de nuevo se puede ver como se obtienen resultados altamente satisfactorios con una $PFA=0.2$ y una $SNR=1$, detectando el pulso buscado en el centro de las muestras de ruido de grano simulado coloreado por el propio pulso.

4.5.3.2 Detección con señales simuladas y pulso buscado real ultrasónico.

En esta segunda prueba con señales simuladas, vamos a utilizar un pulso real ultrasónico obtenido con un transductor de frecuencia central 5MHz, obtenido a partir de un material de metacrilato, de donde se obtiene un pulso limpio de ruido de grano, gracias a la gran facilidad de transmisión de los ultrasonidos en este tipo de material, (ver Figura 74).




Figura 74. a) Señal ultrasónica real obtenida con un transductor de 5 MHz. b) Trozo de pulso ultrasónico práctico real obtenido a partir de la señal a).

Como podemos ver, gracias a la utilización de este material, con tan buen comportamiento con los ultrasonidos, podemos tomar un intervalo de señal de tamaño $nm=450$ muestras y suponer que únicamente tendremos pulso ultrasónico. Si calculamos la densidad espectral de potencia DEP de este pulso se obtiene la Figura 75.




Figura 75. Densidad Espectral de Potencia (DEP) del pulso ultrasónico práctico.

Donde se puede apreciar como la DEP está centrada aproximadamente en 5MHz la frecuencia central del transductor, ya que $f_m=250 \text{ MHz}$. O lo que es lo mismo, si trabajamos con frecuencias digitales ($f_d=f/f_m$), resulta una frecuencia de $f_d=5/250=0.0188$, y un ancho de banda $W=0.01$.

Entonces, en esta simulación, utilizaremos este pulso ultrasónico real como pulso a buscar sobre un fondo de ruido de grano coloreado por este mismo pulso práctico. Por lo que utilizaremos este mismo pulso p para calcular la matriz de auto correlaciones C_{g1} , que posteriormente se utiliza en el preblanqueo (194). Utilizando como tamaño de la FFT posterior $TamFFT=nm=450$ muestras, y un tamaño de ventana de $nm/2$, lo que nos da un número de detectores $L=6$ (195).

A continuación convertimos la PFA deseada en cada detector parcial, que en este caso es la misma que en el caso anterior de $PFA=0.2$, en el equivalente umbral con el que compararemos cada una de las salidas de los detectores, utilizando para ello en el SSDD una distribución de tipo chi-cuadrado de 2 grados de libertad, obteniendo un $umbral1=3.3$ y en el NSSDD una distribución de tipo chi-cuadrado de 2 grados de libertad dividida por su máximo, obteniendo un $umbral2=0.796$, que es diferente al obtenido en la simulación anterior ya que al variar L cambia el umbral (191).

Sobre este ruido de grano simulado añadimos el pulso a buscar, en el centro de las muestras $N/2$ del ruido generado y una amplitud máxima del pulso igual a $SNR=3$. (ver Figura 76)




Figura 76. Ruido de grano simulado como composición del ruido coloreado y el pulso práctico ultrasónico en el centro.

Mostramos los resultados del SSDD en la Figura 77 (sumatorio de decisiones) y Figura 78 (resultado del procesado con $m_0=2$).




Figura 77. Sumatorio de las detecciones con fusión utilizando el algoritmo SSDD cuando el pulso es un pulso ultrasónico práctico




Figura 78. Comparativa entre la señal antes de entrar en el algoritmo SSDD con el pulso práctico y la señal a la salida del algoritmo.

Se puede observar de nuevo que, también en este caso, el algoritmo SSDD es capaz de detectar el pulso buscado en la zona donde se había añadido, cuando a simple vista no sería posible distinguir claramente en la señal a procesar lo que pertenece a ruido de grano y lo que es pulso. En el caso de trabajar con una $PFA=0.2$ y una $SNR=3$ (menor a la utilizada en el caso anterior).

Utilizando el algoritmo normalizado NSSDD, se obtienen los resultados respectivamente indicados en la Figura 79 y en la Figura 80, también con $m_0=2$.




Figura 79. Sumatorio de las detecciones con fusión utilizando el algoritmo NSSDD cuando el pulso es un pulso ultrasónico práctico




Figura 80. Comparativa entre la señal antes de entrar en el algoritmo NSSDD con el pulso práctico y la señal a la salida del algoritmo.

Donde se obtienen también resultados satisfactorios, aunque aumente la PFA_{final} debido a que el pulso utilizado no está completamente libre de ruido de grano y por lo tanto no tiene un espectro totalmente plano en la banda de paso.

4.5.3.3 Prueba de detección del *NSSDD* con pulso sinc.

Ahora vamos a realizar una prueba donde podremos observar gráficamente los resultados que se obtienen al procesar una serie de señales de ruido coloreado con pulsos sinc (ver Figura 81) distribuidos aleatoriamente, verificando así el correcto funcionamiento del algoritmo *NSSDD* para este tipo de pulsos. En el apartado siguiente extenderemos estos experimentos a los 3 algoritmos considerados.




Figura 81. Pulso sinc a buscar

Para ello utilizaremos como señal a procesar, una señal compuesta de $N_{msen}=10$ realizaciones de $N=1000$ muestras cada una de ruido blanco coloreado por el pulso buscado, a las que se le han incorporado 3 pulsos distribuidos aleatoriamente en cada realización (un total de 30), siguiendo la distribución de la Figura 82.




Figura 82. Situación de los 30 pulsos sinc a detectar aleatoriamente distribuidos.

En este caso utilizaremos un procedimiento distinto al utilizado en las pruebas anteriores para asegurar una mejor generación de la señal simulada, ya que, en vez

de introducir el pulso a buscar en su posición tras generar el ruido coloreado, lo que hemos hecho en este caso, ha sido generar un ruido blanco gaussiano de media cero y varianza unidad al que le hemos incorporado una serie de deltas con nulos a sus lados en la posición indicada por la figura anterior, y una vez construida esta señal previa, la hemos pasado por un filtro con respuesta al impulso igual al pulso buscado, de forma que el ruido blanco se colorea y las deltas se convierten en pulsos de tipo sinc.

Por ejemplo, para la prueba que se muestra a continuación, hemos utilizado una amplitud de la delta (antes de colorear) de $A=4$ y una proporción del 75% ($\alpha=0.75$) de ceros respecto al ruido en esta delta, es decir que tenemos $nm=50 \cdot (1-\alpha)=12$ ceros a cada lado de la delta, obteniendo, para el caso de la primera realización, la señal previa que se muestra en la Figura 83.




Figura 83 Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar.

La cual posteriormente se colorea con el pulso buscado de tipo sinc, obteniendo la siguiente señal para la primera realización, ver Figura 84.




Figura 84. Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos tipo sinc

Una vez generada la señal a procesar (ver Figura 85 y Figura 86), aplicamos el algoritmo *NSSDD* con $m_0=1$ (exigencia del n° de detectores que pueden no detectar), $PFA_f=0.0001$ (Probabilidad de falsa alarma final deseada), $solape=1$ (Porcentaje de Solape para el enventanado, si el solape =1, muestra a muestra), $nm=50$, $fact_ventana=1/4$ (Factor por el que multiplicamos el $Tam_vent=nm$ para cambiar el tamaño de la ventana), $fact_norma_L=1$ (Factor por el que multiplicamos $TamFFT=nm$ para que L aumente)




Figura 85. Señales a procesar como composición del ruido coloreado y los pulsos tipo sinc aleatorios

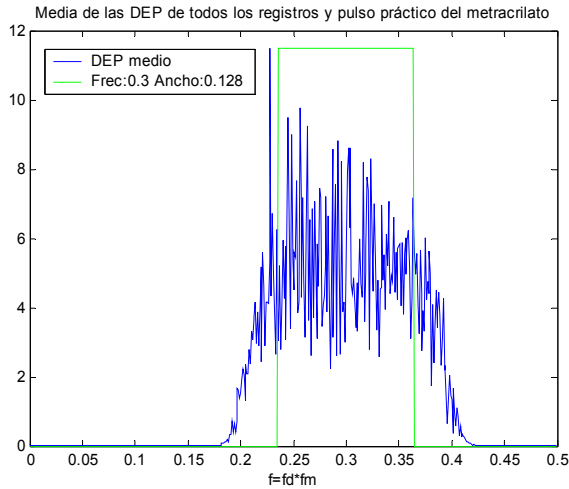


Figura 86. Espectro de la señal a procesar y zona de trabajo del algoritmo NSSDD.

Obteniendo los siguientes resultados, ver Figura 87 y Figura 88.

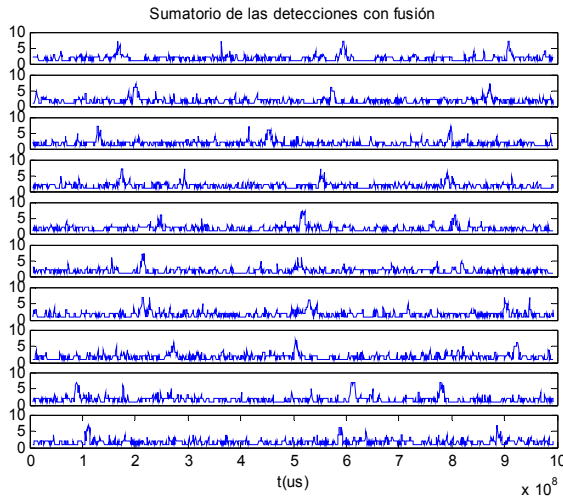


Figura 87. Sumatorio de las detecciones con fusión con NSSDD

Donde podemos observar, la señal detectada y una serie de ventanas que nos muestran la ubicación de los pulsos a buscar.

De forma que si:

- Aparece una señal dentro de una ventana, tendremos una detección correcta.
- Aparece una señal sin enmarcar, tendremos una falsa alarma.
- Aparece una ventana sin señal, tendremos una no detección.




Figura 88. Gráfica de resultados utilizando el algoritmo NSSDD

De donde se pueden deducir los siguientes resultados prácticos:

- 29 Detecciones, es decir una PD real $29/30 = 0.96667$
- 7 Falsas Alarmas, es decir una PFA real $7/10000 = 0.00071066$

Recordemos que habíamos fijado una PFA final de 0.0001, que para $L=7$ se corresponde con una PFA en cada detector de 0.16 y un umbral de 0.86. Por lo que se demuestra que el algoritmo NSSDD funciona correctamente cuando el pulso a buscar tiene un espectro plano en la banda de trabajo. Cabe destacar que, para este caso, con esta PFA final deseada, tanto el algoritmo SSDD como el algoritmo trivial no son capaces de detectar ninguno de los pulsos buscados.

Una vez realizada esta prueba puntual, vamos a describir, a continuación, una serie de pruebas más exhaustivas para verificar el comportamiento de los algoritmos desarrollados y poder así compararlos entre sí. Recordemos que hemos definido el algoritmo trivial como un algoritmo que toma la señal a procesar, la inventana, la pasa por el filtro de preblanqueo, toma una muestra del vector obtenido (en nuestro caso la muestra central) y la compara con el umbral.

4.5.3.4 Verificación de la Probabilidad de Detección con señales simuladas y pulso buscado sinc, para distintas SNR.

A continuación vamos a realizar una serie de pruebas más exhaustivas en donde podremos comprobar la PD en función de la PFA para una serie de pulsos buscados de tipo sinc con diferentes valores de amplitud.

- Para un Pulso con una sinc con $SNR=6$, $alfa=0.75$, $N=1000$, $nm=50$, $Numsen=1$, utilizando 3 x 10 pulsos aleatorios, ver Figura 89.




Figura 89. Primera realización de la señal a procesar con pulso sinc con $SNR=6$, $alfa=0.75$

Ejecuciones con: $m_0=1$ (Exigencia del n^o de detectores que pueden no detectar), $PFA_f=0.001$ (Probabilidad de falsa alarma final deseada), $solape=1$ (Porcentaje de Solape para el enventanado, si el $solape=1$, muestra a muestra), $nm=50$, $fact_ventana=1/4$ (Factor por el que multiplicamos el $Tam_vent=nm$ para cambiar el tamaño de la ventana), $fact_norma_L=1$ (Factor por el que multiplicamos $TamFFT=nm$ para que L aumente), $L=7$.

Obteniendo los siguientes resultados, ver Tabla IV (donde la 1ª columna indica el n^o de falsas alarmas detectadas y las 3 siguientes el n^o de detecciones correctas, siendo 30 el máximo posible, para cada método) y Figura 90.

Nº FA	Sin Normalizar	Normalizado	Trivial
0	0	7	0
1	0	22	0
2	0	27	1
5	11	27	16
7	26	30	30
10	30	30	30

Tabla IV. Resultados de detección obtenidos con Pulso sinc con $SNR=6$ y $alfa=0.75$.




Figura 90. Comparativa de algoritmos con pulso sinc de SNR=6.

Observando como, en este caso en el que al trabajar con una SNR alta, los pulsos buscados sobresalen del ruido de grano, los tres algoritmos tienen un buen comportamiento ya que llegan a una PD del 100% con muy pocas falsas alarmas (7), aunque se puede observar como el NSSDD es sensiblemente mejor que los otros dos, siendo el SSDD y el trivial aproximadamente iguales.

- Para un Pulso con una sinc con $SNR=4$, $\alpha=0.75$, $N=1000$, $nm=50$, $Numsen=1$, utilizando 3 x 10 pulsos aleatorios, ver Figura 91.




Figura 91. Primera realización de la señal a procesar con pulso sinc con SNR=4, $\alpha=0.75$

Ejecuciones con: $m_0=1$ (Exigencia del nº de detectores que pueden no detectar), $PFA_f=0.001$ (Probabilidad de falsa alarma final deseada), $solape=1$ (Porcentaje de Solape para el enventanado, si el $solape=1$, muestra a muestra), $nm=50$, $fact_ventana=1/4$ (Factor por el que multiplicamos el $Tam_vent=nm$ para

cambiar el tamaño de la ventana), $fact_norma_L=1$ (Factor por el que multiplicamos $TamFFT=nm$ para que L aumente), $L=7$.

Obteniendo los siguientes resultados, ver Tabla V y Figura 92

Nº FA	Sin Normalizar	Normalizado	Trivial
0	0	7	0
3	0	14	0
5	0	21	0
10	0	27	0
13	0	28	0
28	0	29	0
43	0	30	0
63	0	30	1
94	0	30	6
133	0	30	9
163	0	30	16
202	0	30	21
240	0	30	25
287	1	30	29
341	12	30	30
399	25	30	30
443	30	30	30

Tabla V. Resultados obtenidos con Pulso sinc con $SNR=4$ y $\alpha=0.75$.




Figura 92. Comparativa de algoritmos con pulso sinc de $SNR=4$

En este caso, al disminuir la SNR , el pulso buscado ya no sobresale tan claramente del ruido de fondo y por lo tanto el trivial (un poco mejor) y el $SSDD$ dejan de funcionar tan bien como en el caso anterior, sin embargo el $NSSDD$ funciona aproximadamente igual que antes.

Cabe destacar, en este punto, la similitud de la gráfica práctica obtenida en la Figura 92 con la obtenida anteriormente en la Figura 68 donde se asumía el preblanqueo perfecto. En ambos casos se concluye la superioridad del algoritmo *NSSDD* respecto al trivial y al *SSDD*.

Particularmente el *SSDD*, parece ser más sensible a la presencia de una pequeña cantidad de ruido de grano cuando el pulso buscado aparece, concretamente, en la Figura 68 el ruido de grano preblanqueado se añade explícitamente al utilizar una $\sigma_{g0}^2=0.01$, sin embargo, en el caso de la Figura 92 el ruido de grano, que afecta al intervalo del pulso, aparece por el efecto de la convolución. Es decir, al trabajar con un $\alpha=0.75$, de las 50 muestras con las que se trabaja, se utilizan 12 ceros antes y otros 12 ceros después del pulso para generar el pulso buscado antes de la convolución, en vez de 50 y 50, por lo que en realidad, parte del ruido de grano se introduce en la señal buscada y, aunque posteriormente realmente trabajemos con $\frac{1}{4}$ parte de la señal, algo del ruido se sigue incorporando al pulso a buscar.

- Para un Pulso con una sinc con $SNR=2$, $\alpha=0.75$, $N=1000$, $nm=50$, $Numsen=1$, utilizando 3 x 10 pulsos aleatorios.




Figura 93. Primera realización de la señal a procesar con pulso sinc con $SNR=2$, $\alpha=0.75$

Ejecuciones con: $m_0=1$ (Exigencia del n° de detectores que pueden no detectar), $PFA_f=0.001$ (Probabilidad de falsa alarma final deseada), $solape=1$ (Porcentaje de Solape para el eventanado, si el $solape=1$, muestra a muestra), $nm=50$, $fact_ventana=1/4$ (Factor por el que multiplicamos el $Tam_vent=nm$ para cambiar el tamaño de la ventana), $fact_norma_L=1$ (Factor por el que multiplicamos $TamFFT=nm$ para que L aumente), $L=7$.

Obteniendo los siguientes resultados, ver Tabla VI y Figura 94.

Nº FA	Sin Normalizar	Normalizado	Trivial
0	0	0	0
2	0	2	0
4	0	10	0
13	0	15	0
30	0	22	0
266	0	29	0
441	0	30	0
1622	0	30	6
2045	0	30	13
2441	0	30	24
3469	0	30	30
4098	2	30	30
4176	5	30	30
4254	12	30	30
4326	14	30	30
4687	25	30	30
5037	29	30	30
5422	30	30	30

Tabla VI. Resultados obtenidos con Pulso sinc con SNR=2 y alfa=0.75.




Figura 94. Comparativa de algoritmos con pulso sinc de SNR=2.

Al reducir tan claramente la SNR, el nº de falsas alarmas para poder detectar los 30 pulsos se dispara espectacularmente.

4.5.3.5 Verificación de la Probabilidad de Detección con señales simuladas y pulso buscado real ultrasónico, para distintas SNR.

A continuación vamos a realizar la misma serie de pruebas exhaustivas del apartado anterior para comprobar la PD en función de la PFA para una serie de pulsos buscados reales ultrasónicos de 5 MHz (ver Figura 95) con diferentes valores de amplitud.




Figura 95. Pulso real ultrasónico de 5 MHz y su DEP.

