

UNIVERSIDAD DE CANTABRIA

DEPARTAMENTO DE TECNOLOGÍA ELECTRÓNICA,  
INGENIERÍA DE SISTEMAS Y AUTOMÁTICA



TESIS DOCTORAL

TÉCNICAS AVANZADAS DE  
IDENTIFICACIÓN Y RECONSTRUCCIÓN DE  
OBJETOS MEDIANTE ULTRASONIDOS

ESTHER GONZÁLEZ SARABIA

INGENIERO INDUSTRIAL

2012

Directores:

DR. JUAN M<sup>a</sup> PÉREZ ORIA

DR. JOSÉ RAMÓN LLATA GARCÍA



UNIVERSIDAD DE CANTABRIA

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS  
INDUSTRIALES Y DE TELECOMUNICACIÓN

DEPARTAMENTO DE TECNOLOGÍA ELECTRÓNICA,  
INGENIERÍA DE SISTEMAS Y AUTOMÁTICA

TESIS DOCTORAL

TÉCNICAS AVANZADAS DE  
IDENTIFICACIÓN Y RECONSTRUCCIÓN DE  
OBJETOS MEDIANTE ULTRASONIDOS

MEMORIA

Presentada para optar al grado de  
DOCTOR INGENIERO INDUSTRIAL

por la Ingeniero Industrial

Esther González Sarabia

Directores:

DR. JUAN M<sup>a</sup> PÉREZ ORIA

DR. JOSÉ RAMÓN LLATA GARCÍA



# Agradecimientos

Quiero expresar mi agradecimiento a:

- Mis directores de tesis, Dr. Juan M<sup>a</sup> Pérez Oria y Dr. José Ramón Llata García por su dedicación y apoyo durante la realización de esta tesis.
- Al grupo de Ingeniería de Control y al personal de la secretaría del departamento por su ayuda y compañerismo, y en especial a Sandra Robla que siempre ha estado dispuesta cuando la he necesitado.
- A Montserrat Gil, de la Universidad de la Rioja, por su colaboración en los inicios de este trabajo.
- Al apoyo de los proyectos de investigación CICYT DPI2006-15313, PROFIT 020100-2002-146, CICYT – DPI2001-1768, CICYT DPI2000-1267 y CICYT-TAP95-0361.
- Y sobre todo a mi familia, y en especial a Ramón, por su apoyo y ayuda, imprescindible para que este trabajo llegara a término.



## Objetivos y organización de la tesis

La sensorización ultrasónica de baja frecuencia en aire posee una serie de ventajas frente a otras tecnologías aplicables en el campo del reconocimiento de objetos en ambientes industriales como son tener un precio reducido, un peso liviano, una electrónica de excitación simple y la capacidad de operar en entornos donde otras técnicas se vuelven inútiles, como por ejemplo poder obtener información en entornos poco o nada iluminados, con presencia de humos, etc. Esto hace que embarcar dichos sensores en pinzas de robots, emplear arrays de sensores en equipos automatizados o integrarla en robótica móvil pueda ser una buena alternativa para gran variedad de aplicaciones.

También hay que decir que trabajar con ultrasonidos en un medio como el aire, presenta cierta problemática que no se observa cuando los ultrasonidos viajan por otros medios, como puede ser los líquidos o sólidos. Así por ejemplo, la velocidad del sonido en el aire ronda los 330 m/s y en cambio en líquidos y sólidos alcanza valores elevados que superan en todos los casos los 1500 m/s. También para manejar distancias de trabajo entorno a un metro, debido a la atenuación de las ondas de ultrasonidos, que está afectada tanto por las propiedades del medio como por la frecuencia de la señal, es necesario emplear sensores de baja frecuencia, los cuales presentan muy poca direccionalidad.

Y hay que añadir también un cierto nivel de incertidumbre en los datos debido al efecto que la variación de los parámetros ambientales produce sobre dichas señales.

Todos estos condicionantes han hecho que las aplicaciones de los ultrasonidos en aire no se hallan desarrollado al mismo nivel que en líquidos o sólidos.

Así, los sensores de ultrasonidos para líquidos y sólidos han sido ampliamente estudiados y mejorados y se presentan en el mercado en una amplia variedad y con una alta escala de integración. Mientras que los sensores de ultrasonidos en aire no han sufrido tanta evolución, ofreciéndose en el mercado para baja frecuencia, sensores básicos encapsulados individualmente y pensados más para tareas de medida o simple detección de presencia.