➤ Para un Pulso real con $SNR=8$, $alfa=0$, $N=1000$, $nm=50$, $Numsen=1$, utilizando 3 x 10 pulsos aleatorios, ver Figura 96.




Figura 96. Construcción de la primera realización de la señal a procesar con pulso real y $SNR=8$. a) Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. b) Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos reales.

Ejecuciones con $m_0=1$ (Exigencia del nº de detectores que pueden no detectar), $solape=1$ (Porcentaje de Solape para el enventanado, si el $solape=1$, muestra a muestra), $nm=48$, $fact_ventana=1$ (Factor por el que multiplico el $Tam_vent=nm$ para cambiar el tamaño de la ventana), $fact_norma_L=5$ (Factor por el que multiplico $TamFFT=nm$ para que L aumente), $L=6$.

Obteniendo los siguientes resultados, ver Tabla VII y Figura 97.

Nº FA	Sin Normalizar	Normalizado	Trivial
0	0	1	0
3	0	8	0
4	0	12	2
5	0	12	5
6	0	13	10
7	0	14	18
8	0	14	29
9	0	15	30
20	0	20	30
33	0	25	30
64	0	29	30
162	0	30	30
558	0	30	30
891	3	30	30
900	6	30	30
908	10	30	30
912	14	30	30
913	30	30	30

Tabla VII Resultados obtenidos con Pulso real con SNR=8




Figura 97. Comparativa de algoritmos con pulso real de SNR=8

A la vista de los resultados obtenidos se puede observar como, al utilizar un nivel de señal por encima del nivel de ruido, el algoritmo NSSDD implementado no presenta una apreciable mejora respecto al detector trivial, funcionando los dos de una manera similar y con una alta probabilidad de detección con baja falsa alarma.

Por otro lado se observa como el algoritmo inicial implementado *SSDD* no funciona correctamente con este tipo de pulso más realista.

- Para un Pulso real con $SNR=6$, $\alpha=0$, $N=1000$, $nm=50$, $Numsen=1$, Procedimiento 2, utilizando 3 x 10 pulsos aleatorios, ver Figura 98.




Figura 98. Construcción de la primera realización de la señal a procesar con pulso real y $SNR=6$. a) Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. b) Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos reales.

Ejecuciones con $m_0=1$ (Exigencia del n° de detectores que pueden no detectar), $solape=1$ (Porcentaje de Solape para el enventanado, si el $solape=1$, muestra a muestra), $nm=48$, $fact_ventana=1$ (Factor por el que multiplico el $Tam_vent=nm$ para cambiar el tamaño de la ventana), $fact_norma_L=5$ (Factor por el que multiplico $TamFFT=nm$ para que L aumente), $L=6$.

Obteniendo los siguientes resultados, ver Tabla VIII y Figura 99.

Nº FA	Sin Normalizar	Normalizado	Trivial
0	0	0	0
7	0	7	0
19	0	12	0
28	0	17	0
35	0	20	0
46	0	24	1
62	0	26	7
79	0	28	13
92	0	29	20
108	0	30	28
139	0	30	30
174	0	30	30
1641	1	30	30
1714	4	30	30
1729	6	30	30
1738	12	30	30

1744	19	30	30
1749	30	30	30

Tabla VIII. Resultados obtenidos con Pulso real con SNR=6




Figura 99. Comparativa de algoritmos con pulso real de SNR=6

Al reducir la SNR se empieza a apreciar la mejora que introduce el NSSDD respecto del sistema trivial mejorando sensiblemente la PD para bajas tasas de PFA.

- Para un Pulso real con SNR=4, alfa = 0, N=1000, nm=50, Numsen=1, Procedimiento 2, utilizando 3 x 10 pulsos aleatorios, ver Figura 100.




Figura 100. Construcción de la primera realización de la señal a procesar con pulso real y SNR=4. a) Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. b) Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos reales.

Ejecuciones con $m_0=1$ (Exigencia del n° de detectores que pueden no detectar), $solape=1$ (Porcentaje de Solape para el inventariado, si el $solape=1$, muestra a muestra), $nm=48$, $fact_ventana=1$ (Factor por el que multiplico el $Tam_vent=nm$ para cambiar el tamaño de la ventana), $fact_norma_L=5$ (Factor por el que multiplico $TamFFT=nm$ para que L aumente), $L=6$.

Obteniendo los siguientes resultados, ver Tabla IX y Figura 101.

Nº FA	Sin Normalizar	Normalizado	Trivial
0	0	0	0
3	0	1	0
6	0	5	0
21	0	12	0
50	0	15	0
80	0	21	0
188	0	30	0
277	0	30	0
515	0	30	7
561	0	30	14
607	0	30	19
650	0	30	25
710	0	30	28
774	0	30	29
3411	1	30	30
3697	2	30	30
3759	3	30	30
3814	3	30	30
3862	5	30	30
3892	10	30	30
3906	13	30	30
3916	27	30	30
3959	30	30	30

Tabla IX. Resultados obtenidos con Pulso real con SNR=4




Figura 101. Comparativa de algoritmos con pulso real de SNR=4

Finalmente, si se continúa reduciendo el nivel de señal respecto al ruido, se observa como el algoritmo *NSSDD* apenas cambia su *PD*, mientras que tanto el *SSDD* como el trivial van empeorando sus tasas de detección como cabía esperar.

Por lo tanto, podemos concluir con que el algoritmo *SSDD*, que en realidad puede ser considerado como el algoritmo de minimización (si $m_0=0$) o un algoritmo de estadísticos de orden (para m_0 arbitrario entre 0 y $L-1$), es decir que representa a los algoritmos convencionales de split-spectrum, está bastante limitado para su uso en tareas donde se prime la detección automática de pulsos cuya característica fundamental sea su uniformidad espectral, más que un nivel de energía importante en cada uno de los detectores sintonizados, donde el *NSSDD* sí que funciona de manera mucho más adecuada, como se ha podido corroborar en las experiencias anteriores.

A continuación, y para completar la parte experimental de la tesis, vamos a presentar una serie de estudios con señales ultrasónicas reales.

4.6 Aplicación a señales ultrasónicas reales bajo control de laboratorio

Tras comprobar el funcionamiento de los algoritmos *SSDD* y *NSSDD* con señales simuladas generadas a partir de pulsos ficticios o de pulsos reales, de los apartados anteriores, vamos a aplicar estos mismos algoritmos desarrollados a señales ultrasónicas reales.

Comenzaremos este punto realizando una serie de pruebas controladas en el laboratorio para comprobar el funcionamiento de los algoritmos con un material propicio a la transmisión de los ultrasonidos, como es el duraluminio.

Para realizar las medidas en el laboratorio hemos utilizado la mesa XY desarrollada por el GTS, donde podemos realizar medidas ultrasónicas en inmersión de forma automática, (Figura 102).




Figura 102. Esquema detallado de la mesa XY

Esta mesa XY tiene capacidad de desplazar automáticamente un cabezal en dos direcciones correspondientes a los ejes coordenados X e Y. En el cabezal se instala un transductor de ultrasonidos (sensor) y su diseño permite que pueda graduarse para instalar diferentes tipos de sensores. En la dirección Z, el cabezal puede desplazarse manualmente hasta alcanzar una distancia adecuada entre el sensor y la superficie del material (aproximadamente hasta 2 mm.). Tanto el movimiento del sensor debido al desplazamiento de los ejes como la adquisición de las señales medidas por ultrasonidos son controladas por un sistema computerizado.

En la Figura 102 puede apreciarse el tanque de inmersión donde se colocan las probetas de material que van a ser inspeccionadas, las cuales pueden ser de diversas formas, tamaños y materiales, estando su volumen y número limitado por

las dimensiones del tanque de inmersión 30x140x90 cm. Las probetas más comunes tienen forma de paralelepípedo. Una vez puesto el material y ajustado el cabezal en la dirección Z, se llena con agua el tanque hasta cubrir las probetas completamente. La película de agua que queda entre el sensor y el material sirve como medio de acople para la transmisión de los ultrasonidos desde el sensor al material.

La probeta con la que vamos a realizar las medias es una pieza paralelepípeda de dura-aluminio de dimensiones 7x7x21cm sumergida en agua, ver Figura 103, a la cual se le ha practicado un taladro de 1cm de diámetro para simular un defecto (circular) en la posición (6cm, 3.5cm). Se ha empleado un transductor de 2MHz separado una distancia de 5mm de la probeta y se ha configurado la medida para obtener un movimiento XY, con unos 1000 puntos en forma de cuadrícula equiespaciada de 5mm, atacando el material por la cara superior.




Figura 103. Probeta de duraluminio con taladro

Teniendo en cuenta la relación entre la velocidad de propagación, la distancia y el tiempo descrita por las siguientes ecuaciones:

$$\text{velprop} = \frac{2 \cdot \text{distancia}}{\text{tiempo}} \quad \text{tiempo} = \frac{2 \cdot \text{distancia}}{\text{velprop}} \quad (200)$$

y que en el dura-aluminio, la velocidad de propagación aproximada es de 6368m/s, podemos concluir que deberemos obtener ecos en los siguientes tiempos:

- Primer eco de la interfase agua-probeta a 11 μ s.
- Segundo eco de la interfase agua-probeta a 22.1 μ s.
- Primer eco del final de la probeta a 33.16 μ s.
- Primer eco del defecto a 20.44 μ s en las señales 22, 23 y 93.
- Segundo eco del defecto a 32.4 μ s en las señales 22, 23 y 93.

Por lo que si tomamos el tiempo del primer eco del final de la probeta (33.16 μ s), le restamos el tiempo que tarda el pulso en llegar a la probeta por el agua (11 μ s), lo multiplicamos por la velocidad de propagación de los ultrasonidos en el dura-aluminio 6368m/s y lo dividimos por 2 (técnica de pulso/eco), obtenemos la distancia de 7cm que corresponde con el ancho de la probeta. Y fijándonos en que el defecto correspondiente al taladro debe estar a un tiempo de 20.44 μ s. Si a este tiempo se le resta el tiempo que tarda el pulso en llegar a la probeta (11 μ s), se multiplica por 6368m/s (velocidad de propagación de los ultrasonidos en

duraluminio) y se divide por 2 (técnica de pulso/eco), obtenemos una distancia de 3cm que corresponde con el inicio del taladro.

A continuación se muestra, en la Figura 104, las señales obtenidas, donde en el eje de las abscisas se representa el tiempo transcurrido, mientras que en el eje de ordenadas se representan las 112 señales recogidas con la mesa XY, que se corresponden con el barrido de izquierda a derecha de la señal 9 a la 56 y del mismo barrido de derecha a izquierda en las señales de la 59 a la 107, siendo las señales intermedias, de la 1 a la 8 y de la 108 a la 112, señales donde sólo aparece agua y no hay contacto con la probeta bajo análisis, y la 57 y 58, señales captadas al desplazar el cabezal en profundidad. Por lo tanto, tenemos una repetición espacial en las medidas procesadas, lo que nos va a permitir corroborar los resultados obtenidos, ya que de la 9 a la 56 deberíamos tener aproximadamente las mismas señales que de la 107 a la 59, ya que se recorre la misma probeta de prueba, aunque con una cierta desviación espacial en la dirección de penetración Y.




Figura 104. Señales reales utilizadas con el duraluminio

Mostrando en la Figura 105 la medida del espectro medio de todas las señales a procesar, lo que nos da una idea de los parámetros de ancho de banda y frecuencia del transductor a utilizar en el procesado, que en este caso serán de $frec_transd=2\text{MHz}$ y $Ancho_transd=1\text{MHz}$




Figura 105. Medida de la Densidad Espectral de Potencia de todas las señales a procesar y parte del espectro a utilizar para este procesado.

4.6.1 Resultados obtenidos en el duraluminio con el algoritmo trivial

Si realizamos el procesado utilizando el algoritmo trivial, con los siguientes parámetros: $m_0=1$ (todos deben detectar menos uno), $solape=1$ (muestra a muestra), $nm=30$ (nº de muestras pequeño), $fact_norma_L=10$ (de forma que $TamFFT=10 \cdot L$ y por lo tanto interpolando) y $L=13$ (nº de detectores).

Se obtienen los resultados de la Figura 106 y la Figura 107, donde se ha fijado la PFA_r a 0.05 (tras diversas pruebas) lo que da un umbral de 1.96, para tener máxima detectabilidad, es decir, buscando el porcentaje de PFA_r más adecuado para que se llegue a discernir los ecos de los defectos buscados aunque aparezcan falsas alarmas.




Figura 106 Resultados obtenidos con el algoritmo trivial en el duraluminio, mostrando detecciones, es decir unos o ceros.




Figura 107. Resultados obtenidos con el algoritmo trivial en el duraluminio, mostrando el valor absoluto de la señal procesada donde se había detectado.

Por lo que, con el algoritmo trivial, podemos observar como somos capaces de detectar, de izquierda a derecha, la interfase entre el agua y el comienzo de la probeta de duraluminio a una distancia temporal de unos $11\mu\text{s}$, a continuación el segundo eco de esta interfase a unos $22\mu\text{s}$, y finalmente el eco de fondo de la probeta a unos $33\mu\text{s}$. Con algunas falsas alarmas. Siendo incapaces de mostrar claramente los ecos pertenecientes al defecto que se deberían mostrar alrededor de los $21\mu\text{s}$ y $32\mu\text{s}$ (segundo eco) aproximadamente en las señales 22, 23 y 93.

4.6.2 Resultados obtenidos en el duraluminio con el algoritmo SSDD

Si realizamos el procesamiento utilizando el algoritmo SSDD, con los mismos parámetros que en el caso anterior: $m_0=1$ (todos deben detectar menos uno), $solape=1$ (muestra a muestra), $nm=30$ (n° de muestras pequeño), $fact_norma_L=10$ (de forma que $TamFFT=10 \cdot L$ y por lo tanto interpolando) y $L=13$ (n° de detectores).

Se obtienen los resultados ilustrados en la Figura 108 y la Figura 109 donde, en este caso, se ha podido subir la PFA_r hasta 0.2, con un umbral de 0.48, teniendo máxima detectabilidad, es decir, llegando a discernir los ecos de los defectos buscados mucho más claramente.




Figura 108 Resultados obtenidos con el algoritmo SSDD en el duraluminio, mostrando detecciones, es decir unos o ceros.




Figura 109. Resultados obtenidos con el algoritmo SSDD en el duraluminio, mostrando el valor absoluto de la señal procesada donde se había detectado.

En el caso del *SSDD*, sí somos capaces de detectar todas las interfases en los tiempos previstos $11\mu\text{s}$, $22.1\mu\text{s}$ y $33.16\mu\text{s}$ y los ecos producidos por el defecto controlado tanto en el primer eco (a $20.44\mu\text{s}$) como en el segundo eco del defecto (a $32.4\mu\text{s}$).

Además, si se compara con el resultado anterior del detector trivial, se puede observar cómo se consigue una mayor definición de las interfases y una mayor limpieza de falsas alarmas en las zonas donde no debe haber detección aunque de hecho se haya aumentado el porcentaje de PFA_r .

4.6.3 Resultados obtenidos en el duraluminio con el algoritmo *NSSDD*

Si realizamos el procesado utilizando el algoritmo *NSSDD*, con los mismos parámetros que en los ejemplos anteriores: $m_0=1$ (todos deben detectar menos uno), $solape=1$ (muestra a muestra), $nm=30$ (nº de muestras pequeño), $fact_norma_L=10$ (de forma que $TamFFT=10\cdot L$ y por lo tanto interpolando) y $L=13$ (nº de detectores).

Se obtienen los resultados de la Figura 110 y la Figura 111, donde se ha tenido que reducir la PFA_r a $7e-10$, con un umbral de 0.7, que ha generado una PFA_r real de 0.02 (tras diversos experimentos) permitiendo tener máxima detectabilidad y ser capaces de discernir los ecos de los defectos buscados aunque aparezcan más falsas alarmas.




Figura 110 Resultados obtenidos con el algoritmo *NSSDD* en el duraluminio, mostrando detecciones, es decir unos o ceros.




Figura 111. Resultados obtenidos con el algoritmo *NSSDD* en el duraluminio, mostrando el valor absoluto de la señal procesada donde se había detectado.

Pudiendo observar, en el caso del *NSSDD*, cómo también somos capaces de detectar las interfases y los ecos pero sin tanta definición como en el caso del *SSDD*, y con un mayor número de falsas alarmas aunque de hecho se haya reducido la PFA_f .

Por lo que podemos concluir que, en el caso de este tipo de señales reales, si nos fijamos en la detección del defecto, se consiguen los mejores resultados con el *SSDD*, a continuación con *NSSDD* y finalmente con el trivial.

Esta conclusión no se corresponde exactamente con los resultados obtenidos con las señales simuladas del apartado anterior, pero se ha de tener en cuenta una serie de factores condicionantes, como son, el hecho de estar trabajando con señales de banda estrecha y por lo tanto necesitar rellenar por ceros al realizar la FFT para poder tener un número mínimo de detectores a fusionar, lo que implica que las detecciones están altamente correladas.

Por otra parte debe recordarse que los estudios teóricos y las simulaciones previas que nos llevaron a la conclusión de la superioridad del *NSSDD*, sobre el *SSDD* y el trivial, asumían pulsos a detectar prácticamente limpios de ruido, lo que no parece cumplirse aquí, ya que el nivel de los ecos de los taladros es muy bajo (no hay prácticamente ruido de grano).

4.7 Aplicación de los ensayos no destructivos de materiales con ultrasonidos a la restauración de edificios históricos.

La presente aplicación de las técnicas de inspección ultrasónica, en la restauración de edificios históricos, nace de una fructífera colaboración entre los departamentos de Conservación y Restauración de Bienes Culturales, el departamento de Proyectos Arquitectónicos y nuestro propio departamento de Comunicaciones, de la que han surgido diversos proyectos de colaboración interdisciplinarios, tanto en la restauración de la Real Basílica de la Virgen de los Desamparados de Valencia como más recientemente, en la restauración de la Iglesia de los Santos Juanes de Valencia.

Concretamente se ha desarrollado una investigación aplicada sobre el análisis de capas de materiales en restauración de edificios históricos. Dicho análisis se ha efectuado mediante evaluación no destructiva por ultrasonidos, siendo ésta una contribución en la línea de la investigación de técnicas de diagnóstico y tratamiento de materiales utilizados en el Patrimonio Artístico definido por la Comisión Interministerial de Ciencia y Tecnología.

La investigación sobre el estado de las capas de materiales es un tema importante en restauración y también en ingeniería. Existen muchas aplicaciones en la industria petrolera en evaluación del espesor de paredes de tubos. En ese campo los materiales analizados son metales con excelentes características de homogeneidad y propagación para las ondas ultrasónicas. Por el contrario, en restauración de edificios históricos los materiales a analizar consisten básicamente en materiales de construcción tales como yeso, mortero ó rocas ornamentales. Estos exhiben diferentes clases de inhomogeneidades y la propagación de ondas a través de la microestructura del material es compleja.

4.7.1 Descripción del entorno de trabajo en la Real Basílica de la Virgen de los Desamparados de Valencia.

En un principio, se efectuaron una serie de medidas de señales ultrasónicas en un área de la cúpula de la Basílica de la Virgen de los Desamparados de Valencia, con la intención de detectar los ecos producidos en la señal recibida debido a reflexiones del pulso ultrasónico contra las diferentes capas de materiales de la pared (ver Figura 112).



Figura 112. Interior de la Cúpula de la Virgen de los Desamparados de Valencia

Para ello se realizaron un conjunto de medidas en una línea vertical recta sobre un área de la superficial interna de la cúpula. La Figura 113 muestra los puntos en la superficie de la pared donde el sensor fue aplicado.




Figura 113. Superficie examinada en la Cúpula de la Basílica

Se realizaron diversas pruebas para seleccionar los transductores de ultrasonidos más adecuados, trabajando con palpadores entre 250kHz y 10MHz.

Los transductores de ultrasonidos tienen como principal característica que funcionan a una frecuencia de trabajo y con un cierto ancho de banda. Mientras más alta sea la frecuencia del traductor más alta es la capacidad para detectar

detalles pequeños, pero también más baja la capacidad de penetración en el material. Es decir, es posible detectar detalles más pequeños, pero estos deben estar más cerca de la superficie.

Teniendo en cuenta los aspectos anteriores, es posible seleccionar diferentes clases de transductores. En este caso hemos escogido el transductor de 5 MHz ver Figura 114.



Figura 114. Detalle del transductor de 5MHz

Para medir el espesor de las primeras capas de la pared mediante la detección de los tiempos de llegada de las señales ultrasónicas se usó un transductor de 5MHz de alta resolución y baja capacidad de penetración. La capacidad de penetración de esta frecuencia en yeso está en el rango de 1 a 2 cm. como máximo. Este transductor tiene un tamaño pequeño con un diámetro de 0.7cm. y por lo tanto su acoplamiento es sensible a las irregularidades superficiales del material. Tiene un desempeño óptimo trabajando en superficies de materiales homogéneas y lisas.

Los parámetros de configuración y equipamiento usados son los siguientes (ver Tabla X).

Parámetros de ultrasonidos		Parámetros de adquisición	
Equipo de ultrasonidos:	<i>Matec PR5000</i>	Equipo de adquisición:	<i>Osciloscopio TDS3012 Tektronix</i>
Transductores:	<i>5 MHz del fabricante Krautkrämer</i>	Frecuencia de muestreo:	<i>10MHz</i>
Ancho del pulso	<i>0.90us</i>	Número de muestras:	<i>10.000</i>
Amplitud del pulso	<i>80%</i>	Tiempo adquirido:	<i>1ms</i>
Filtro analógico	<i>2.5 MHz- 6 MHz</i>	Resolución de la amplitud:	<i>16bits</i>
Señal de	<i>ráfaga de tonos</i>	Rango dinámico:	<i>±2.5V</i>

Parámetros de ultrasonidos	
excitación	de 5 MHz
Modo de operación:	Pulso/Eco
Ganancia del amplificador:	65dB

Parámetros de adquisición	
Promediado:	64 adquisiciones

Tabla X. Parámetros de configuración y equipamiento

Siendo el equipo de medida utilizado el que se puede ver en la Figura 115, donde se observa de abajo a arriba: El equipo de ultrasonidos Matec PR5000, la tarjeta de adquisición externa por USB, los transductores y cables y el PC portátil estándar para la transferencia y almacenamiento de las señales.




Figura 115. Detalle de los equipos de medida

Uno de los primeros problemas que surgieron nada más subir al andamio de la Basílica fue la imposibilidad de utilizar el típico gel ultrasónico de acoplamiento, debido a que este gel podía interferir en la propia restauración pictórica que se estaba realizando, por esta razón se decidió utilizar un plástico protector (ver Figura 116).



Figura 116. Transductor cubierto por plástico durante la medida

Por otro lado, las propias circunstancias físicas de la cúpula impedían el acceso por las dos caras del material a trabajar, por lo que se tuvo que utilizar un esquema de inspección del material pulso-eco, donde un único sensor funciona como emisor y receptor (ver Figura 117b), en vez de utilizar un esquema de inspección de transmisión-recepción. En este esquema se emite un pulso ultrasónico que penetra en la pared y se recibe una señal que contiene información sobre la microestructura del material.




Figura 117. Técnicas de inspección ultrasónica.

Por lo tanto, y debido a las grandes dificultades técnicas que se introducen por el hecho de trabajar en un entorno tan desfavorable, se decidió completar el trabajo, en un modelo a escala 1:1 de un área de la cúpula que se había implementado como parte de las tareas de restauración arquitectónico-pictóricas que se estaban desarrollando, con el fin de minimizar el riesgo en la restauración de las pinturas de la pared.

Además, se han podido realizar extracciones de algunas muestras de materiales del modelo a escala que se han medido en el laboratorio para obtener un cálculo preciso de la velocidad de propagación de las ondas ultrasónicas en los materiales, y así poder relacionar los tiempos de llegada de los pulsos ultrasónicos detectados con las distancias aproximadas a las que se han producido y por lo tanto un perfil aproximado de las capas de materiales de la cúpula, que se deben corresponder con el perfil que se estima se tiene en la realidad y que se muestra en la Figura 118.




Figura 118. Perfil aproximado de las capas de materiales de la cúpula

Donde:

- 1ª capa: Intónaco de mortero de cal y arena, donde se ubican las pinturas con 0.3cm de ancho.
- 2ª capa: Arriccio de yeso de 1.2cm de ancho, a una profundidad de $0.3+1.2=1.5cm$
- 3ª capa: Trullisatio y arenato de yeso de ancho 1.5cm, a una profundidad de $0.3+1.2+1.5=3cm$.

Por lo tanto, considerando una velocidad de propagación por el material de 1600m/s, obtenida del estudio que se considerará en el próximo punto, debemos tener ecos en los espacios temporales descritos por la Tabla XI.

Capa	Profundidad	Tiempo
1º eco de la 1ª capa: Intónaco de mortero de cal y arena	0.3cm	3.75µs
2º eco de la 1ª capa: Intónaco de mortero de cal y arena	(0.6)cm	7.50µs
3º eco de la 1ª capa: Intónaco de mortero de cal y arena	(0.9)cm	11.25µs
4º eco de la 1ª capa: Intónaco de mortero de cal y arena	(1.2)cm	15.00µs
2ª capa: Arriccio de yeso	1.5cm	18.75µs
3ª capa: Trullisatio y arenato de yeso	3.0cm	37.50µs

Tabla XI. Relación de capas, profundidades y tiempos donde encontrar ecos

4.7.2 Resultados obtenidos en la Real Basílica de la Virgen de los Desamparados.

Como se ha comentado anteriormente, se trabajó con 10 señales adquiridas en la cúpula de la Real Basílica de la Virgen de los Desamparados de Valencia, concretamente con las señales descritas en la Figura 119 y Figura 120, cuya densidad espectral de potencia se muestra en la Figura 121, utilizando como equipamiento el equipo de ultrasonidos Matec PR5000 con un transductor de 5MHz. Con el objetivo de realizar un análisis de la primera capa del intónaco de mortero situado a una profundidad de 0.3cm.




Figura 119. Representación temporal de las señales originales adquiridas en la Real Basílica de la Virgen de los Desamparados de Valencia




Figura 120. Representación gráfica de las señales adquiridas en la Real Basílica de la Virgen de los Desamparados de Valencia




Figura 121. Densidad espectral de potencia media de las señales en comparación con la DEP del pulso de 5 MHz limpio y zona de trabajo, en la Basílica.

4.7.2.1 Utilizando el algoritmo trivial

Los resultados obtenidos utilizando el algoritmo que hemos denominado trivial con preblanqueo son los que se muestran en la Figura 122 y en la Figura 123, utilizando los siguientes parámetros: $m_0=0$ (todos deben detectar), $solape=1$ (muestra a muestra), $nm=30$ (nº de muestras), $fact_norma_L=20$ (de forma que $TamFFT=20 \cdot L$ y por lo tanto interpolando) y $L=7$ (nº de detectores).

Utilizando como $frec_transd=4,7\text{MHz}$ en vez de los 5MHz nominales, ya que realmente el transductor utilizado tiene su máxima ganancia a esta frecuencia y un $Ancho_transd=500\text{KHz}$.

Eligiendo como $PFA_r=0.01$, con un umbral de 2.576 (tras multitud de experimentos) para tener máxima detectabilidad, y poder llegar a discernir los ecos de las capas buscadas aunque aparezcan falsas alarmas.




Figura 122. Representación de las detecciones obtenidas en la Basílica con el algoritmo trivial




Figura 123. Representación gráfica de las detecciones con el algoritmo trivial en la Basílica

De los resultados obtenidos con el trivial, se puede ver cómo somos capaces de detectar el 3º eco de la primera capa del intónaco situada a unos $11.25\mu\text{s}$ (0.9cm). No siendo capaces de ver más allá del centímetro de profundidad debido a las grandes atenuaciones sufridas por la señal al ir penetrando en este material tan inhomogéneo.

Por otro lado, se puede observar que no somos capaces de detectar el primer eco debido que aparece en la zona “muerta” inicial en que el receptor no recibe para evitar la recepción directa desde el emisor, ni tampoco el segundo eco ya que debería aparecer alrededor de los $7.5\mu\text{s}$ (0.6cm) y en esta zona hay gran multitud de ecos debidos al ruido.

4.7.2.2 Utilizando el algoritmo SSDD

Los resultados obtenidos utilizando el algoritmo *SSDD* son los que se muestran en la Figura 124 y en la Figura 125, en los que hemos utilizado los siguientes parámetros: $m_0=0$ (todos deben detectar), $solape=1$ (muestra a muestra), $nm=20$ (nº de muestras), $fact_norma_L=2$ y $L=8$ (nº de detectores).

Con $frec_transd=4,7\text{MHz}$ y $Ancho_transd=9\text{MHz}$ ya que en este caso es más conveniente interpolar lo mínimo posible ampliando el ancho de banda de trabajo para mantener un número de detectores L aproximadamente igual que en los casos anteriores.

Al cambiar sensiblemente los parámetros utilizados hemos cambiado también la $PFA_r=0.001$, con un umbral de 1.726 (tras multitud de experimentos) con el mismo objetivo de siempre de tener máxima detectabilidad.




Figura 124. Representación de las detecciones obtenidas en la Basílica con el algoritmo SSDD

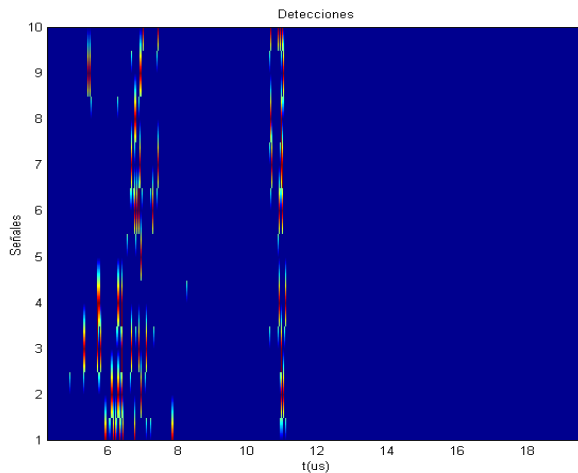


Figura 125. Representación gráfica de las detecciones con el algoritmo SSDD en la Basílica

En este caso, con el *SSDD*, se obtienen resultados parecidos a los obtenidos con el algoritmo trivial fijando una PFA_t , menor perfilándose mejor el tercer eco de la primera capa del intónaco.

4.7.2.3 Utilizando el algoritmo *NSSDD*

Los resultados obtenidos utilizando el algoritmo que *NSSDD* son los que se muestran en la Figura 126 y en la Figura 127, con los parámetros: $m_0=2$ (todos deben detectar salvo 2), $solape=1$ (muestra a muestra), $nm=20$ (n° de muestras), $fact_norma_L=2$ (de forma que $TamFFT=2\cdot L$) y $L=8$ (n° de detectores). Utilizando como $frec_transd=4,7MHz$ y un $Ancho_transd=9MHz$.

Eligiendo como $PFA_t=3.5e-4$, con un umbral de 0.8 para poder tener máxima detectabilidad, y poder llegar a discernir los ecos de las capas buscadas aunque aparezcan algunas falsas alarmas.




Figura 126. Representación de las detecciones obtenidas en la Basílica con el algoritmo *NSSDD*




Figura 127 Representación gráfica de las detecciones con el algoritmo *NSSDD* en la Basílica

Observando los resultados obtenidos en el caso del *NSSDD* se puede concluir que seguimos detectando el tercer eco del intónaco (sobre los $11\mu\text{s}$), aunque no con tanta claridad como en los algoritmos anteriores al reducir las falsas alarmas permitidas.

El disponer de sólo 10 realizaciones impide obtener conclusiones consistentes sobre los algoritmos experimentados, que, en todo caso, parecen ser capaces de perfilar razonablemente el interfaz entre la 1ª capa de mortero y la siguiente capa de yeso a partir del 3º eco. Por ello, como ya hemos comentado procedimos a completar el trabajo en un modelo a escala de una parte de la bóveda, ubicada en la UPV, tal y como se describe a continuación.

4.7.3 Resultados obtenidos en el modelo a escala de la Real Basílica de la Virgen de los Desamparados.

El modelo arquitectónico a escala real de un área de la cúpula de la Real Basílica de la Virgen de los Desamparados de Valencia utilizado se muestra en la Figura 128 y Figura 129, sobre el cual existe información disponible acerca de su estructura interna y del patrón de materiales.

Las dimensiones del modelo son de: 2.5m de ancho, 2m de alto, 0.5m de grueso, y exhibe una curva convexa en su pared como en la pared de la cúpula.



Figura 128. Fotografía del modelo a escala



Figura 129. Fotografía de la realización de una medida ultrasónica sobre el modelo a escala

Un detalle de una medida tomada sobre una línea de la malla se muestra en la Figura 130.



Figura 130. Detalle de la toma de una medida sobre el mallado en el modelo a escala

A través de esta línea recta, se han realizado 74 medidas equi-espaciadas para distinguir las zonas anómalas, como se indicará más adelante.

Una vez hecho un estudio exhaustivo en el laboratorio [60] sobre una serie de catas de las distintas capas de los materiales utilizados en este modelo, con el fin de determinar con precisión las distintas velocidades de propagación, es el momento de realizar el estudio de los resultados que se obtienen al aplicar los algoritmos de split-spectrum a las señales capturadas en el modelo a escala de la Basílica.

Para ello se realizó un mallado de medidas de 37 posiciones siguiendo una línea recta vertical con una separación de 4cm entre medidas, numeradas de arriba a abajo del modelo, acomodando dos mediciones en cada posición debido al pequeño tamaño del transductor de 5MHz. Por lo que se han hecho un total de 74 mediciones a través de las 37 posiciones del mallado, como puede verse en la Figura 131.

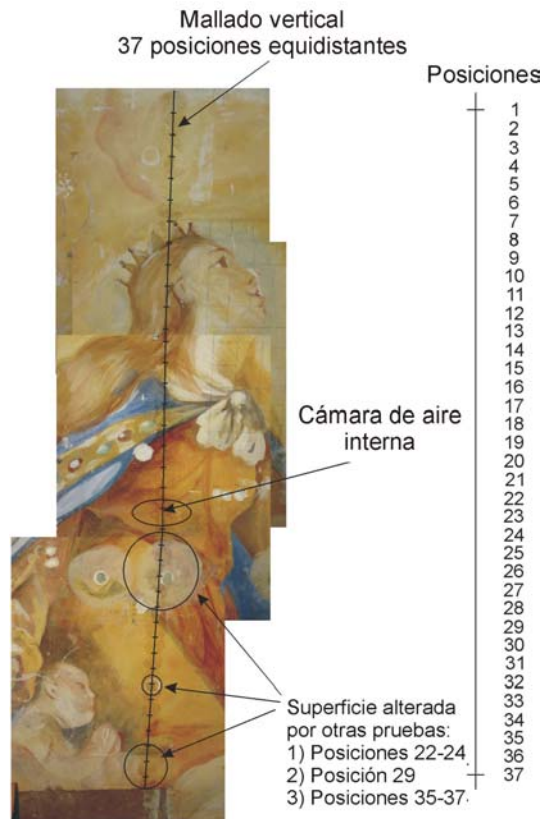


Figura 131. Composición fotográfica de la zona analizada en el modelo a escala

Por lo tanto se trabajó con 74 señales adquiridas (dos por cada posición) en el modelo a escala de la cúpula de la Real Basílica de la Virgen de los Desamparados de Valencia, concretamente con las señales descritas en la Figura 132, cuya densidad espectral de potencia media es la mostrada en la Figura 133.




Figura 132. Representación gráfica de las señales adquiridas en el modelo a escala de la Real Basílica de la Virgen de los Desamparados de Valencia

En esta Figura 132 hemos superpuesto, con unas líneas verticales, las zonas donde debemos obtener detección, concretamente el segundo y tercer eco de la 1ª capa del intónaco de mortero situado a $0.3 \times 2 \text{ cm} = 0.6 \text{ cm}$ (alrededor de los $7.5 \mu\text{s}$) y $0.3 \times 3 \text{ cm} = 0.9 \text{ cm}$ (alrededor de los $11 \mu\text{s}$).