En este trabajo se potencia el uso de los sensores de ultrasonidos en tareas de identificación y reconstrucción de objetos, buscando además los medios para minimizar sus inconvenientes en la mayor medida posible.

El objeto de la presente tesis se dirige, apoyándose en la información proporcionada por los sensores de ultrasonidos, hacia la resolución de ciertos problemas habituales en las tareas de automatización en las que se requiere obtener información de los objetos de su entorno, los cuales se desea manipular, y a la resolución de problemas en el reconocimiento del entorno para su aplicación en la navegación autónoma de robots. Por tanto este trabajo está orientado, por un lado a aplicaciones relacionadas con el uso de manipuladores, en las que es necesario utilizar técnicas de reconocimiento y clasificación de objetos, así como de reconstrucción superficial de los mismos. Y por otro, está orientado también a las aplicaciones de navegación autónoma en robótica móvil en entornos estructurados en las que es necesario reconocer los elementos del entorno así como su posición relativa respecto al robot.

El trabajo parte de un análisis de las características de las envolventes de los ecos ultrasónicos susceptibles de contener información relevante de los ecos y se evalúa su aptitud a través de diferentes técnicas de inteligencia artificial como son las redes neuronales, para el reconocimiento y clasificación y los conjuntos difusos para la reconstrucción tridimensional.

Seguidamente se modela, para la técnica pulso-eco, la señal recibida desde entornos estructurados simples, como son los formados por paredes planas y esquinas, para su posterior utilización en el reconocimiento del entorno en robótica móvil. Para esta aplicación, una vez desarrollado el modelo se emplearán algoritmos genéticos para facilitar la tarea de utilización del modelo en sentido inverso, es decir, una vez obtenido un eco, reconocer la situación real a que pertenece.

Por último se han mostrado las conclusiones y líneas futuras de trabajo, incluyendo una breve introducción a la aplicación que el modelo desarrollado puede ofrecer a la mejora en la reconstrucción tridimensional de escenas y objetos, que con sensores de baja frecuencia no presenta inicialmente una solución de calidad aceptable.

Este documento tiene los siguientes contenidos:

En el capítulo 1 se realiza una revisión de las características básicas de los ultrasonidos en aire y método de procesado del eco que se ha empleado para obtener su envolvente y los parámetros más representativos del eco.

En el capítulo 2 se proponen una serie de técnicas de reconocimiento de patrones, formas y posiciones empleando redes neuronales.

En el capítulo 3 se proponen una serie de métodos de mejora de la imagen ultrasónica empleando conjunto difusos.

En el capítulo 4 se realiza un amplio análisis para la caracterización de los sensores de ultrasonidos de baja frecuencia.

En el capítulo 5 se presenta el análisis y la programación de un modelo de transmisión de los ultrasonidos para obtener simulaciones de los ecos recibidos ante entornos estructurados simples.

En el capítulo 6 se emplea el modelo anteriormente desarrollado en la localización de esquinas en entornos estructurados empleando algoritmos genéticos para su aplicación en la generación de trayectorias en robótica móvil.

Y por último en el capítulo 7 se exponen las conclusiones del trabajo y la presentación de los trabajos futuros a continuar en la línea de esta tesis.



# Índice general

<b>1. Conceptos básicos de ultrasonidos.</b>	<b>1</b>
1.1. Introducción.	1
1.2. Características generales.	2
1.3. Tipos de transductores de ultrasonidos.	9
1.3.1. Transductores electrostáticos.	9
1.3.2. Transductores piezoeléctricos.	11
1.3.3. Transductores empleados.	12
1.4. Disposición física de los sensores, estructuras sensoriales y reflectores tipo.	13
1.5. Procesado del eco ultrasónico.	16
1.5.1. Método pulso-eco.	16
1.5.2. Procesado digital del eco.	21
1.5.3. Parámetros del eco	24
1.6. Resumen y conclusiones del capítulo	29
<b>2. Reconocimiento de patrones mediante redes neuronales.</b>	<b>33</b>
2.1. Introducción	33
2.2. Introducción a las redes neuronales.	34
2.3. Redes Neuronales Artificiales	38
2.4. Elementos de una red neuronal	41
2.5. Elementos de una neurona	42
2.6. Tipos de neuronas	45
2.6.1. Neuronas de entrada.	45
2.6.2. Neuronas ocultas.	45