Por otro lado cabe destacar que el mallado utilizado cruza zonas con anomalías superficiales que se deben tener en cuenta a la hora de interpretar los resultados obtenidos, concretamente aparecen tres zonas con un menor nivel de señal debido a estas anomalías (de abajo a arriba): una zona inicial (señales 1 y 2), una zona central amplia (señales 45 a la 51) y una zona final (señales 71 a 74).




Figura 133. Densidad espectral de potencia media de las señales en comparación con la DEP del pulso de 5 MHz limpio y zona de trabajo, en el modelo a escala de la Basílica.

4.7.3.1 Resultados utilizando el algoritmo trivial

Los resultados obtenidos utilizando el algoritmo trivial son los que se muestran en la Figura 134 y Figura 135 utilizando los siguientes parámetros: $m_0=0$ (todos deben detectar), $solape=1$ (muestra a muestra), $nm=20$ (nº de muestras), $fact_norma_L=20$ (de forma que $TamFFT=20 \cdot L$ y por lo tanto interpolando) y $L=11$ (nº de detectores). Utilizando como $frec_transd=4,725MHz$ y un $Ancho_transd=500KHz$.

Eligiendo como $PFA_r=0.001$, con un umbral de 3.291 (tras muchas pruebas) permitiendo tener máxima detectabilidad, y poder llegar a discernir los ecos de las capas buscadas.




Figura 134. Representación gráfica de las detecciones con el algoritmo trivial en el modelo a escala de la Basílica




Figura 135. Representación gráfica de la señal procesada mostrando el valor absoluto de la muestra central donde ha habido detección, con el algoritmo trivial, en el modelo a escala de la Basílica

Donde podemos observar con el algoritmo trivial, que somos capaces de detectar dos nubes de puntos:

- La primera alrededor de los 7 μ s, correspondiente al 2º eco de la 1ª capa del material
- La segunda alrededor de los 11 μ s, correspondiente al 3º eco de la 1ª capa del intónaco

4.7.3.2 Resultados utilizando el algoritmo SSDD

Los resultados obtenidos utilizando el algoritmo *SSDD* son los que se muestran en la Figura 136 y Figura 137 utilizando los siguientes parámetros: $m_0=1$ (todos deben detectar menos uno), $solape=1$ (muestra a muestra), $nm=50$ (nº de muestras), $fact_norma_L=1$ (de forma que $TamFFT=L$ y por lo tanto sin interpolar) y $L=6$ (nº de detectores).

Utilizando como $frec_transd=4,7MHz$ $Ancho_transd=9MHz$ ya que en este caso es más conveniente interpolar lo mínimo posible ampliando el ancho de banda de trabajo para mantener un número de detectores L aproximadamente igual al utilizado en el caso anterior.

Eligiendo como $PFA_r=0.0001$, con un umbral de 4.361 (tras multitud de experimentos) para tener máxima detectabilidad, y poder llegar a discernir los ecos de las capas buscadas aunque aparezcan falsas alarmas.




Figura 136. Representación gráfica de las detecciones con el algoritmo SSDD en el modelo a escala de la Basílica




Figura 137. Representación gráfica de la señal procesada mostrando el valor absoluto de la muestra central donde ha habido detección, con el algoritmo SSDD, en el modelo a escala de la Basílica

Con el algoritmo implementado *SSDD*, de nuevo conseguimos detectar los dos ecos, aunque en este caso, mucho mejor el 3º eco de la primera capa del intónaco sobre los 11 us.

4.7.3.3 Resultados utilizando el algoritmo *NSSDD*

Los resultados obtenidos utilizando el algoritmo *NSSDD* son los que se muestran en la Figura 138 y en la Figura 139, utilizando los mismos parámetros que en el caso anterior: $m_0=1$ (todos deben detectar menos uno), $solape=1$ (muestra a muestra), $nm=50$ (nº de muestras), $fact_norma_L=1$ (de forma que $TamFFT=L$ y por lo tanto sin interpolar) y $L=6$ (nº de detectores). Utilizando como $frec_transd=4,7MHz$ $Ancho_transd=9MHz$.

Eligiendo como $PFA_r=0.019$, con un umbral de 0.5 (tras multitud de experimentos) para tener máxima detectabilidad, y poder llegar a discernir los ecos de las capas buscadas aunque aparezcan falsas alarmas.




Figura 138. Representación gráfica de las detecciones con el algoritmo NSSDD en el modelo a escala de la Basílica




Figura 139. Representación gráfica de la señal procesada mostrando el valor absoluto de la muestra central donde ha habido detección, con el algoritmo NSSDD, en el modelo a escala de la Basílica

Finalmente con el algoritmo NSSDD, vislumbramos, aproximadamente, los dos ecos de la primera capa, aunque, eso sí, con muchas más falsas alarmas.

Con los tres algoritmos probados, detectamos el perfil correspondiente a la tercera reflexión, sin embargo la segunda reflexión está demasiado corrompida por los múltiples ecos de la superficie y del interior como para poder reconstruir el perfil. La cuarta posible reflexión parece estar demasiado atenuada como para aparecer.

Aparentemente, los mejores resultados se obtienen con el algoritmo *SSDD*, seguido del detector trivial y el *NSSDD*. Sorprendentemente, el *NSSDD* parece tener el mayor número de falsas alarmas, lo que entra en contradicción con el mejor rendimiento que indica la teoría y habían predicho las simulaciones. Pero se ha de tener en cuenta que el mortero es un material compuesto por arena y pasta de cemento, en los cuales, dos partes esenciales de su micro estructura son poros de aire (de un tamaño que puede variar desde los 10^{-10} a los 10^{-4} m) y granos de arena (de un tamaño entre 10^{-4} y 10^{-3} m).

La velocidad de propagación en este tipo de mortero ya ha sido estimada anteriormente obteniéndose un valor de $c = \frac{d}{t} = \frac{0.3 \cdot 10^{-2}}{1.92 \cdot 10^{-6}} = 1562,5 \text{ m/s}$.

Por lo que podemos estimar ahora la longitud de onda correspondiente al transductor utilizado de 5 MHz de frecuencia central, obteniendo un valor de $\lambda = \frac{c}{f} = \frac{1562.5}{5 \cdot 10^6} = 0,312 \cdot 10^{-3} \text{ m}$ que resulta ser del mismo orden de magnitud que los granos de arena. Por esta razón, en este caso, junto a la microestructura del ruido de grano tenemos ecos aislados debidos a los granos de arena. Además con los 5 MHz de frecuencia de trabajo, somos sensibles a las irregularidades superficiales que añaden más ecos aislados a la señal recogida. Como el algoritmo *NSSDD* es independiente del nivel de señal, éste es capaz de detectar no sólo los ecos debidos a la interfase buscada sino también los ecos debidos a los granos de arena y a las irregularidades superficiales. Por otro lado, el algoritmo *SSDD* y el detector trivial sí son sensibles al nivel de señal por lo que filtran muchos de los ecos aislados que no superan el umbral prefijado. En este sentido se puede decir que el *NSSDD* no tiene más falsas alarmas, sino muchas más detecciones indeseadas.

4.8 Conclusiones

Para finalizar este capítulo 4 de la aplicación a sistemas de inspección ultrasónica vamos a resumir las principales conclusiones a las que hemos llegado. Realizando previamente una síntesis de las tareas realizadas.

4.8.1 Síntesis del capítulo

Se han desarrollado unos nuevos **algoritmos de split-spectrum utilizando detección distribuida (SSDD)**, adecuados para la detección automática de pulsos, los cuales incluyen como caso particular los algoritmos de split-spectrum clásicos. En estos algoritmos hemos utilizado, como filtros paso banda, la transformada discreta de Fourier (DFT), en la que se puede suponer incorrelación entre las muestras, y se ha demostrado que son óptimos cuando la varianza del ruido de grano se reduce en presencia del pulso buscado y no es posible tener un conocimiento a priori de este pulso, que además supondremos, tiene toda su energía distribuida a lo largo de todos o muchos de los subespacios generados por los distintos filtros paso banda del algoritmo SSP.

Se ha propuesto, por tanto, un esquema robusto que funciona bajo diferentes modelos de los efectos que produce la presencia del pulso buscado, implementando un detector automático a la salida de cada filtro paso banda, que genera decisiones distribuidas y fusionando las decisiones locales distribuidas para tomar la decisión final. Para ello se ha desarrollado un estadístico que calcula la energía en el subespacio de cada filtro paso banda, el cual se compara con un umbral, lo que es equivalente a un filtro adaptado al subespacio, que es la solución óptima que maximiza la PD_i para una PFA_i dada, bajo la suposición de que la señal a detectar pertenece al correspondiente subespacio, lo que nos lleva a la primera restricción del esquema propuesto que es la de que el pulso buscado debe tener parte de su energía dentro de todos o algunos de los anchos de banda en frecuencia de los filtros paso banda.

Una vez diseñados los decisores locales, se ha diseñado la regla de fusión óptima, en la que se ha supuesto que las muestras están incorreladas si sólo hay ruido, apareciendo correlación entre las muestras cuando está presente el pulso buscado, lo cual se modela con el coeficiente de correlación ρ . Se obtienen las fórmulas generales de PFA_{final} y PD_{final} en función de los parámetros del modelo, L número de detectores locales, PFA y PD locales, m_0 número máximo de no detecciones permitidas y el coeficiente de correlación ρ .

A partir de las fórmulas obtenidas se han obtenido una serie de **curvas** que verifican el correcto funcionamiento de las expresiones, permitiendo comprobar que es posible obtener valores muy pequeños de PFA_{final} incluso para una PFA individual muy grande, eligiendo adecuadamente el parámetro m_0 . Para una PD dada, la máxima PD_{final} se obtiene para el caso incorrelado $\rho=0$, decreciendo monótonamente en función de la PD , siendo la $PD_{final}=PD$ en el caso de máxima

correlación $\rho=1$. Como la PD_{final} , habitualmente no es menor que la PD individual, la fusión de decisiones generará valores pequeños de PFA_{final} , dejando los valores de PD_{final} a unos niveles razonables, simplemente eligiendo adecuadamente el parámetro m_0 .

Cabe destacar el papel del filtro de preblanqueo utilizado en los algoritmos implementados, el cual introduce dos efectos simultáneos: por un lado normaliza la varianza del ruido de grano, y por otro lado expande la potencia media del ruido de grano a lo largo de todo el ancho de banda, aunque también modifica la distribución de energía del pulso buscado a lo largo del ancho de banda.

En este sentido se puede concluir con que el algoritmo propuesto *SSDD* funciona correctamente con una gran variedad de pulsos, sin restricciones en función de la polaridad u otro tipo de condiciones limitantes, excepto la condición de que debe tener suficiente energía en al menos $L - m_0$ de los subespacios utilizados.

Finalmente, antes de pasar al trabajo con señales simuladas y reales, se ha hecho una serie de comparativas entre el *SSDD* y el detector denominado trivial, que consiste sencillamente en comparar con el umbral las propias muestras de la secuencia original preblanqueada.

De estas comparativas se puede concluir que, para valores de falsa alarma por debajo de un cierto nivel, el algoritmo implementado *SSDD* tiene un mejor comportamiento que el trivial, considerando que las pruebas se han realizado en el caso más favorable para el detector trivial y menos favorable para el *SSDD*. Aunque también se deduce que el nivel del pulso buscado debe ser suficientemente elevado. El problema es que el asumido perfecto preblanqueo ensancha la energía del pulso a lo largo de los L canales del filtro, lo que implica la necesidad de elegir un umbral suficientemente pequeño, es decir, que el algoritmo *SSDD* asume que la presencia del pulso, inyecte suficiente energía en cada uno de los subespacios, pero es necesario un mínimo de energía en cada subespacio para garantizar la detección, sin tener unos valores de PFA_{final} demasiado elevados.

Por todo esto se sugiere la conveniencia de introducir algún tipo de normalización, llegando al segundo de los algoritmos implementados, el *SSDD* normalizado o *NSSDD*, donde cada valor de la energía de salida del filtro se divide por el máximo antes de la comparación con el umbral. Se comprueba con la generación de una serie de gráficas, una mejora en los resultados obtenidos respecto al algoritmo trivial y al *SSDD*.

Tras el estudio teórico y la elaboración de los algoritmos se han realizado una serie de **experimentos** con señales simuladas, para pasar posteriormente a trabajar con señales reales en laboratorio primero y finalmente con señales reales obtenidas de la aplicación de los ultrasonidos a los ensayos no destructivos de materiales en la restauración de edificios históricos.

Respecto a los experimentos con señales simuladas, cabe destacar que se han realizado una serie de **simulaciones** para controlar la *PFA* y analizar la detección y con distintos pulsos simulados:

- En cuanto al control de la *PFA*, se ha utilizado un pulso buscado simulado con un espectro plano en la banda de trabajo, generándose la matriz de autocorrelaciones para el preblanqueo y el ruido coloreado. Se obtienen unos resultados altamente satisfactorios que comprueban cómo somos capaces de seguir fielmente, con simulaciones, las curvas teóricas de PFA_{final} en función de la *PFA* individual para distintos valores de m_0 .
- En cuanto al análisis de la detección, se han generado curvas ROC para los diferentes algoritmos implementados, comparándolos con el trivial, obteniéndose los mejores resultados con el *NSSDD* seguido del trivial y finalmente el *SSDD*. Estos resultados se justifican por la presencia de una pequeña cantidad de ruido de grano sobre el pulso buscado, que provoca una rápida degradación del rendimiento del algoritmo *SSDD*, y que parece no afectar demasiado al *NSSDD*.
- En cuanto a la detección con señales simuladas, se han realizado diversas pruebas:
 - Primero utilizándose como pulso buscado, el mismo del control de la *PFA*, sobre un ruido de fondo coloreado. Se comprueba cómo con el *SSDD* somos capaces de detectar el pulso oculto para una cierta *SNR* y con el *NSSDD* también, incluso reduciendo la *SNR* drásticamente.
 - Segundo, utilizándose como pulso buscado y ruido coloreado, un pulso ultrasónico real de 5 MHz. Se comprueba cómo el *SSDD* es capaz de detectar el pulso buscado donde se ha añadido al ruido coloreado, cuando a simple vista no es fácil de reconocer, mientras que con el *NSSDD*, también se detecta aunque con alguna falsa alarma debida a que el pulso utilizado no tiene un espectro totalmente plano en la banda de paso.
 - Tercero, procesando una serie de señales de ruido coloreado con distintos pulsos buscados con espectro plano, distribuidos aleatoriamente, obteniendo muy buenos resultados con el *NSSDD*, con una *PD* del 97% y una *PFA* de 10^{-4} que coincide con la *PFA* fijada. Sin embargo para esta *PFA*, ni el trivial ni el *SSDD* consiguen buenos resultados.
 - Cuarto, generándose una serie de pruebas más exhaustivas, donde se comprueba la *PD* en función de la *PFA* con diferentes *SNR*, obteniendo buenos resultados con los tres algoritmos cuando la *SNR* es alta, pero empeorando los resultados al reducir la *SNR* (de forma que el pulso buscado ya no sobresale del ruido), salvo en el caso del *NSSDD* que mantiene unos buenos resultados por delante del trivial y el *SSDD*. Se verifica el resultado obtenido en el análisis de la detección, respecto al empeoramiento del *SSDD*, al aparecer una pequeña cantidad de ruido de grano sobre el pulso a buscar.

- Quinto, generándose las mismas pruebas exhaustivas anteriores pero con el pulso buscado real ultrasónico de 5 MHz, donde se obtienen buenos resultados con el *NSSDD* y el trivial y muy malos con el *SSDD*.

Finalmente hemos trabajado con señales reales, primero en el laboratorio utilizando la mesa *XY*, y una probeta de **duraluminio** con un defecto conocido, obteniendo los mejores resultados con el *SSDD*, a continuación con el *NSSDD* y finalmente con el trivial. Para continuar con el trabajo en los ensayos no destructivos de materiales con ultrasonidos aplicados a la restauración de edificios históricos, concretamente para el cálculo del espesor de capas de materiales internos de la cúpula de la Real **Basilica** de la Virgen de los Desamparados de Valencia, siendo capaces de detectar la primera capa, más superficial, de la zona de trabajo, alrededor de los 0.3 cm de profundidad y de penetrar hasta 1 cm de profundidad.

4.8.2 Conclusiones finales

Sobre los aspectos teóricos

Hemos propuesto un nuevo esquema de detección automática de ecos ultrasónicos en fondo de ruido granular basado en incorporar la detección distribuida en los algoritmos “split-spectrum”. El nuevo esquema y el estudio realizado en relación con el mismo, suponen algunas aportaciones interesantes en este ámbito:

- Disponer de algoritmos split-spectrum con detección óptima y ajuste de *PFA*
- Entender mejor las limitaciones de los algoritmos split-spectrum existentes, ya que son casos particulares del esquema genérico propuesto.
- En particular hemos comprobado que la reducción del ruido granular en presencia del eco a detectar, es un elemento clave para el buen funcionamiento de estos algoritmos, que de otra forma difícilmente pueden competir con un simple detector de umbral
- Hemos verificado que incorporar una etapa de preblanqueo es sustancial con la optimización del detector y puede ser una mejora importante incluso en el detector que hemos denominado trivial: preblanqueo y umbral.
- Nuevamente, hemos mostrado que el filtro adaptado en subespacio, es una herramienta potente para abordar este tipo de problemas, explotando la equivalencia formal entre filtro (paso banda) sintonizado y subespacio (paso banda) sintonizado.

Sobre las simulaciones

Hemos considerado la realización de una serie de simulaciones para controlar la *PFA*, analizar la detección y detectar con distintos pulsos simulados. Hemos trabajado básicamente con dos pulsos, un primer pulso con espectro aproximadamente plano en la banda de paso de trabajo, y un segundo pulso, tomado de una señal real ultrasónica de 5 MHz.

Los resultados obtenidos respecto al control de la *PFA* y el análisis de la detección con curvas *ROC* son altamente satisfactorios comprobando la capacidad de seguimiento de las simulaciones respecto a las curvas teóricas y consiguiendo mejores resultados con el *NSSDD*, seguido del *SSDD* y el trivial.