2.6.3. Neuronas de salida. . . . .	46
2.7. Arquitecturas de las Redes . . . . .	46
2.7.1. Capa de neuronas . . . . .	46
2.8. Entrenamiento de las redes neuronales . . . . .	47
2.8.1. Aprendizaje Supervisado . . . . .	48
2.8.2. Aprendizaje No Supervisado . . . . .	48
2.8.3. Regla de aprendizaje básica . . . . .	48
2.9. Topologías de las redes . . . . .	50
2.9.1. Redes feedforward . . . . .	50
2.9.2. Redes recurrentes . . . . .	50
2.10. Tipos de redes estándar . . . . .	51
2.10.1. Perceptron . . . . .	52
2.10.2. Redes Lineales . . . . .	55
2.10.3. Redes de Backpropagation . . . . .	58
2.11. Propuestas y resultados en el reconocimiento de formas y orientación de piezas. . . . .	60
2.11.1. Reconocimiento de formas y orientación de piezas empleando una configuración sensor-emisor. . . . .	60
2.11.2. Reconocimiento de formas y orientación de piezas empleando una configuración de array circular. . . . .	74
2.11.3. Reconocimiento de formas y orientación de piezas empleando una configuración de array lineal. . . . .	79
2.11.4. Reconocimiento de formas y orientación de piezas empleando una configuración de array 3x3. . . . .	86
2.12. Resumen y conclusiones del capítulo . . . . .	102
<b>3. Mejora de la imagen ultrasónica mediante conjuntos difusos. 105</b>	
3.1. Introducción. . . . .	105
3.2. Introducción a los conjuntos difusos. . . . .	106
3.2.1. Conjuntos lógicos clásicos. . . . .	106
3.2.2. Conjuntos lógicos difusos. . . . .	107
3.2.3. Estructura del sistema difuso . . . . .	109
3.2.4. Sistemas difusos de tipo Sugeno . . . . .	112

3.2.5. Algoritmo de agrupamiento basado en lógica borrosa: Fuzzy c-means. . . . .	113
3.3. Propuestas y resultados en la mejora de imágenes ultrasónicas. . . . .	115
3.3.1. Introducción . . . . .	115
3.3.2. Suavizado y realzado fuzzy a partir de la imagen 3D basada en el tiempo de amplitud máxima. . . . .	118
3.3.3. Suavizado y realzado fuzzy a partir de la imagen 3D basada en el tiempo de vuelo y de amplitud máxima. . . . .	124
3.3.4. Suavizado y realzado de la imagen 3D mediante median- te la técnica de agrupamiento fuzzy c-means. . . . .	133
3.4. Resumen y conclusiones del capítulo . . . . .	140
<b>4. Caracterización de la respuesta temporal de los sensores</b>	<b>141</b>
4.1. Introducción . . . . .	141
4.2. Obtención del patrón de radiación. . . . .	142
4.3. Relación entre número de ciclos de la señal de excitación y del eco obtenido. . . . .	148
4.4. Aproximación de la envolvente para pulsos de excitación de cor- ta duración. . . . .	153
4.5. Aproximación de la envolvente para pulsos de excitación de larga duración. . . . .	159
4.6. Resumen y conclusiones . . . . .	163
<b>5. Modelo de transmisión de las ondas ultrasónicas.</b>	<b>165</b>
5.1. Introducción. . . . .	165
5.2. La ecuación de onda unidimensional. . . . .	166
5.3. La ecuación de onda bidimensional. . . . .	167
5.4. Reflexión en la superficie de un sólido. . . . .	167
5.5. Reflexión de las ondas ultrasónicas sobre un plano. . . . .	173
5.6. Reflexión de las ondas ultrasónicas sobre una esquina cóncava . . . . .	177
5.7. Experimentación sobre una esquina cóncava de 65 grados. . . . .	189
5.8. Experimentación sobre una esquina cóncava de 90 grados. . . . .	203
5.9. Efecto del ángulo de apertura de la esquina cóncava. . . . .	219