En cuanto a los resultados obtenidos con los pulsos simulados se ha podido comprobar el correcto funcionamiento de los algoritmos implementados, siendo el *NSSDD* mejor en el caso de que la *SNR* se reduzca drásticamente y empeorando el *SSDD* si el pulso está inmerso en ruido, por lo que se concluye que el *SSDD* está bastante limitado para su uso en tareas donde se prime la detección automática de pulsos cuya característica fundamental sea su uniformidad espectral, más que un nivel de energía importante en cada uno de los detectores sintonizados, donde el *NSSDD* sí que funciona de manera correcta.

Sobre las experiencias con señales reales

Hemos considerado dos experimentos con señales reales. El primero, realizado en laboratorio con probetas de aluminio, ha permitido comprobar la capacidad de los algoritmos propuestos para detectar defectos. El segundo experimento se ha realizado en el marco de investigaciones encaminadas a apoyar a los restauradores de bóvedas de monumentos históricos, mediante ensayos no destructivos por ultrasonidos. En particular hemos aplicado las técnicas propuestas a la obtención del perfil de interfaz entre la primera y segunda capas de la bóveda de la Virgen de los Desamparados de Valencia, demostrando que la aplicación de los tres detectores propuestos permite visualizar el perfil buscado, cosa imposible en las señales originales.

Ha resultado significativo comprobar cómo el algoritmo *SSDD* es el que mejores resultados ha proporcionado con señales reales, si bien el *NSSDD* era el mejor en la teoría y en las simulaciones. El aparente peor comportamiento del *NSSDD* puede explicarse por la propia gran sensibilidad de este último algoritmo ante la presencia de ecos aislados, incluso de bajo nivel, ya que de hecho es un algoritmo independiente del nivel de la señal bajo análisis. Muchas de las aparentes falsas alarmas generadas deben interpretarse realmente como “detecciones no deseadas” pero esencialmente correctas: si son debidas a ecos aislados, estrictamente no son ruido de grano, ya que este último, desde el punto de vista de los modelos de señal y ruido, está definido como una superposición de ecos pequeños.

Apéndices

Apéndice A

Consideremos la solución óptima para el modelo definido en la ecuación (172). Necesitaremos las funciones de densidad de probabilidad, bajo las dos hipótesis, para generar el razón de verosimilitud logarítmica:

$$\begin{aligned} \ln \Lambda(\mathbf{r}) &= \ln \frac{f_1(\mathbf{r})}{f_2(\mathbf{r})} = \ln \frac{\sigma_{g1}^L}{\sigma_{g0}^L} - \frac{1}{2\sigma_{g0}^2} (\mathbf{r} - \mathbf{p})^T \mathbf{D}_g^{-1} (\mathbf{r} - \mathbf{p}) + \frac{1}{2\sigma_{g1}^2} \mathbf{r}^T \mathbf{D}_g^{-1} \mathbf{r} \cong \\ &\cong \ln \frac{\sigma_{g1}^L}{\sigma_{g0}^L} - \frac{1}{2\sigma_{g0}^2} (\mathbf{r} - \mathbf{p})^T \mathbf{D}_g^{-1} (\mathbf{r} - \mathbf{p}) \end{aligned} \quad (\text{A.1})$$

Donde ya hemos utilizado el hecho de que $\sigma_{g0}^2 \ll \sigma_{g1}^2$. Por lo que el test se puede escribir de la siguiente forma:

$$\ln \Lambda(\mathbf{r}) \underset{>}{<} \ln \lambda \quad \Leftrightarrow \quad -(\mathbf{r} - \mathbf{p})^T \mathbf{C}_{g1}^{-1} (\mathbf{r} - \mathbf{p}) \underset{>}{<} 2 \frac{\sigma_{g0}^2}{\sigma_{g1}^2} \cdot \ln \lambda \frac{\sigma_{g0}^L}{\sigma_{g1}^L} = t \quad (\text{A.2})$$

Donde hemos preferido expresar el estadístico en función de \mathbf{C}_{g1} , debido a que la matriz de covarianza del ruido de grano bajo la hipótesis H_1 , puede ser estimada a partir de muestras de entrenamiento.

Apéndice B

Consideremos ahora el caso de utilizar la transformada discreta de Fourier (DFT) para implementar los filtros paso banda:

$$\mathbf{h}_i = \begin{bmatrix} 1 & e^{-j\frac{2\pi}{N}i} & e^{-j\frac{2\pi}{N}i \cdot 2} & \dots & e^{-j\frac{2\pi}{N}i \cdot (N-1)} \end{bmatrix}^T = \mathbf{e}_i \quad (\text{B. 1})$$

Si llamamos $\mathbf{w} = \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{g}$, a la componente de ruido de grano preblanqueado de \mathbf{r} , y tenemos en cuenta que $\mathbf{e}_i^H \mathbf{e}_i = N$, bajo la hipótesis H_1 tenemos:

$$\frac{\mathbf{r}^H \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{h}_i \mathbf{h}_i^H \mathbf{C}_{g1}^{-\frac{1}{2}} \mathbf{r}}{\mathbf{h}_i^H \mathbf{h}_i} = \frac{\mathbf{w}^H \mathbf{e}_i \mathbf{e}_i^H \mathbf{w}}{N} \quad (\text{B. 2})$$

Considerando ahora, separadamente, las partes reales e imaginarias del vector \mathbf{e}_i (teniendo en cuenta que \mathbf{w} es un vector real)

$$\mathbf{w}^H \mathbf{e}_i \mathbf{e}_i^H \mathbf{w} = (\mathbf{w}^T \mathbf{e}_{iR} + j \mathbf{w}^T \mathbf{e}_{iI}) \cdot (\mathbf{e}_{iR}^T \mathbf{w} - j \mathbf{e}_{iI}^T \mathbf{w}) = \mathbf{w}^T \mathbf{e}_{iR} \mathbf{e}_{iR}^T \mathbf{w} + \mathbf{w}^T \mathbf{e}_{iI} \mathbf{e}_{iI}^T \mathbf{w} \quad (\text{B. 3})$$

Donde podemos hacer la simplificación ya que la parte imaginaria de la parte cuadrática es cero.

Por otro lado tenemos que:

$$\begin{aligned} \mathbf{e}_{iR}^T \mathbf{e}_{iR} &= \sum_{n=0}^{N-1} \sin^2 \frac{2\pi}{N} kn = \sum_{n=0}^{N-1} \frac{1}{2} \left(1 - \cos 2 \cdot \frac{2\pi}{N} kn \right) = \frac{N}{2} - \sum_{n=0}^{N-1} \frac{1}{4} \left(e^{j2\frac{2\pi}{N}kn} + e^{-j2\frac{2\pi}{N}kn} \right) = \\ &= \frac{N}{2} - \frac{1}{4} \left(\frac{1 - e^{j2\frac{2\pi}{N}kN}}{1 - e^{j2\frac{2\pi}{N}kn}} + \frac{1 - e^{-j2\frac{2\pi}{N}kN}}{1 - e^{-j2\frac{2\pi}{N}kn}} \right) = \frac{N}{2} \end{aligned} \quad (\text{B. 4})$$

$$\text{Y además } \mathbf{e}_{iI}^T \mathbf{e}_{iI} = \mathbf{e}_i^H \mathbf{e}_i - \mathbf{e}_{iR}^T \mathbf{e}_{iR} = \frac{N}{2}$$

Por lo que finalmente podemos expresar (B. 3) de la siguiente forma:

$$\begin{aligned} \frac{\mathbf{w}^H \mathbf{e}_i \mathbf{e}_i^H \mathbf{w}}{N} &= \frac{\mathbf{w}^T \mathbf{e}_{iR} \mathbf{e}_{iR}^T \mathbf{w} + \mathbf{w}^T \mathbf{e}_{iI} \mathbf{e}_{iI}^T \mathbf{w}}{N} = 2 \cdot \left(\frac{\mathbf{w}^T \mathbf{e}_{iR} \mathbf{e}_{iR}^T \mathbf{w}}{N/2} + \frac{\mathbf{w}^T \mathbf{e}_{iI} \mathbf{e}_{iI}^T \mathbf{w}}{N/2} \right) = \\ &2 \cdot \left(\frac{\mathbf{w}^T \mathbf{e}_{iR} \mathbf{e}_{iR}^T \mathbf{w}}{\mathbf{e}_{iR}^T \mathbf{e}_{iR}} + \frac{\mathbf{w}^T \mathbf{e}_{iI} \mathbf{e}_{iI}^T \mathbf{w}}{\mathbf{e}_{iI}^T \mathbf{e}_{iI}} \right) \end{aligned} \quad (\text{B. 5})$$

Donde cada término por separado, de la suma de (B. 5), bajo la hipótesis H_1 , sigue una distribución de tipo chi-cuadrado con un grado de libertad (ver ejemplo en [51]), y la suma de ambos términos permite seguir una distribución chi-cuadrado con dos grados de libertad.

Apéndice C

Llamando $x_i = 2 \cdot \frac{\mathbf{r}^H \mathbf{C}_{g_i}^{-\frac{1}{2}} \mathbf{h}_i \mathbf{h}_i^H \mathbf{C}_{g_i}^{-\frac{1}{2}} \mathbf{r}}{\mathbf{h}_i^H \mathbf{h}_i}$, tenemos, como hemos podido demostrar en el apéndice B, que bajo la hipótesis H_i , x_i es una variable aleatoria con una distribución de tipo chi-cuadrado con dos grados de libertad.

Para facilidad en la notación, llamaremos a partir de ahora, $x_i \equiv X$, por lo que la función de densidad de probabilidad (pdf) y la función de distribución acumulativa (cdf) de X son:

$$f_X(x) = \frac{1}{2} e^{-\frac{x}{2}} u(x); \quad F_X(x) = \left(1 - e^{-\frac{x}{2}} \right) \tag{C.1}$$

Donde $u(\cdot)$ es la función escalón.

Nosotros deseamos averiguar la pdf correspondiente a la variable aleatoria $Z = \frac{X}{\max(X_1 \dots X_L)}$. Por lo que llamando $Y = \max(X_1 \dots X_L)$. Tenemos que

$f_Z(z) = \int_{-\infty}^{\infty} f_Z(z/y) f_Y(y) dy$, pero $f_Z(z/y) = |y| \cdot f_X(yz/y)$, por lo que $Z = \frac{X}{y}$ es precisamente una versión escalada de X . Por lo que podemos escribir:

$$f_Z(z) = \int_{-\infty}^{\infty} |y| \cdot f_X(yz/y) f_Y(y) dy = \int_{-\infty}^{\infty} |y| \cdot f_{XY}(yz, y) dy = \int_{-\infty}^{\infty} |y| \cdot f_X(yz) f_Y(y) dy \tag{C.2}$$

Donde asumimos independencia entre X e Y . Como la variable aleatoria X coincide con uno de los valores donde hemos seleccionado el máximo, la independencia entre X e Y no es estrictamente cierta, pero puede ser una buena aproximación para grandes valores de L (ver Figura C.1), por lo que, prosiguiendo ahora desde (C.2) tenemos:

Donde es bien conocido [20] que, si las variables aleatorias $\{X_i\} \ i = 1 \dots L$, son independientes (una hipótesis correcta bajo H_i), entonces:

$$f_Y(y) = L \cdot F_X^{L-1}(y) f_X(y) = L \cdot \left(1 - e^{-\frac{1}{2}y} \right)^{L-1} \cdot \frac{1}{2} e^{-\frac{1}{2}y} u(y) \tag{C.3}$$

Por lo que podemos escribir:

$$f_Z(z) = \frac{L}{4} \cdot \int_0^{\infty} y \cdot e^{-\frac{yz}{2}} \left(1 - e^{-\frac{y}{2}} \right)^{L-1} e^{-\frac{y}{2}} dy = \frac{L}{4} \cdot \int_0^{\infty} y \cdot e^{-\frac{y}{2}(z+1)} \left(1 - e^{-\frac{y}{2}} \right)^{L-1} dy \quad z > 0 \tag{C.4}$$

Ahora utilizaremos el hecho de que $\left(1 - e^{-\frac{y}{2}}\right)^{L-1} = \sum_{k=0}^{L-1} \binom{L-1}{k} \left(-e^{-\frac{y}{2}}\right)^k$, obteniendo la siguiente expresión:

$$f_z(z) = \frac{L}{4} \cdot \sum_{k=0}^{L-1} (-1)^k \binom{L-1}{k} \int_0^\infty y \cdot e^{-\frac{y}{2}(z+1)} e^{-\frac{y}{2}k} dy = \left[L \cdot \sum_{k=0}^{L-1} (-1)^k \binom{L-1}{k} (z+1+k)^{-2} \right] u(z) \quad (C. 5)$$

De donde podemos obtener la PFA correspondiente a un cierto umbral dado t_i , haciendo la integral de $f_z(z)$

$$\begin{aligned} PFA(t_i) &= \int_{t_i}^\infty f_z(z) dz = L \cdot \sum_{k=0}^{L-1} (-1)^k \binom{L-1}{k} \int_{t_i}^\infty (z+1+k)^{-2} dz = \\ &= L \cdot \sum_{k=0}^{L-1} (-1)^k \binom{L-1}{k} (t_i+1+k)^{-1} \end{aligned} \quad (C. 6)$$

En la Figura C.1 podemos observar el resultado de desarrollar la expresión de la $PFA(t_i)$ para unos valores del umbral $0 < t_i < 1$, y para distintos valores de L incrementales.




Figura C.1. PFA en función del umbral para diferentes valores de L .

Podemos observar como, la aproximación de independencia se va haciendo cada vez más cierta a medida que aumentamos el valor de L , así como el valor de la $PFA(1)$ es siempre cero, ya que el valor normalizado no puede ser nunca mayor que 1.

CAPÍTULO 5:

Conclusiones y líneas futuras



Capítulo 5: Conclusiones y líneas futuras de investigación

5.1 Conclusiones por capítulos

Reproducimos a continuación las síntesis y conclusiones a las que hemos llegado en cada capítulo.

5.1.1 Fusión de decisiones

Respecto al estudio teórico realizado sobre la **fusión de decisiones**, la síntesis final a la que hemos llegado es:

- Tras comentar el concepto de fusión de datos, su modelo general, aplicaciones y arquitecturas, se han descrito los fundamentos de la detección distribuida con sensores múltiples desde el punto de vista de Neyman-Pearson y desde el punto de vista de la formulación Bayesiana.
- A continuación se ha tratado la detección distribuida y fusión de decisiones óptima en sistemas con múltiples sensores **incorrelados**.
- Se ha pasado finalmente, a la parte teórica fundamental de la tesis, que es el estudio de las diversas técnicas de detección distribuida con decisiones **correladas**, que son las que utilizaremos al aplicar las técnicas de filtro adaptado al subespacio sobre un único sensor:
 - Ilustrándose el caso general, eligiendo el esquema sub-óptimo tipo paralelo con central de fusión, y estudiando las diferentes estrategias de fusión posibles, tipo OR, tipo AND o de la mayoría.
 - Comentándose la fusión óptima si las reglas de decisión y las correlaciones locales se conocen, demostrándose que las reglas óptimas de fusión requieren únicamente, para cada subconjunto de decisiones locales, que la probabilidad de cada decisión local sea positiva, es decir, que exista señal.
 - Concluyendo con un modelo de correlación catalogado mediante la razón de correlación, que va desde decisiones locales mutuamente independientes hasta decisiones locales con dependencia máxima, mostrando que el rendimiento de la regla de fusión se degrada cuando el grado de correlación aumenta y que la ventaja en el rendimiento, al utilizar un gran número de detectores locales, disminuye cuando se incrementa la correlación entre ellos.

Conclusiones finales

Por lo tanto, y para finalizar, se comprueba que hemos realizado un estudio exhaustivo de los diferentes algoritmos de detección distribuida. Donde, como se ha podido observar, que un elemento clave es la posibilidad o no de asumir incorrelación entre las decisiones. Cuando tal cosa es posible, todos los algoritmos se simplifican, y esencialmente se vuelven equivalentes.

Al enfocar nuestra tesis hacia aplicaciones concretas, consideramos fundamental analizar si la hipótesis de incorrelación es razonable, y si no lo es, elegiremos la forma más simple de incluir su efecto en las correspondientes ecuaciones. Pensamos que muchas de las técnicas anteriormente expuestas aportan en general una mejora relativamente pequeña a los algoritmos de fusión, a cambio de incrementar notablemente su complejidad. No obstante consideramos de interés la revisión realizada, y oportuna su inclusión en este capítulo previo a las aplicaciones. Como veremos, haremos sobre todo uso del trabajo expuesto en [20], ya que aporta soluciones relativamente simples para el caso de la correlación, de fácil particularización cuando asumir incorrelación es razonable.

5.1.2 Aplicación de incendios

Respecto a la utilización de los estudios teóricos realizados al tratamiento de señales infrarrojas aplicado a la detección automática de **incendios** forestales, hemos llegado a la siguiente síntesis:

- Las investigaciones se han centrado en los aspectos relativos al tratamiento de las señales captadas por cada uno de los sensores térmicos, incorporando algoritmos avanzados de tratamiento de la señal que permiten la posibilidad de una detección automática para una cierta PFA dada, maximizando la PD gracias a la incorporación del conocimiento de las características del entorno de trabajo y del tipo de señal a buscar. Hemos sido capaces de discernir entre focos de incendios y otras fuentes de señal no problemáticas, con un diseño adaptado a cada sub-área bajo vigilancia y a cada momento temporal, al introducir el concepto de calibración y preblanqueo.
- Por lo tanto, se han aplicado las técnicas de fusión de decisiones tanto incorreladas como correladas a la detección distribuida en sistemas monosensor, mejorando el esquema inicial previo en dos aspectos fundamentalmente:
 - La incorporación de técnicas de fusión de decisiones en sistemas monosensor **incorreladas**, para el caso de las salidas de cada uno de los detectores de filtro adaptado al subespacio, gobernados por la matriz de persistencia, donde se ha buscado la regla de decisión óptima según el criterio de Neyman-Pearson, asumiendo independencia estadística. Se han obtenido las expresiones de la PD_p y la PFA_p , en el caso del detector de persistencia, en función de la PD_o y la PFA_o de cada detector y del parámetro nu de exigencia en el número de detecciones. Para ilustrar los resultados obtenidos se han

- generado una serie de curvas ROC normales con una evolución creciente de la PD al aumentar la PFA , mejorando la PD_p al utilizar la fusión respecto a las PD_o de cada detector individual.
- La mejora de la gestión global de las decisiones para la generación de una detección fusionada y coherente, utilizando técnicas de fusión de decisiones en sistemas monosensor **correladas**, donde se aborda el problema de la fusión de las decisiones ya fusionadas del detector de persistencia y la decisión del detector de crecimiento, que en general son decisiones correladas, ya que utilizan el mismo vector de observaciones para decidir. Se ha buscado la fusión óptima conociendo las reglas de decisión y las correlaciones locales, según el criterio de Neyman-Pearson, obteniendo las razones de verosimilitud y las PD_i y PFA_i globales.
 - Para verificar los resultados se han realizado una serie de simulaciones prácticas, generando multitud de curvas simuladas, tanto de la PFA_p y PD_p del detector fusionado de persistencia, como de la PFA_i y PD_i , del detector de crecimiento, como finalmente de la PFA_i y PD_i globales. Se ha verificado, en todos los casos, el comportamiento teórico con el práctico simulado.
 - Finalmente se han comprobado los resultados con experiencias reales de funcionamiento del sistema, concretamente del sistema DISTER, implementado por el departamento en el parque natural de la Albufera, en la localidad de El Saler, en el término municipal de Valencia:
 - Comentando las experiencias destacables de funcionamiento, tanto de las pruebas con fuegos reales controlados realizadas para verificar el perfecto funcionamiento del sistema, como de los ejemplos de detección reales con intervención por parte del cuerpo de bomberos.
 - Finalizando con una evaluación de los datos de funcionamiento del sistema durante un largo periodo de tiempo de funcionamiento continuado del mismo, indicando las incidencias más destacables tanto de detección como de posibles falsas alarmas provocadas por fenómenos no previstos.

Conclusiones finales

Sobre los aspectos teóricos

Hemos comprobado que la detección distribuida permite incorporar diferentes tipos de diferencias entre el ruido infrarrojo de fondo y la firma infrarroja que puede generar un incendio descontrolado. Por una parte el comportamiento de persistencia de calor en intervalos cortos (unos pocos segundos) permite separar efectos ocasionales, que en dichos intervalos de observación pueden generar una brusca subida del nivel de señal infrarroja, pero seguida de una brusca bajada. Analizar la persistencia en un número determinado de intervalos cortos, fusionando las correspondientes decisiones lleva a una decisión global de persistencia a medio plazo (5 o 6 intervalos de unos pocos segundos). Por otra parte el incremento de temperatura a medio y largo plazo característico de un fuego descontrolado es

explotado mediante un detector de crecimiento. La fusión de ambos detectores lleva al detector final.

De acuerdo con los principios que han dado origen a esta tesis, el diseño óptimo de los detectores de persistencia y de crecimiento es relativamente sencillo y se basa en el uso del filtro adaptado o su variante de filtro adaptado en subespacio. Resulta en particular de interés destacar la forma relativamente simple de incorporar conocimiento genérico sobre la señal a detectar mediante el uso de filtros adaptados en subespacio. “Sintonizando” adecuadamente el subespacio, podemos adaptar esquemas similares al propuesto a otras aplicaciones de vigilancia, como las basadas en detección de movimiento.

En cuanto al ajuste de los detectores hemos desarrollado las ecuaciones requeridas para ajustar la *PFA*, respetando el criterio N-P en todos los pasos, es decir garantizando máxima *PD* final.

Finalmente, en cuanto a la fusión de decisiones correladas, como en principio lo son la de persistencia final y la de crecimiento, hemos verificado que, al tratarse sólo de dos decisiones, las alternativas de fusión sólo afectan a la decisión a adoptar cuando uno de los dos detectores genera un 0 y el otro un 1. Si la regla elegida es decidir un 1, sólo cuando ambos detectores deciden 1, el detector final es óptimo con independencia de la presencia o no de correlación.

Sobre las simulaciones

Hemos verificado con simulaciones las expresiones teóricas calculadas para el control de la *PFA* y la *PD* de las mejoras introducidas al incorporar la fusión de decisiones tanto incorrelada a corto plazo en el detector de persistencia, como correladas con la fusión de decisiones global del detector de persistencia y el detector de crecimiento, generando multitud de curvas simuladas que han demostrado este control al ser capaces de seguir fielmente las curvas teóricas.

Sobre las experiencias con señales reales

Hemos verificado que el comportamiento del sistema de detección de incendios ha sido correcto en los experimentos realizados. Especialmente destacable ha sido la monitorización del sistema durante un largo periodo de tiempo, lo que ha permitido comprobar su fiabilidad en cuanto a detección de fuegos reales, a la par que el control existente sobre las falsas alarmas, cuya tasa se ha aproximado razonablemente a la ajustada a partir de las ecuaciones. Muchas más experiencias se requieren en entornos variados para refinar progresivamente el sistema y hacerlo realmente fiable. En este sentido es ventajoso aprovechar el tener un sistema en funcionamiento, ya que de su propio funcionamiento podemos ir deduciendo las mejoras sucesivas.

5.1.3 Aplicación a detección ultrasónica

Respecto a los algoritmos implementados en relación con el problema clásico de la detección automática de ecos ultrasónicos sobre ruido de grano, para el ensayo no destructivo de materiales, en la segunda aplicación de detección de capas de materiales, con **ultrasonidos**, para la restauración arquitectónica, la síntesis es:

- Se han desarrollado unos nuevos algoritmos de **split-spectrum** (SSP) utilizando detección distribuida (*SSDD* y *NSSDD*), adecuados para la detección automática de pulsos a la salida de cada filtro paso banda, que genera decisiones distribuidas, y fusionando las decisiones locales distribuidas para tomar la decisión final. Se ha demostrado que son óptimos cuando la varianza del ruido de grano se reduce en presencia del pulso buscado y no es posible tener un conocimiento a priori de este pulso buscado, que además supondremos tiene toda su energía distribuida a lo largo de todos o muchos de los subespacios generados por los distintos filtros paso banda del algoritmo SSP.
- Se han obtenido las fórmulas generales de PFA_{final} y PD_{final} en función de los parámetros del modelo y se han obtenido una serie de curvas que verifican el correcto funcionamiento de las expresiones, permitiendo comprobar que es posible obtener valores muy pequeños de PFA_{final} incluso para una PFA individual muy grande y que la PD_{final} nunca es menor de la PD individual lo que implica que la fusión de decisiones generará valores pequeños de PFA_{final} dejando los valores de PD_{final} a unos niveles razonables.
- Se han hecho una serie de comparativas entre el algoritmo implementado *SSDD* y el detector trivial, como solución del filtro adaptado tras el preblanqueo, comprobándose el mejor comportamiento del *SSDD*, si el nivel del pulso buscado es suficientemente elevado para que inyecte bastante energía en cada subespacio, ya que el asumido perfecto preblanqueo, ensancha la energía del pulso a lo largo de los L canales del filtro.
- Se han realizado una serie de **experimentos con señales simuladas**, de las que se concluye que:
 - En cuanto al control de la PFA , se han obtenido unos resultados altamente satisfactorios que comprueban cómo somos capaces de seguir fielmente, con simulaciones, las curvas teóricas de PFA_{final} en función de la PFA individual para distintos valores de exigencia.
 - En cuanto al análisis de la detección, se han generado curvas ROC para los diferentes algoritmos implementados, comparándolos con el trivial. Se han obtenido los mejores resultados con el *NSSDD* seguido del trivial y finalmente el *SSDD*, teniendo en cuenta que el pulso buscado estaba inmerso en ruido de grano.
 - En cuanto a la **detección** con señales simuladas, se han realizado diversas pruebas de las que cabe destacar:

- Se comprueba como, con el *SSDD* y el *NSSDD* somos capaces de detectar el pulso, con espectro plano, oculto para una cierta *SNR*, incluso reduciendo la *SNR* drásticamente en el *NSSDD*.
 - Se han realizado pruebas exhaustivas, obteniéndose buenos resultados con los tres algoritmos cuando la *SNR* es alta, pero empeorando los resultados al reducir la *SNR*, salvo en el caso del *NSSDD* que mantiene unos buenos resultados por delante del trivial y el *SSDD*.
 - Se comprueba como el *SSDD* es capaz de detectar el pulso buscado real ultrasónico de 5MHz, mientras al reducir la *SNR* con el *NSSDD*, también se detecta, aunque con alguna falsa alarma, debida a que el pulso utilizado no tiene un espectro totalmente plano en la banda de paso.
 - Se han generado las mismas pruebas exhaustivas anteriores pero con el pulso buscado real ultrasónico de 5 MHz, obteniéndose buenos resultados con el *NSSDD* y el trivial y muy malos con el *SSDD*, al reducir la *SNR* ya que este tipo de pulso está inmerso en ruido de grano.
 - Por lo que se concluye que el *SSDD* está bastante limitado para su uso en tareas donde se prime la detección automática de pulsos cuya característica fundamental sea su uniformidad espectral, más que un nivel de energía importante en cada uno de los detectores sintonizados, donde el *NSSDD* sí que funciona de manera correcta.
- Se ha trabajado con **señales ultrasónicas reales** bajo el control de laboratorio, donde se ha trabajado con una probeta de **duraluminio** con un defecto conocido, de donde se puede destacar:
 - Con el trivial somos capaces de detectar las interfases con falsas alarmas, pero no el defecto.
 - Con el *SSDD* somos capaces de detectar las interfases y el defecto claramente, sin apenas falsas alarmas.
 - Con el *NSSDD* somos capaces de detectar las interfases y el defecto con mayor resolución, pero sin tanta definición y con muchas falsas alarmas.
- Finalmente, se ha trabajado con señales reales para el cálculo del espesor de capas de materiales internos de la cúpula de la Real **Basílica** de la Virgen de los Desamparados de Valencia.
 - Somos capaces de detectar únicamente la primera capa, más superficial, de la zona de trabajo, alrededor de los 0.3 cm de profundidad.
 - En cualquier caso somos incapaces de penetrar más allá de 1 cm de profundidad.
 - Los algoritmos implementados, si bien obtienen unos resultados más o menos parecidos al detector trivial, son capaces de perfilar un poco mejor la capa detectada, con una *PFA* mucho menor.
- En el **modelo a escala** de la Basílica, donde se ha realizado un estudio exhaustivo sobre una serie de catas de las distintas capas de los materiales

utilizados en este modelo, se han aplicado los algoritmos implementados a las señales reales obtenidas, para poder determinar el espesor y ubicación física de las capas detectadas.

- Las distintas capas de material de mortero y yeso tienen unas velocidades de propagación del ultrasonido similares alrededor de los 1600 m/s.
- Somos capaces de detectar dos nubes de puntos que se corresponden con el 2º eco de la primera capa y con el 3º eco de la primera capa, situada a 0.3 cm de profundidad, perfilándose mejor con el *SSDD* que con el trivial, y obteniéndose muy malos resultados con el *NSSDD*.

Conclusiones finales

Sobre los aspectos teóricos

Hemos propuesto un nuevo esquema de detección automática de ecos ultrasónicos en fondo de ruido granular basado en incorporar la detección distribuida en los algoritmos “split-spectrum”. El nuevo esquema y el estudio realizado en relación con el mismo, suponen algunas aportaciones interesantes en este ámbito:

- Disponer de algoritmos split-spectrum con detección óptima y ajuste de *PFA*
- Entender mejor las limitaciones de los algoritmos split-spectrum existentes, ya que son casos particulares del esquema genérico propuesto.
- En particular hemos comprobado que la reducción del ruido granular en presencia del eco a detectar, es un elemento clave para el buen funcionamiento de estos algoritmos, que de otra forma difícilmente pueden competir con un simple detector de umbral
- Hemos verificado que incorporar una etapa de preblanqueo es sustancial con la optimización del detector y puede ser una mejora importante incluso en el detector que hemos denominado trivial: preblanqueo y umbral.
- Nuevamente, hemos mostrado que el filtro adaptado en subespacio, es una herramienta potente para abordar este tipo de problemas, explotando la equivalencia formal entre filtro (paso banda) sintonizado y subespacio (paso banda) sintonizado.

Sobre las simulaciones

Hemos considerado la realización de una serie de simulaciones para controlar la *PFA*, analizar la detección y detectar con distintos pulsos simulados. Hemos trabajado básicamente con dos pulsos, un primer pulso con espectro aproximadamente plano en la banda de paso de trabajo, y un segundo pulso, tomado de una señal real ultrasónica de 5 MHz.

Los resultados obtenidos respecto al control de la *PFA* y el análisis de la detección con curvas *ROC* son altamente satisfactorios comprobando la capacidad de seguimiento de las simulaciones respecto a las curvas teóricas y consiguiendo mejores resultados con el *NSSDD*, seguido del trivial y el *SSDD*.

En cuanto a los resultados obtenidos con los pulsos simulados se ha podido comprobar el correcto funcionamiento de los algoritmos implementados, siendo el *NSSDD* mejor en el caso de que la *SNR* se reduzca drásticamente y empeorando el *SSDD* si el pulso está inmerso en ruido, por lo que se concluye que el *SSDD* está bastante limitado para su uso en tareas donde se prime la detección automática de pulsos cuya característica fundamental sea su uniformidad espectral, más que un nivel de energía importante en cada uno de los detectores sintonizados, donde el *NSSDD* sí que funciona de manera correcta.

Sobre las experiencias con señales reales

Hemos considerado dos experimentos con señales reales. El primero, realizado en laboratorio con probetas de aluminio, ha permitido comprobar la capacidad de los algoritmos propuestos para detectar defectos en situación de baja relación señal-ruido de grano. El segundo experimento se ha realizado en el marco de investigaciones encaminadas a apoyar a los restauradores de bóvedas de monumentos históricos, mediante ensayos no destructivos por ultrasonidos. En particular hemos aplicado las técnicas propuestas a la obtención del perfil de interfaz entre la primera y segunda capas de la bóveda de la Virgen de los Desamparados de Valencia, demostrando que la aplicación de los tres detectores propuestos permite visualizar el perfil buscado, cosa imposible en las señales originales.

Ha resultado significativo comprobar cómo el algoritmo *SSDD* es el que mejores resultados ha proporcionado con señales reales, si bien el *NSSDD* era el mejor en la teoría y en las simulaciones. El aparente peor comportamiento del *NSSDD* puede explicarse por la propia gran sensibilidad de este último algoritmo ante la presencia de ecos aislados, incluso de bajo nivel, ya que de hecho es un algoritmo independiente del nivel de la señal bajo análisis. Muchas de las aparentes falsas alarmas generadas deben interpretarse realmente como “detecciones no deseadas” pero esencialmente correctas: si son debidas a ecos aislados, estrictamente no son ruido de grano, ya que este último, desde el punto de vista de los modelos de señal y ruido, está definido como una superposición de ecos pequeños.

5.2 Conclusión general

Como conclusión general podemos decir que esta tesis ha demostrado el interés de aplicar detección distribuida en señales monosensor, como forma de abordar el diseño de detectores complejos a partir de fusionar las decisiones de detectores más simples. Se ha ilustrado tal conclusión mediante dos aplicaciones, comprobándose la importancia de atacar los diseños en el marco de problemas concretos, si bien algunas opciones, tal y como la de usar filtros adaptados en subespacio, tienen interés general.

5.3 Líneas futuras

Hemos demostrado en esta tesis el interés de la filosofía de detección distribuida en dos aplicaciones. Obviamente queda abierta la posibilidad de utilizar estas ideas en otras aplicaciones que requieran detección automática. Por otra parte y, aunque cada detector individual puede ser implementado de la forma más conveniente, hemos visto que la utilización de filtros adaptados en subespacio resulta de interés con carácter general; ya que modelar el conocimiento de lo que deseamos detectar, mediante su inclusión en un subespacio adecuado, es una forma simple de incorporar la información disponible “a priori” en muchas situaciones.

En cuanto la detección de incendios forestales, puede servir de ejemplo para la aplicación en sistemas de vigilancia automática de toda índole. Ajustando adecuadamente la “banda de paso” de los subespacios de los detectores individualmente podemos seleccionar qué deseamos detectar y qué deseamos rechazar. Por ejemplo un detector de movimiento sería el complementario a un detector de persistencia y se podría diseñar usando un subespacio con una banda, cuya frecuencia de sintonía y anchura dependieran del margen de velocidades de movimiento esperables.

El esquema propuesto para la detección de pulsos ultrasónicos puede generalizarse en diversos aspectos. Primeramente las bandas de los diferentes canales podrían tener anchos de banda distintos (esto está implícito por ejemplo si usamos transformada Wavelet en vez de la transformada de Fourier).

En general sus frecuencias de sintonía y anchos de banda podrían ajustarse en función del entorno concreto: modelos de señal y ruido asumidos. También podríamos utilizar subespacios de dimensión superior a 1, como hemos hecho en la aplicación de incendios. En definitiva podemos sustituir cada canal resultado de aplicar la DFT por una proyección en un subespacio paso banda adecuado, que podríamos diseñar, por ejemplo, de forma similar a lo realizado con los detectores de persistencia.

Por otra parte la fusión de decisiones podría generalizarse utilizando un planteamiento de clasificador. Es decir, el vector formado por las energías de las salidas de los diferentes canales podría ser la entrada de un clasificador que adaptase la decisión: hay eco o no hay eco, según el valor del mencionado vector. Tal y como se ha implementado en esta tesis, lo que estamos haciendo es decidir mediante umbralización componente a componente, cuales son esas regiones. Pero puede pensarse en estrategias más adecuadas obtenidas mediante entrenamiento del clasificador (supervisión) con ruido de grano y ecos de señal similares a los buscados.

Bibliografía y publicaciones

Bibliografía .