5.9.1. Caso de esquina formada por dos paredes formando un ángulo de 60 grados. . . . .	220
5.9.2. Caso de esquina formada por dos paredes formando un ángulo de 90 grados. . . . .	237
5.9.3. Caso de esquina formada por dos paredes formando un ángulo de 120 grados. . . . .	249
5.10. Resumen y conclusiones . . . . .	260
<b>6. Localización de esquinas mediante algoritmos genéticos.</b>	<b>263</b>
6.1. Introducción . . . . .	263
6.2. Introducción a los algoritmos genéticos. . . . .	264
6.3. Algoritmos genéticos y los métodos clásicos . . . . .	265
6.4. Elementos básicos de un algoritmo genético . . . . .	266
6.5. Etapas de desarrollo de un algoritmo genético. . . . .	269
6.5.1. Generación de la población inicial . . . . .	269
6.5.2. Evaluación de individuos . . . . .	273
6.5.3. Selección de Individuos . . . . .	276
6.5.4. Cruzamiento . . . . .	281
6.5.5. Mutación . . . . .	284
6.5.6. Reinserción . . . . .	286
6.5.7. Terminación . . . . .	288
6.6. Fundamento teórico de los algoritmos genéticos: Teorema de los Esquemas . . . . .	289
6.7. Localización de esquinas empleando algoritmos genéticos. . . . .	292
6.8. Ensayo 1 para la localización de esquinas. . . . .	294
6.9. Ensayo 2 para la localización de esquinas. . . . .	301
6.10. Resumen y conclusiones . . . . .	308
<b>7. Contribuciones y trabajos futuros.</b>	<b>311</b>
7.1. Principales aportaciones y futuras líneas de investigación. . . . .	311
7.2. Primeros trabajos en las futuras líneas de investigación. Reconstrucción tridimensional de imágenes ultrasónicas basada en la descomposición en subecos. . . . .	314

7.2.1. Introducción . . . . .	314
7.2.2. Equipamiento y hardware desarrollado para la experi- mentación. . . . .	315
7.3. Extracción y análisis de características del eco. . . . .	319
<b>Bibliografía</b>	<b>333</b>

*ÍNDICE GENERAL*

---

# Índice de figuras

1.1. Presión acústica y campo de radiación . . . . .	4
1.2. Patrón de Radiación para el sensor Murata MA40B8s a 40KHz	6
1.3. Patrón de Radiación para el sensor Polaroid 600 a 50KHz . . .	6
1.4. Patrón de Radiación para el sensor AIRMAR 75 a 75KHz . . .	6
1.5. Patrón de Radiación para el sensor SensComp200 a 210KHz . .	6
1.6. Transductores electrostáticos . . . . .	10
1.7. Transductores piezoeléctricos . . . . .	11
1.8. a) Sensor Murata 40B8 R/S b) SensComp 40LT16/40LR16 . . .	12
1.9. Tipos de reflectores básicos: a) plano, b) esquina, c) borde . . .	16
1.10. Ejemplo de señal de excitación y señal de recepción mediante pulso-eco. . . . .	17
1.11. Diagrama bloques del proceso de obtención del tiempo de vuelo	18
1.12. Diagrama de radiación de los sensores SensComp 40LR16/LT16	19
1.13. Cálculo del tiempo de vuelo por umbral . . . . .	20
1.14. Ejemplo de eco recibido . . . . .	23
1.15. Ejemplo de eco rectificado . . . . .	23
1.16. Ejemplo de envolvente del eco . . . . .	24
1.17. Señal de emisión y recepción . . . . .	25
1.18. Eco rectificado y envolvente . . . . .	25
1.19. Derivada de la envolvente . . . . .	26
2.1. Diagrama de neurona artificial . . . . .	38
2.2. Agrupación de neuronas en una capa . . . . .	39
2.3. Agrupación de neuronas formando una red neuronal . . . . .	40

## ÍNDICE DE FIGURAS

---

2.4. Estructura de una neurona artificial. . . . .	41
2.5. Función de activación umbral. . . . .	44
2.6. Función de activación lineal. . . . .	45
2.7. Función de activación sigmoidea. . . . .	45
2.8. Red neuronal de dos capas. . . . .	47
2.9. Red neuronal recurrente . . . . .	52
2.10. Representación de un Perceptrón . . . . .	53
2.11. Representación de una red lineal. . . . .	56
2.12. Sistema sensorico. . . . .	61
2.13. Esquema de la configuración del sistema sensorico. . . . .	61
2.14. Generador de funciones HP 33120A . . . . .	62
2.15. Osciloscopio digital HP 54615B . . . . .	62
2.16. a) Eco recibido, b) envolvente del eco y c) derivada de la envolvente. . . . .	64
2.17. Gráficos de los parámetros a) amplitud, b) área de la envolvente y c) área de la derivada de la envolvente. . . . .	65
2.18. Gráficos de los parámetros a) amplitud, b) área de la envolvente y c) área de la derivada de la envolvente para una pieza con dos simetrías. . . . .	66
2.19. Gráficos de los parámetros a) amplitud, b) área de la envolvente y c) área de la derivada de la envolvente para una pieza con cuatro simetrías. . . . .	67
2.20. Red para aprendizaje de clases binarias . . . . .	68
2.21. Red neuronal para clasificación . . . . .	69
2.22. Red neuronal asociativa instar . . . . .	69
2.23. Red radial basis . . . . .	69
2.24. Array circular . . . . .	75
2.25. Array circular . . . . .	76
2.26. Esquema array circular . . . . .	76
2.27. Presiones para objetos rectangulares y circulares . . . . .	77
2.28. Vista lateral presiones para objetos rectangulares y circulares . . . . .	77
2.29. Comparativa $n^0$ de neuronas frente a epochs . . . . .	78
2.30. Diferentes combinaciones para redes de dos capas . . . . .	79