- [1] L.L.Scharf, “*Statistical Signal Processing*”, Addison Wesley, New York, 1991
- [2] L.M.Garth and V.P. Poor, “*Detection of Non-Gaussian Signals: A Paradigm for Modern Statistical Signal Processing*”, Proc. IEEE, Vol.82, No. 7, Julio 1994, pp. 1061-1095
- [3] S.M. Kay, “*Fundamentals of Statistical Signal Processing, Volume II. Detection Theory*”, Prentice Hall, New Jersey, 1998
- [4] R. D. Hippenstiel, “*Detection Theory. Applications and Digital Signal Processing*”, CRC Press, London, 2002
- [5] P.V. Varshney, “*Special issue on data fusion*”, Proceedings on the IEEE, Vol. 85, Nº1, Enero. 1997.
- [6] D.L. Hall, J. Llinas, “*An Introduction to Multisensor Data Fusion*”, Proceedings of the IEEE, Vol. 85, Nº 1, pp. 6-23, Enero. 1997.
- [7] R. Viswanathan, P.K. Varshney, “*Distributed Detection with Multiple Sensors: Part I-Fundamentals*”. Proc. IEEE, Vol.85, No. 1, pp. 54-63, Enero, 1997
- [8] R. Blum, S. Kassam, H. Poor “*Distributed Detection with Multiple Sensors: Part II-Advanced Topics*”. Proc. IEEE, Vol.85, No. 1, pp. 64-79, Enero, 1997
- [9] G. López Risueño, “*Detección y Análisis de Señales en Interceptadotes mediante Técnicas Tiempo-Frecuencia*”, Tesis Doctoral, ETSI Telecomunicaciones-UPM, 2002
- [10] W.K. Pratt, “*Digital Image Processing*”, John Wiley & Sons, New York, 1991
- [11] SEDPII, “*Sistema Electrónico de Detección Precoz de Incendios*”, Departamento de Comunicaciones-UPV, subvencionado por Helisureste SA e IMPIVA, 1996.
- [12] DELFIN, “*Detección Electrónica y Localización de Focos de Incendio*”, Departamento de Comunicaciones-UPV, subvencionado por Generalitat Valenciana. 2001-2002.
- [13] DISTER, “*Detección de Incendios mediante Sensores TÉRmicos*”, Departamento de Comunicaciones-UPV, subvencionado por el Ayuntamiento de Valencia, 2001-2002.
- [14] L. Vergara, J. Gosálbez, J.V. Fuente, R. Miralles, **I. Bosch**, “*Ultrasonic Non Destructive Testing on Marble Rocks Blocks*”, Material Evaluation, Vol 62 Nº 1, pp. 73-78, Enero 2004.
- [15] L.Vergara, J. Gosálbez, **I. Bosch**, J. Molina, R. Miralles, “*Tratamiento de Señales Ultrasonicas en Ensayos no Destructivos: Aplicación en el ámbito de la restauración, Revista de Restauración & Rehabilitación*”, pp. 44-49, Febrero 2003.
- [16] R. Miralles, L. Vergara, J. Gosalbez, **I. Bosch**, A. Salazar “*Procedimiento para la detección de cuerpos extraños en confituras y mermeladas mediante ultrasonidos y visión multispectral*”. Patente en estudio por la AINIA (Instituto Tecnológico Agroalimentario). 2004.

- [17] J. Gosálbez, L. Vergara, R. Miralles, J.V. Fuente, “*Comparative Study of Methods to Estimate the Ultrasonic Pulse in Non-destructive Analysis of Materials*”, 8th European Conference on Nondestructive Testing (ECTNT 2002), Barcelona, Junio 2002
- [18] Z. Chair, P.K. Varshney, “*Optimal Data Fusion in Multiple Sensor Detection Systems*”, IEEE Trans. On Aerospace and Electronic Systems, Vol. 22, No. 1, Enero 1986, pp 98-101
- [19] V. Aalo, R. Viswanathan, “*On Distributed Detection with Correlated Sensors: Two Examples*”, IEEE Trans. On Aerospace and Electronic Systems, Vol. 25, No. 3, Mayo 1989, pp 414-421
- [20] E. Drakopoulos, C.C. Lee, “*Optimum Multisensor Fusion of Correlated Local Decisions*”, IEEE Trans. On Aerospace and Electronic Systems, Vol. 27, No. 4, Julio 1991, pp 593-606
- [21] M. Kam, Q. Zhu, W.S. Gray, “*Optimal Data Fusion of Correlated Decisions in Multiple Sensor Detection Systems*”, IEEE Trans. On Aerospace and Electronic Systems, Vol. 28, No. 3, Julio 1992, pp 916-920
- [22] V. Aalo, R. Viswanathan, “*Asymptotic Performance of a Distributed Detection System in Correlated Gaussian Noise*”, IEEE Trans. On Signal Processing, Vol. 40, No. 1, Enero 1992, pp 211-213
- [23] B. Chen, P.K. Varshney, “*A Bayesian Sampling Approach to Decision Fusion Using Hierarchical Models*”, IEEE Trans. On Signal Processing, Vol. 50, No. 8, Agosto 2002, pp 1809-1818
- [24] Q. Yan, R. S. Blum, “*On Some Unresolved Issues in Finding Optimum Distributed Detection Schemes*”, IEEE Trans. On Signal Processing, Vol. 48, No. 12, Diciembre 2000, pp 3280-3288
- [25] Q. Yan, R. S. Blum, “*Distributed Signal Detection Under the Neyman-Pearson Criterion*”, IEEE Trans. On Information Theory, Vol. 47, No. 4, Mayo 2000, pp 1368-1377
- [26] P. Willet, P.F. Swaszek, R.S. Blum, “*The Good, Bad, and Ugly: Distributed Detection of a Known Signal in Dependent Gaussian Noise*”, IEEE Trans. On Signal Processing, Vol. 48, No. 12, Diciembre 2000, pp 3266-3279.
- [27] P.O. Duda, P.E. Hart: “*Pattern Classification and Scene Analysis*”. New York Wiley, 1973, ch4.
- [28] L. Vergara, P. Bernabeu, “*Automatic signal detection applied to fire control by infrared digital signal processing*”. Signal Processing, Vol. 80 (No 4), pp. 659-669, Abril, 2000.
- [29] L. Vergara, P. Bernabeu, “*Simple approach to nonlinear prediction*”. Electronic Letters. Vol. 37 (No 14), pp 926-928, Julio 2001.
- [30] P. A. Bernabeu “*Nuevos esquemas de detección distribuida basados en el uso de predicción no lineal: Aplicación a la detección de incendios en grandes áreas*”. Tesis doctoral. UPV. 2002.
- [31] L. Vergara, P. Bernabeu, J. Igual: “*Wide area surveillance by infrared digital signal processing*”, FUSION 2000, París, Julio 2000.
- [32] P. Bernabeu, L. Vergara, **I. Bosch**, “*Nonlinear prediction of infrared data by the Wiener system*”, EUSIPCO-2002, Proceedings EURASIP, Toulouse (Francia), Septiembre 2002.

- [33] P. Bernabeu, L. Vergara, **I. Bosch**, J. Igual. “*A prediction/detection scheme for automatic forest fire surveillance*”. Elsevier. Digital Signal Processing: A review Journal. Vol: 14. pp: 481 – 507. Año: 2004
- [34] L. Vergara, N. Cardona, **I. Bosch**, P. Catalán, J. Larrey, “*DISTER, Early Fire Detection Using Thermal Sensors*”, XII World Forestry Congress, Canadá, Septiembre 2003.
- [35] L. Vergara, **I. Bosch**, P. Bernabeu: “*Infrared Signal Processing for Early Warning of Forest Fires*”, Fourth International Workshop on Remote Sensing and GIS Applications to Forest Fire Management, Ghent, Bélgica, Junio 2003.
- [36] L. Vergara. **I. Bosch**: “*Forest fire detection by infrared data processing, General System and Decision Fusion Algorithms*”. Lecture Proposal for NATO ASI on Data Fusion (Internacional). Yerevan, Armenia, Agosto 2003.
- [37] CICYT “*Tratamiento digital de señales infrarrojas aplicado a la detección precoz de incendios forestales*”. Ministerio de Ciencia y Tecnología. Dirección General de investigación, CICYT. Plan Nacional I+D+I (TIC 2002-04643). 2003-2005
- [38] Z. Li, Y. J. Kaufman, C. Ichoku, R. Fraser, A. Trishchenko, L. Giglio, J. Jin, X. Yu: “*A review of AVHRR-based active fire detection algorithms: principles, limitations and recommendations In Global and Regional Vegetation Fire Monitoring from Space*”, edited by F. J. Ahern, J. G. Goldammer and C. O. Justice (The Hague: SPB Academic Publishers BV), pp. 199–225, 2001.
- [39] FIREHAWK, “*Electronic Forest Fire Detection and Management System*”, Digital Imaging System, Sudáfrica, 2000.
- [40] EAGLE, “*A Pilot Project on Fire Detection in Central Portugal*”, University of Coimbra, Portugal, 2001.
- [41] C.T. Mullis, L.L. Scharf., “*Quadratic Estimators of the Power Spectrum, en S. Hayking, ed., Advances in Spectrum Analysis and Array Processing I*”, Prentice-Hall, Englewood Cliffs, NJ, 1991, pp. 1-16
- [42] M. G. Gustaffson, T. Stepinsky: “*Studies of split-spectrum processing, optimal detection, and maximum likelihood amplitude estimation using a simple clutter model*”, Ultrasonics, vol. 35, no 1, pp 31-35, Febrero. 1997.
- [43] L. Vergara, J.M. Páez: “*Backscattering gran noise modeling in ultrasonic non-destructive testing*”, Waves in Random Media , vol 1, no 1, pp 81-92, Enero. 1991.
- [44] V.M. Narayanan, P.M. Shankar, L. Vergara, J.M. Reid: “*Studies on ultrasonic scattering from quasi-periodic structures*”, IEEE Trans. on Ultrasonics, Ferroelectrics and Frequency Control, Vol. 44, No. 1, Enero 1997.
- [45] L. Vergara, J.V. Fuente, J. Gosálbez, R. Miralles, **I. Bosch**: “*Processing of ultrasonic grain noise signals for the estimation of depth -and frequency- dependent attenuation*”, Meas. Sci. Technol., vol. 14, pp 1018-1024, Noviembre. 2003.
- [46] M. Grevillot, C. Cudel, J.J. Meyer, S. Jacquey: “*Two approaches to multiple specular echo detection using split-spectrum processing: moving bandwidth minimization and mathematical morphology*”. Ultrasonics, vol. 37, pp. 417-422, Septiembre. 1999.

- [47] Q. Tian, N. M. Bilgutay: “*Statistical Analysis of split spectrum processing for multiple target detection*”, IEEE Trans. on Ultrasonics, Ferroelectrics and Frequency Control, Vol. 45, No. 1, pp. 251-256, Enero. 1998.
- [48] R. Draï, A. Benammar, A. Benchaala: “*Signal processing for the detection of multiple imperfection echoes drowned in the structural noise*”, Ultrasonics, in press.
- [49] X. Li, N. Bilgutay: “*Wiener filter realization for target detection using group delay statistics*”, IEEE Trans. on Signal Processing, Vol. 41, No. 6, pp. 2067-2074, Junio 1993.
- [50] M. G. Gustaffson: “*Nonlinear clutter suppression using split spectrum processing and optimal detection*”, IEEE Trans. on Ultrasonics, Ferroelectrics and Frequency Control, Vol. 43, pp. 109-124, No. 1, Enero 1996.
- [51] L.L. Scharf: “*Statistical Signal Processing*”, Addison Wesley, New York, 1991.
- [52] I. Amir, N.M. Bilgutay, V. L. Newhouse: “*Analysis and comparison of some frequency compounding algorithms for the reduction of ultrasonic clutter*”, IEEE Trans. on Ultrasonics, Ferroelectrics and Frequency Control, Vol. 33, No. 4, pp. 402-411, Julio 1986.
- [53] N.M. Bilgutay, J. Saniie, U. Bencharit: “*Spectral and spatial processing techniques for improved ultrasonic imaging of materials*”, Signal Processing and Pattern Recognition in Nondestructive Evaluation of Materials, C.H. Chen (ed.), pp. 71-85, Springer Verlag, Berlin, 1988.
- [54] X. Li, N.M. Bilgutay, J. Saniie: “*Frequency diverse statistic filtering for clutter suppression*”, Proc. International Conference on Acoustics, Speech and Signal Processing, ICASSP-89, pp. 1349-1352, Glasgow (UK), 1989.
- [55] R. Draï, F. Sellidj, M. Khelil, A. Benchaala: “*Elaboration of some signal processing algorithms in ultrasonic techniques: application to material NDT*”, Ultrasonics, vol. 38, pp. 503-507, Marzo 2000.
- [56] L. Ericsson, T. Stepinsky: “*Algorithms for suppressing ultrasonic backscattering from material structure*”, Ultrasonics, vol. 40, pp. 733-734, Mayo 2002.
- [57] J. Saniie, D.T. Nagle, K. D. Donohue: “*Analysis of order statistic filters applied to ultrasonic flaw detection using split-spectrum*”, IEEE Trans. on Ultrasonics, Ferroelectrics and Frequency Control, Vol. 38, No. 2, pp. 133-140, Julio 1991.
- [58] P.M. Shankar, P.Karpur, V.L. Newhouse, J. L. Rose: “*Split-spectrum processing: analysis of polarity thresholding algorithm for improvement of signal to noise ratio and detectability in ultrasonic signals*”, IEEE Trans. on Ultrasonics, Ferroelectrics and Frequency Control, Vol. 36, No. 1, pp. 101-108, Enero. 1989.
- [59] N. M. Bilgutay, U. B. Bencharit, J. Saniie: “*Enhanced ultrasonic imaging with split-spectrum processing and polarity thresholding*”, IEEE Trans. On Acoustics, Speech and Signal Processing, vol.37, no. 10, Octubre 1989.
- [60] J. Gosálbez, A. Salazar, **I. Bosch**, R. Miralles, L. Vergara “*Thickness material layer profile in restoration determined by ultrasound non destructive evaluation*”. Ponencia en el congreso: VII International Conference on restoration of architectural heritage and

buildings. Actas del congreso. ISBN: 84-609-1697-9. Pág: 316 – 319. Yaiza, Lanzarote (España). Año: 2004

- [61] I. Pitas, A.N. Venetsanopoulos: “*Nonlinear Digital Filters: Principles and Applications (Chap.5)*”, Kluwer Academics Publishers: Massachusetts, 1991.

Publicaciones y patentes relacionadas

Publicaciones en revistas

- [1] L. Vergara, J. Gosálbez, **I. Bosch**, R. Miralles, J. Molina, J. V. Fuente, “*Tratamiento ultrasónico en ensayos no destructivos: Aplicación en el ámbito de restauración*”. América Ibérica. R&R Restauración y rehabilitación ISSN: 1134-4571. pp: 44 – 49. Año: 2003
- [2] P. Bernabeu, L. Vergara, **I. Bosch**, J. Igual. “*A prediction/detection scheme for automatic forest fire surveillance*”. Elsevier. Digital Signal Processing: A review Journal. ISSN: 1051-2004. Vol: 14. pp: 481 – 507. Año: 2004
- [3] J. Gosálbez, A. Salazar, **I. Bosch**. “*Sistema Automático de Inspección de Materiales por Ultrasonidos*”. Orvisa comunicaciones limitadas. Revista Mundo Eléctrico Colombiano, ISSN: 1692-7052. Vol: 18, No. 56. pp: 72-74. Año: 2004
- [4] **I. Bosch**, L. Vergara “*New split-spectrum algorithms based on distributed detection*”. Enviado a IEEE Transaction on Signal Processing. Año 2005.

Publicaciones en congresos

Internacionales

- [5] P. Bernabeu, L. Vergara, **I. Bosch** “*Nonlinear prediction of infrared data by the Wiener system*” Poster en el congreso EUSIPCO-2002. EURASIP. Proceedings. Pág: 309 – 312 Toulouse (Francia). Año: 2002
- [6] L. Vergara, **I. Bosch**, P. Bernabeu, N. Cardona. “*Infrared signal processing for early warning of forest fires*” Poster en el Congreso: 4th International WorkShop on Remote Sensing and GIS Applications to Forest Fire Management: Innovative Concepts and Methods in Fire Danger Estimation. EARSEL. Proceedings of the 4th International (ISBN: 2-908885-25-5) Pág: 239 – 242. Ghent (Bélgica). Año: 2003
- [7] L. Vergara, **I. Bosch**. “*Forest fire detection by infrared data processing: general system and decision fusion algorithms*”. Conferencia invitada en el congreso: 2003 NATO-ASI Seminar on “Data fusion for situation monitoring, incident detection, alert and response management” Actas del congreso. Pág: 20 – 29. Tsakhkadzor (Armenia). Año: 2003
- [8] L. Vergara, N. Cardona, **I. Bosch**, P. Catalán, J. Larrea “*Detección de Incendios mediante Sensores Térmicos (Early Fire Detection Using Thermal Sensors)*”. Poster en el congreso: XII Congreso Forestal Mundial. Actas del congreso con referencia nº 5369, Pág: 10 – 11. Quebec (Canada). Año: 2003
- [9] J. Gosálbez, A. Salazar, **I. Bosch**, R. Miralles, L. Vergara. “*Diagnosis of the material consolidation status in restoration through ultrasonic non destructive testing*”. Ponencia

- en el congreso: VII International Conference on restoration of architectural heritage and buildings. Actas del congreso. ISBN: 84-609-1697-9. Pág: 320 – 323. Yaiza, Lanzarote (España). Año: 2004
- [10] J. Gosálbez, A. Salazar, **I. Bosch**, R. Miralles, L. Vergara “*Thickness material layer profile in restoration determined by ultrasound non destructive evaluation*”. Ponencia en el congreso: VII International Conference on restoration of architectural heritage and buildings. Actas del congreso. ISBN: 84-609-1697-9. Pág: 316 – 319. Yaiza, Lanzarote (España). Año: 2004
- [11] **I. Bosch**, L. Vergara, A. Salazar, J. Gosálbez, J. C. García. “*Sistema Automático de Detección de incendios mediante Sensores Térmicos*”. Ponencia en el congreso: Congreso Internacional de protección contra incendios. OPCI “Organización iberoamericana de protección contra incendios”. ISBN: 958-33-7424-5. pp. 269 – 323. Bogotá (Colombia). Año: 2004
- [12] **I. Bosch**, L. Vergara. “*New insights and extensions of split-spectrum algorithms from an optimum distributed detection perspective*”. Aceptado en el IEEE Ultrasonics symposium. Róterdam. Año 2005
- [13] J. Gosálbez, **I. Bosch**, A. Salazar “*Análisis mediante ultrasonidos de la consolidación y espesor de capas de materiales en edificios históricos*”. Aceptado en el III Congreso Internacional de Materiales, CIM 2005. Cartagena de Indias. Año: 2005

Nacionales

- [14] L. Vergara, J. Gosálbez, **I. Bosch**, R. Miralles, J. Molina, J. V. Fuente. “*Tratamiento de Señales Ultrasónicas en Ensayos No Destructivos de Materiales*”. Ponencia en el congreso: XIV Congreso Nacional de Conservación y Restauración de Bienes Culturales. Secretaría Técnica del Congreso. Libro de Actas (2 Vol) (ISBN: 84-95389-48-7) Pág: 323 – 331. Valladolid. Año: 2002
- [15] **I. Bosch**, J. Gosálbez, L. Vergara, R. Miralles, J. V. Fuente, A. Salazar. “*Tratamiento de Señales Ultrasónicas en Ensayos No Destructivos de Materiales: Aplicación en el ámbito de restauración*”. Ponencia en el congreso: 10º Congreso Nacional de Ensayos No Destructivos (END). Asociación española de ensayos no destructivos 2003 (ISBN: 84-688-2078-4) Pág: 81 – 90. Cartagena. Año: 2003
- [16] A. Salazar, J. Gosálbez, **I. Bosch**, R. Miralles, L. Vergara. “*Análisis del estado de consolidación y espesor de capas de materiales en restauración mediante ensayos no destructivos por ultrasonidos*”. Ponencia en el congreso: XV Congreso de Conservación y Restauración de Bienes Culturales. Murcia. Año: 2004
- [17] **I. Bosch**, J. Gosálbez, A. Salazar, L. Vergara, R. Miralles. “*Análisis ultrasónico en aplicaciones de restauración arquitectónica*”. Aceptado en el Symposium Nacional de la Unión Científica Internacional de Radio (URSI). Año 2005

Patentes

- [1] L. Vergara, N. Cardona, **I. Bosch**, J. Larrey, P. Catalán. “*Sistema autónomo de adquisición y procesado de imágenes termométricas*”. N° de solicitud: P200301447
País de prioridad: España. Fecha de prioridad: 01-06-2003. Entidad titular: Universidad Politécnica de Valencia. Países a los que se ha extendido: Resto del mundo excepto a EEUU
- [2] L. Vergara, N. Cardona, **I. Bosch**, J. Larrey, P. Catalán “*Sistema de vigilancia para la detección precoz de incendios*”. N° de solicitud: P200301365. País de prioridad: España. Fecha de prioridad: 01-06-2003. Entidad titular: Universidad Politécnica de Valencia. Países a los que se ha extendido: Resto del mundo excepto EEUU

Índice de Figuras:

Figura 1. Arquitectura básica de detección distribuida multisensor.....	3
Figura 2. Arquitectura básica de detección distribuida monosensor.	4
Figura 3. Modelo general de procesos de la fusión de datos.	15
Figura 4. Fusión centralizada.....	19
Figura 5. Fusión autónoma	20
Figura 6. Fusión híbrida.....	20
Figura 7. Arquitectura de fusión a nivel de datos.	21
Figura 8. Arquitectura de fusión a nivel de características.	22
Figura 9. Arquitectura de fusión a nivel de decisiones.....	22
Figura 10. Configuración en Paralelo con Central de Fusión	24
Figura 11. Configuración en Serie	25
Figura 12. Configuración en Paralelo sin Central de Fusión.....	26
Figura 13. Configuración en árbol.....	29
Figura 14. Test secuencial.....	36
Figura 15. Estructura óptima de la central de fusión de datos.	40
Figura 16. División del plano de señal en tres regiones.	63
Figura 17. Esquema de fusión de datos tipo paralelo y reformulación utilizando modelos jerárquicos.....	67
Figura 18. Sistema global.	80
Figura 19. Partes del sistema de detección de incendios.	81
Figura 20. Sucesión de imágenes (matrices) en diferentes barridos y predicción del ruido infrarrojo	83
Figura 21. Evolución del nivel en un píxel cualquiera desde el barrido n al n+3	83
Figura 22. Esquema general del procesado.....	84
Figura 23. Subsistema de procesado aplicado a la detección automática en cada píxel Predictor y detectores de energía y de persistencia.	86
Figura 24. Esquema básico del Detector de Crecimiento “a largo plazo” propuesto	89
Figura 25. Esquema básico del Filtro Adaptado	90
Figura 26. Gráficas comparativas entre dos distribuciones χ^2 y $-\chi^2$ con p=5 grados de libertad (Figura 26a) y la convolución de las dos distribuciones anteriores y una distribución normal con media cero y varianza $2*p+2*p=20$ (Figura 26b).....	91
Figura 27. Esquema básico del detector automático, incorporando la detección de persistencia, la detección de crecimiento y la fusión de decisiones.	92
Figura 28. Gráficas de ejemplo de aplicación del esquema básico del detector automático, incorporando la detección de persistencia y la fusión de decisiones. .	95
Figura 29. Gráficas teóricas y prácticas de PFA_p en función de los parámetros nu, L y PFA_0	101
Figura 30. Gráficas prácticas de PD_p en función de los parámetros nu, L, PFA_0 y SNR.....	103
Figura 31. Gráfica práctica de PD_p en función del parámetro crec.....	104
Figura 32. Gráficas prácticas de PFA_i en función de los parámetros L y PFA_t	106
Figura 33. Gráficas de PD_i en función de los parámetros L, PFA_t , SNR y crec.	107
Figura 34. Gráficas de PFA_p , PFA_i y PFA_t teórica (línea continua) y práctica (asteriscos) en función del parámetro L.....	109
Figura 35. Gráficas de PFA_p , PFA_i y PFA_t teórica (línea continua) y práctica (asteriscos) en función de los parámetros de PFAs locales.....	111

Figura 36. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función del parámetro L .	113
Figura 37. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función de los parámetros de PFAs locales.	114
Figura 38. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función del parámetro de SNR.	115
Figura 39. Gráficas de PD_p , PD_i y PD_T teórica (línea continua) y práctica (asteriscos) en función del parámetro de pendiente de crecimiento $crec$.	117
Figura 40. Zona vigilada en la instalación del DISTER en El Saler.	119
Figura 41. Ejemplo de instalación en una estación local móvil y detalle de cámara termográfica Flir Thermovision 320V.	120
Figura 42. Aspecto de la pantalla de control del sistema de apoyo de vídeo y detalle de cámara de vídeo motorizada tipo Domo.	120
Figura 43. Estación de control en el CECOM del Parque de Bomberos de Valencia y aspecto de la pantalla del sistema de gestión de la Estación Central.	121
Figura 44. Imagen IR. Detección de fuego controlado en Parque de Bomberos.	123
Figura 45. Imágenes GIS y procesada. Detección de fuego controlado desde Gola 4M.	124
Figura 46. Imágenes visible, térmica, GIS y procesada. Detección de fuego controlado desde Gola 10.	125
Figura 47. Imagen del sistema de detección GIS en el momento de recibirse la alarma en CECOM	126
Figura 48. Secuencia de detección GIS. Incendio 9 Enero 2003 desde Gola 4F.	127
Figura 49. Fotos del OnSafe visibles y térmica de la detección del Bidón gasolina con residuos vegetales desde Gola 4M. 27 y 28 de Enero 2003.	128
Figura 50. Fotos GIS y OnSafe visibles y térmica de falsa alarma debida al sol en Gola 10. 20 de Febrero 2003.	129
Figura 51. Fotos GIS y Procesadas de detección desconocida en Gola 4M. 19 de Marzo 2003.	130
Figura 52. Fotos GIS, Onsafe visible y procesadas de detección de barbacoa en Gola 4M. 1 de Mayo 2003.	130
Figura 53. Fotos GIS, Onsafe visible y térmica y procesada de detección de globo aereostático en Perellonet. 12 de Mayo 2003.	131
Figura 54. Fotos GIS y procesada de detección desconocida en Perellonet. 21 de Mayo 2003.	131
Figura 55. Fotos GIS y procesada de detección hogueras de San Juan en Perellonet. 24 de Junio 2003.	132
Figura 56. Esquema de detección automática básica.	145
Figura 57. Esquema básico de los algoritmos de split-spectrum	147
Figura 58. Esquema básico inicial de trabajo	149
Figura 59. Esquema del algoritmo del split-spectrum basado en detección distribuida (SSDD)	156
Figura 60. PFA_T en función del parámetro m_0 (máximo número de ceros permitidos para decidir H_0) para diferentes valores de PFA en cada detector individual.	160
Figura 61. PD_T en función de ρ para diferentes valores de PD en cada detector. Con $L=20$ y $m_0=10$.	161
Figura 62. Curvas ROC	162
Figura 63. Comparación con detector trivial. - - SSDD — trivial.	164

Figura 64. PFA_{final} con normalización, para diferentes valores de $m_0=0,2,5,10$, y $L=20$ 165

Figura 65. Gráficas de la función sinc recortada, utilizada para simular el pulso buscado, tanto en el tiempo como en la frecuencia..... 167

Figura 66. Curvas teóricas y simuladas de PFA_r , utilizando el algoritmo SSDD 169

Figura 67. Curvas teóricas y simuladas de PFA_f , utilizando el algoritmo NSSDD ... 170

Figura 68. Curvas ROC correspondiente a los tres algoritmos con $m_0=0$, $N=L=20$, $\sigma_{g1}^2=1$ $\sigma_{g0}^2=0.01$ y $A=1.5$, asumiendo preblanqueo perfecto..... 171

Figura 69. Ruido de grano simulado como composición del ruido coloreado y la sinc recortada p en el centro, con un factor de solape del ruido $\alpha=50\%$ 173

Figura 70. Sumatorio de las detecciones utilizando el algoritmo SSDD cuando el pulso es una sinc. 174

Figura 71. Comparativa entre la señal antes de entrar en el algoritmo SSDD con pulso sinc y la señal a la salida del algoritmo..... 174

Figura 72. Sumatorio de las detecciones utilizando el algoritmo NSSDD cuando el pulso es una sinc. 175

Figura 73. Comparativa entre la señal antes de entrar en el algoritmo NSSDD r_f con pulso sinc y la señal a la salida del algoritmo..... 175

Figura 74. a) Señal ultrasónica real obtenida con un transductor de 5 MHz. b) Trozo de pulso ultrasónico práctico real obtenido a partir de la señal a). 176

Figura 75. Densidad Espectral de Potencia (DEP) del pulso ultrasónico práctico.. 176

Figura 76. Ruido de grano simulado como composición del ruido coloreado y el pulso práctico ultrasónico en el centro..... 177

Figura 77. Sumatorio de las detecciones con fusión utilizando el algoritmo SSDD cuando el pulso es un pulso ultrasónico práctico 178

Figura 78. Comparativa entre la señal antes de entrar en el algoritmo SSDD con el pulso práctico y la señal a la salida del algoritmo. 178

Figura 79. Sumatorio de las detecciones con fusión utilizando el algoritmo NSSDD cuando el pulso es un pulso ultrasónico práctico 179

Figura 80. Comparativa entre la señal antes de entrar en el algoritmo NSSDD con el pulso práctico y la señal a la salida del algoritmo. 179

Figura 81. Pulso sinc a buscar 180

Figura 82. Situación de los 30 pulsos sinc a detectar aleatoriamente distribuidos. 180

Figura 83 Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. 181

Figura 84. Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos tipo sinc 182

Figura 85. Señales a procesar como composición del ruido coloreado y los pulsos tipo sinc aleatorios..... 182

Figura 86. Espectro de la señal a procesar y zona de trabajo del algoritmo NSSDD. 183

Figura 87. Sumatorio de las detecciones con fusión con NSSDD 183

Figura 88. Gráfica de resultados utilizando el algoritmo NSSDD 184

Figura 89. Primera realización de la señal a procesar con pulso sinc con $SNR=6$, $\alpha=0.75$ 185

Figura 90. Comparativa de algoritmos con pulso sinc de $SNR=6$ 186

Figura 91. Primera realización de la señal a procesar con pulso sinc con $SNR=4$, $\alpha=0.75$ 186

Figura 92. Comparativa de algoritmos con pulso sinc de $SNR=4$ 187

Figura 93. Primera realización de la señal a procesar con pulso sinc con SNR=2, alfa=0.75.....	188
Figura 94. Comparativa de algoritmos con pulso sinc de SNR=2.....	189
Figura 95. Pulso real ultrasónico de 5 MHz y su DEP.	190
Figura 96. Construcción de la primera realización de la señal a procesar con pulso real y SNR=8. a) Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. b) Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos reales.	190
Figura 97. Comparativa de algoritmos con pulso real de SNR=8.....	191
Figura 98. Construcción de la primera realización de la señal a procesar con pulso real y SNR=6. a) Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. b) Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos reales.	192
Figura 99. Comparativa de algoritmos con pulso real de SNR=6.....	193
Figura 100. Construcción de la primera realización de la señal a procesar con pulso real y SNR=4. a) Señal previa como composición de ruido blanco y deltas de amplitud SNR donde deberán estar los pulsos a buscar. b) Señal a procesar de la primera realización, como composición de ruido blanco coloreado y pulsos reales.	193
Figura 101. Comparativa de algoritmos con pulso real de SNR=4.....	195
Figura 102. Esquema detallado de la mesa XY.....	196
Figura 103. Probeta de duraluminio con taladro.....	197
Figura 104. Señales reales utilizadas con el duraluminio.....	198
Figura 105. Medida de la Densidad Espectral de Potencia de todas las señales a procesar y parte del espectro a utilizar para este procesado.	199
Figura 106. Resultados obtenidos con el algoritmo trivial en el duraluminio, mostrando detecciones, es decir unos o ceros.....	200
Figura 107. Resultados obtenidos con el algoritmo trivial en el duraluminio, mostrando el valor absoluto de la señal procesada donde se había detectado.	200
Figura 108. Resultados obtenidos con el algoritmo SSDD en el duraluminio, mostrando detecciones, es decir unos o ceros.....	201
Figura 109. Resultados obtenidos con el algoritmo SSDD en el duraluminio, mostrando el valor absoluto de la señal procesada donde se había detectado.	201
Figura 110. Resultados obtenidos con el algoritmo NSSDD en el duraluminio, mostrando detecciones, es decir unos o ceros.....	202
Figura 111. Resultados obtenidos con el algoritmo NSSDD en el duraluminio, mostrando el valor absoluto de la señal procesada donde se había detectado.	203
Figura 112. Interior de la Cúpula de la Virgen de los Desamparados de Valencia..	205
Figura 113. Superficie examinada en la Cúpula de la Basílica.....	205
Figura 114. Detalle del transductor de 5MHz.....	206
Figura 115. Detalle de los equipos de medida.....	207
Figura 116. Transductor cubierto por plástico durante la medida.....	208
Figura 117. Técnicas de inspección ultrasónica.....	208
Figura 118. Perfil aproximado de las capas de materiales de la cúpula.....	209
Figura 119. Representación temporal de las señales originales adquiridas en la Real Basílica de la Virgen de los Desamparados de Valencia.....	210

Figura 120. Representación gráfica de las señales adquiridas en la Real Basílica de la Virgen de los Desamparados de Valencia	210
Figura 121. Densidad espectral de potencia media de las señales en comparación con la DEP del pulso de 5 MHz limpio y zona de trabajo, en la Basílica.	211
Figura 122. Representación de las detecciones obtenidas en la Basílica con el algoritmo trivial	212
Figura 123. Representación gráfica de las detecciones con el algoritmo trivial en la Basílica.....	212
Figura 124. Representación de las detecciones obtenidas en la Basílica con el algoritmo SSDD	213
Figura 125. Representación gráfica de las detecciones con el algoritmo SSDD en la Basílica.....	213
Figura 126. Representación de las detecciones obtenidas en la Basílica con el algoritmo NSSDD	214
Figura 127. Representación gráfica de las detecciones con el algoritmo NSSDD en la Basílica.....	214
Figura 128. Fotografía del modelo a escala	216
Figura 129. Fotografía de la realización de una medida ultrasónica sobre el modelo a escala	216
Figura 130. Detalle de la toma de una medida sobre el mallado en el modelo a escala	216
Figura 131. Composición fotográfica de la zona analizada en el modelo a escala.	217
Figura 132. Representación gráfica de las señales adquiridas en el modelo a escala de la Real Basílica de la Virgen de los Desamparados de Valencia	218
Figura 133. Densidad espectral de potencia media de las señales en comparación con la DEP del pulso de 5 MHz limpio y zona de trabajo, en el modelo a escala de la Basílica.....	218
Figura 134. Representación gráfica de las detecciones con el algoritmo trivial en el modelo a escala de la Basílica.....	219
Figura 135. Representación gráfica de la señal procesada mostrando el valor absoluto de la muestra central donde ha habido detección, con el algoritmo trivial, en el modelo a escala de la Basílica	219
Figura 136. Representación gráfica de las detecciones con el algoritmo SSDD en el modelo a escala de la Basílica.....	220
Figura 137. Representación gráfica de la señal procesada mostrando el valor absoluto de la muestra central donde ha habido detección, con el algoritmo SSDD, en el modelo a escala de la Basílica	221
Figura 138. Representación gráfica de las detecciones con el algoritmo NSSDD en el modelo a escala de la Basílica.....	222
Figura 139. Representación gráfica de la señal procesada mostrando el valor absoluto de la muestra central donde ha habido detección, con el algoritmo NSSDD, en el modelo a escala de la Basílica	222

Índice de Tablas

Tabla I. Probabilidad de detección (dada una probabilidad de falsa alarma >0 para $N \rightarrow \infty$)	52
Tabla II. Incidencias destacables de DISTER de Enero a Marzo de 2003	128
Tabla III. Incidencias destacables de DISTER de Marzo a Diciembre de 2003	129
Tabla IV. Resultados de detección obtenidos con Pulso sinc con SNR=6 y alfa=0.75.	185
Tabla V. Resultados obtenidos con Pulso sinc con SNR=4 y alfa=0.75.....	187
Tabla VI. Resultados obtenidos con Pulso sinc con SNR=2 y alfa=0.75.....	189
Tabla VII Resultados obtenidos con Pulso real con SNR=8	191
Tabla VIII. Resultados obtenidos con Pulso real con SNR=6	193
Tabla IX. Resultados obtenidos con Pulso real con SNR=4	194
Tabla X. Parámetros de configuración y equipamiento	207
Tabla XI. Relación de capas, profundidades y tiempos donde encontrar ecos	209