2.31. Piezas de fundición . . . . .	80
2.32. Esquema del sistema . . . . .	80
2.33. Array lineal . . . . .	81
2.34. Representación 3D del parámetro tiempo de amplitud máxima traducido a distancia . . . . .	82
2.35. Representación 2D del parámetro tiempo de amplitud máxima .	83
2.36. Red neuronal esquema 1 . . . . .	84
2.37. Red neuronal esquema 2 . . . . .	85
2.38. Pieza de fundición . . . . .	86
2.39. Array 3x3 . . . . .	88
2.40. Array 3x3 con electrónica de control . . . . .	88
2.41. Ejemplo ecos recibidos desde los ocho sensores del array. . . . .	89
2.42. Evolución del tiempo de vuelo en los ocho sensores . . . . .	89
2.43. Evolución del tiempo de máximo en los ocho sensores . . . . .	90
2.44. Evolución de la máxima amplitud en los ocho sensores . . . . .	90
2.45. Ejemplo de datos del tiempo de vuelo a) con perturbación y b) sin perturbación . . . . .	92
2.46. Configuración de redes . . . . .	92
2.47. Sensores 1, 3 y 7 . . . . .	93
2.48. Sensores 2, 6 y 8 . . . . .	93
2.49. Sensores 1, 5 y 6 . . . . .	94
2.50. Sensores 3, 4 y 8 . . . . .	94
2.51. Numeración sensores receptores . . . . .	94
2.52. Configuraciones de a) dos, b) tres, c) cuatro y d) ocho sensores .	95
2.53. Ejemplo de evolución del mse para clasificación de cara . . . . .	97
2.54. Evolución del <i>mse</i> para la configuración 4 . . . . .	99
2.55. Evolución del <i>mse</i> para la configuración 12 . . . . .	99
3.1. Función de pertenencia de una variable lógica . . . . .	107
3.2. Función de pertenencia de una variable lógica difusa . . . . .	108
3.3. Estructura de un sistema difuso . . . . .	109
3.4. Vista inferior del array lineal de sensores . . . . .	117
3.5. Vista lateral del array lineal de sensores . . . . .	118

## ÍNDICE DE FIGURAS

---

3.6. Pieza ensayada . . . . .	119
3.7. Esquema de la pieza . . . . .	119
3.8. Entradas fuzzy para suavizado . . . . .	121
3.9. Entradas fuzzy para realce . . . . .	121
3.10. Salidas fuzzy para realce . . . . .	122
3.11. Reconstrucción inicial . . . . .	123
3.12. Aplicación del suavizado . . . . .	123
3.13. Aplicación del realce . . . . .	124
3.14. Disposición del array y la pieza . . . . .	125
3.15. Reconstrucción inicial . . . . .	126
3.16. Segunda aproximación . . . . .	126
3.17. Funciones de pertenencia para las entradas . . . . .	127
3.18. Funciones de pertenencia para la salida . . . . .	128
3.19. Pieza después de la interpolación . . . . .	130
3.20. Los ocho vecinos de cada punto de la imagen . . . . .	131
3.21. Funciones de pertenencia para la reducción del ruido . . . . .	131
3.22. Reducción del ruido de la pieza . . . . .	132
3.23. Reconstrucción final . . . . .	133
3.24. Imagen de partida . . . . .	134
3.25. Proyecciones de los datos escalados . . . . .	135
3.26. Proyecciones de los datos escalados sin puntos del suelo . . . . .	135
3.27. Distancias entre pares de datos más próximos . . . . .	137
3.28. Agrupamientos obtenidos y sus centros . . . . .	137
3.29. Puntos que no pertenecen claramente a ningún grupo . . . . .	138
3.30. Proyecciones de las posiciones finales de los puntos . . . . .	139
3.31. Imagen final reconstruida . . . . .	139
4.1. Micrófono Brüel Kjær Type 4939 . . . . .	143
4.2. Patrón de radiación de los sensores SensComp 40LT16/40LR16 obtenido para distancias a la fuente de 15, 20, 25, 30cm a) di- recto, b)normalizado. . . . .	145
4.3. Patrón de radiación en dB a)en coordenadas cartesianas, b) en coordenadas polares. . . . .	146

4.4. Patrón de radiación experimental frente a teórico a) directo para las distancias de 15, 20, 25 y 30 cm, b) normalizado . . . . .	147
4.5. Ciclos de señal de excitación frente a ciclos a los que se produce el máximo a) en el eco en recepción directa, b) en rebote sobre pared plana con $0^{\circ}$ de inclinación. . . . .	151
4.6. Ciclos de señal de excitación frente a ciclos a los que se produce el máximo en el eco en rebote sobre pared plana con a) $10^{\circ}$ de inclinación, b) $20^{\circ}$ de inclinación. . . . .	152
4.7. Transitorio para pulso de 6 ciclos de la señal de excitación . . .	154
4.8. Transitorio para pulso de 8 ciclos de la señal de excitación . . .	155
4.9. Transitorio para pulso de 10 ciclos de la señal de excitación . . .	155
4.10. Transitorio para pulso de 12 ciclos de la señal de excitación . . .	156
4.11. Transitorio para pulso de 14 ciclos de la señal de excitación . . .	156
4.12. Transitorio para señal de excitación de 6 ciclos y 6 voltios . . .	157
4.13. Transitorio para señal de excitación de 6 ciclos y 4 voltios . . .	158
4.14. Transitorio para señal de excitación de 6 ciclos y 2 voltios . . .	158
4.15. Transitorio para señal de excitación de 6 ciclos y 1 voltio . . .	159
4.16. Aproximación para pulso de 15 ciclos de señal de excitación . .	160
4.17. Aproximación para pulso de 20 ciclos de señal de excitación . .	160
4.18. Aproximación para pulso de 25 ciclos de señal de excitación . .	161
4.19. Aproximación para pulso de 30 ciclos de señal de excitación . .	161
4.20. Aproximación para pulso de 40 ciclos de señal de excitación . .	162
4.21. Aproximación para pulso de 50 ciclos de señal de excitación . .	162
5.1. Ondas incidente, reflejada y transmitida. . . . .	169
5.2. Emisión de fuente puntual ultrasónica de 40 kHz en un hemisferio	170
5.3. Patrón de radiación calculado mediante las funciones de Bessel .	170
5.4. Aplicación del patrón de direccionalidad de Bessel a la emisión a 40 KHz . . . . .	171
5.5. Patrón de radiación empleando la campana de Gauss . . . . .	171
5.6. Aplicación del patrón de direccionalidad de Gauss a la emisión a 40 KHz . . . . .	172
5.7. Comparativa de ambos patrones de radiación . . . . .	172

## ÍNDICE DE FIGURAS

---

5.8. Fuente imagen para el calculo de la reflexión sobre una superficie plana . . . . .	176
5.9. Rayos de incidencia y reflexión sobre una superficie plana . . . . .	176
5.10. Señal de recepción en rebote sobre pared plana . . . . .	177
5.11. Reflexión sobre esquina cóncava . . . . .	178
5.12. Reflexión directa sobre la pared 1 . . . . .	181
5.13. Reflexión directa sobre la pared 2 . . . . .	181
5.14. Reflexión directa de la confluencia de las dos paredes . . . . .	182
5.15. Reflexión primero sobre pared 1 y después sobre pared 2 . . . . .	182
5.16. Reflexión primero sobre la pared 2 y después sobre la pared 1 . . . . .	183
5.17. Representación conjunta de las cinco señales . . . . .	183
5.18. Reflexión debida al foco 1s . . . . .	184
5.19. Reflexión debida al foco 2s . . . . .	184
5.20. Reflexión debida al foco 3s . . . . .	185
5.21. Reflexión debida al foco 1ss . . . . .	185
5.22. Reflexión debida al foco 2ss . . . . .	186
5.23. Reflexión total . . . . .	186
5.24. Montaje experimental . . . . .	189
5.25. Mecanismo de desplazamiento . . . . .	190
5.26. Inclinación de 50 grados . . . . .	191
5.27. Inclinación de 60 grados . . . . .	192
5.28. Inclinación de 70 grados . . . . .	193
5.29. Inclinación de 80 grados . . . . .	194
5.30. Inclinación de 90 grados . . . . .	195
5.31. Inclinación de 100 grados . . . . .	196
5.32. Inclinación de 110 grados . . . . .	197
5.33. Inclinación de 120 grados . . . . .	198
5.34. Envoltentes y error para 50 grados . . . . .	199
5.35. Envoltentes y error para 60 grados . . . . .	199
5.36. Envoltentes y error para 70 grados . . . . .	200
5.37. Envoltentes y error para 80 grados . . . . .	200
5.38. Envoltentes y error para 90 grados . . . . .	201
5.39. Envoltentes y error para 100 grados . . . . .	201

5.40. Envoltentes y error para 110 grados . . . . .	202
5.41. Envoltentes y error para 120 grados . . . . .	202
5.42. Error cuadrático medio . . . . .	203
5.43. Inclinación de -40 grados . . . . .	205
5.44. Inclinación de -30 grados . . . . .	206
5.45. Inclinación de -20 grados . . . . .	207
5.46. Inclinación de -10 grados . . . . .	208
5.47. Inclinación de 0 grados . . . . .	209
5.48. Inclinación de 10 grados . . . . .	210
5.49. Inclinación de 20 grados . . . . .	211
5.50. Inclinación de 30 grados . . . . .	212
5.51. Inclinación de 40 grados . . . . .	213
5.52. Envoltentes y error para -40 grados . . . . .	214
5.53. Envoltentes y error para -30 grados . . . . .	214
5.54. Envoltentes y error para -20 grados . . . . .	215
5.55. Envoltentes y error para -10 grados . . . . .	215
5.56. Envoltentes y error para 0 grados . . . . .	216
5.57. Envoltentes y error para 10 grados . . . . .	216
5.58. Envoltentes y error para 20 grados . . . . .	217
5.59. Envoltentes y error para 30 grados . . . . .	217
5.60. Envoltentes y error para 40 grados . . . . .	218
5.61. Errores cuadráticos medios de cada posición angular . . . . .	218
5.62. Representación en planta para esquina de 60 grados con 3 cm de separación entre sensores . . . . .	222
5.63. Reflexión directa en la pared 1 para esquina de 60gr con 3cm de separación . . . . .	222
5.64. Reflexión directa en la pared 2 para esquina de 60gr con 3cm de separación . . . . .	223
5.65. Reflexión directa en la unión de las dos paredes para esquina de 60gr con 3cm de separación . . . . .	223
5.66. Reflexión primero en la pared 1 y después en la pared 2 para esquina de 60gr con 3cm de separación . . . . .	224

## ÍNDICE DE FIGURAS

---

5.67. Reflexión primero en la pared 2 y después en la pared 1 para esquina de 60gr con 3cm de separación . . . . .	224
5.68. Eco completo para esquina de 60 grados con separación de 3 cm	225
5.69. Envoltentes y error para esquina de 60 grados con separación de 3 cm . . . . .	226
5.70. Representación en planta para esquina de 60 grados con 6 cm de separación entre sensores . . . . .	227
5.71. Reflexión directa en la pared 1 para esquina de 60 grados con 6 cm de separación . . . . .	228
5.72. Reflexión directa en la pared 2 para esquina de 60 grados con 6 cm de separación . . . . .	229
5.73. Reflexión directa en la unión de las dos paredes para esquina de 60 grados con 6 cm de separación . . . . .	229
5.74. Reflexión primero en la pared 1 y después en la pared 2 para esquina de 60 grados con 6 cm de separación . . . . .	230
5.75. Reflexión primero en la pared 2 y después en la pared 1 para esquina de 60 grados con 6 cm de separación . . . . .	230
5.76. Eco completo para esquina de 60 grados con separación de 6 cm	231
5.77. Envoltentes y error para esquina de 60 grados con separación de 6 cm . . . . .	231
5.78. Representación en planta para esquina de 60 grados con 12 cm de separación entre sensores . . . . .	232
5.79. Reflexión directa en la pared 1 para esquina de 60 grados con 12 cm de separación . . . . .	233
5.80. Reflexión directa en la pared 2 para esquina de 60 grados con 12 cm de separación . . . . .	233
5.81. Reflexión directa en la unión de las dos paredes para esquina de 60 grados con 12 cm de separación . . . . .	234
5.82. Reflexión primero en la pared 1 y después en la pared 2 para esquina de 60 grados con 12 cm de separación . . . . .	234
5.83. Reflexión primero en la pared 2 y después en la pared 1 para esquina de 60 grados con 12 cm de separación . . . . .	235
5.84. Eco completo para esquina de 60 grados con separación de 12 cm	235

5.85. Envoltentes y error para esquina de 60 grados con separación de 12 cm . . . . .	236
5.86. Representación en planta para esquina de 90 grados con 3 cm de separación entre sensores . . . . .	238
5.87. Reflexión directa en la pared 1 para esquina de 90 grados con 3 cm de separación . . . . .	239
5.88. Reflexión directa en la pared 2 para esquina de 90 grados con 3 cm de separación . . . . .	239
5.89. Reflexión directa en la unión de las dos paredes para esquina de 90 grados con 3 cm de separación . . . . .	240
5.90. Eco completo para esquina de 90 grados con separación de 3 cm	240
5.91. Envoltentes y error para esquina de 90 grados con separación de 3 cm . . . . .	241
5.92. Representación en planta para esquina de 90 grados con 6 cm de separación entre sensores . . . . .	242
5.93. Reflexión directa en la pared 1 para esquina de 90 grados con 6 cm de separación . . . . .	243
5.94. Reflexión directa en la pared 2 para esquina de 90 grados con 6 cm de separación . . . . .	243
5.95. Reflexión directa en la unión de las dos paredes para esquina de 90 grados con 6 cm de separación . . . . .	244
5.96. Eco completo para esquina de 90 grados con separación de 6 cm	244
5.97. Envoltentes y error para esquina de 90 grados con separación de 6 cm . . . . .	245
5.98. Representación en planta para esquina de 90 grados con 12 cm de separación entre sensores . . . . .	246
5.99. Reflexión directa en la pared 1 para esquina de 90 grados con 12 cm de separación . . . . .	246
5.100 Reflexión directa en la pared 2 para esquina de 90 grados con 12 cm de separación . . . . .	247
5.101 Reflexión directa en la unión de las dos paredes para esquina de 90 grados con 12 cm de separación . . . . .	247

## ÍNDICE DE FIGURAS

---

5.102	Reflexión primero en la pared 1 y después en la pared 2 para esquina de 90 grados con 12 cm de separación . . . . .	248
5.103	Eco completo para esquina de 90 grados con separación de 12 cm	248
5.104	Envoltentes y error para esquina de 90 grados con separación de 12 cm . . . . .	249
5.105	Representación en planta para esquina de 120 grados con 3 cm de separación entre sensores . . . . .	250
5.106	Reflexión directa en la pared 1 para esquina de 120 grados con 3 cm . . . . .	251
5.107	Reflexión directa en la pared 2 para esquina de 120 grados con 3 cm . . . . .	251
5.108	Reflexión directa en la unión de las dos paredes para esquina de 120 grados con 3 cm . . . . .	252
5.109	Eco completo para esquina de 120 grados con separación de 3 cm	252
5.110	Envoltentes y error para esquina de 120 grados con separación de 3 cm . . . . .	253
5.111	Representación en planta para esquina de 120 grados con 6 cm de separación entre sensores . . . . .	254
5.112	Reflexión directa en la pared 1 para esquina de 120 grados con 6 cm de separación . . . . .	254
5.113	Reflexión directa en la pared 2 para esquina de 120 grados con 6 cm de separación . . . . .	255
5.114	Reflexión directa en la unión de las dos paredes para esquina de 120 grados con 6 cm de separación . . . . .	255
5.115	Eco completo para esquina de 120 grados con separación de 6 cm	256
5.116	Envoltentes y error para esquina de 120 grados con separación de 6 cm . . . . .	256
5.117	Representación en planta para esquina de 120 grados con 12 cm de separación entre sensores . . . . .	257
5.118	Reflexión directa en la pared 1 para esquina de 120 grados con 12 cm de separación . . . . .	258
5.119	Reflexión directa en la pared 2 para esquina de 120 grados con 12 cm de separación . . . . .	258

5.120	Reflexión directa en la unión de las dos paredes para esquina de 120 grados con 12 cm de separación . . . . .	259
5.121	Eco completo para esquina de 120 grados con separación de 12 cm . . . . .	259
5.122	Envolventes y error para esquina de 120 grados con separación de 12 cm . . . . .	260
6.1.	Situación en planta de la esquina respecto al par emisor-receptor	295
6.2.	Eco incógnita a analizar. . . . .	295
6.3.	Análisis de las zonas del eco incógnita . . . . .	296
6.4.	Generación semialeatoria de individuos . . . . .	297
6.5.	Población final . . . . .	299
6.6.	Comparativa del eco incógnita con la solución encontrada. . . . .	299
6.7.	Representación en planta de la solución . . . . .	300
6.8.	Evolución de la función objetivo . . . . .	300
6.9.	Situación en planta de la esquina incógnita . . . . .	303
6.10.	Eco incógnita . . . . .	303
6.11.	Análisis de las zonas del eco incógnita . . . . .	304
6.12.	Generación semialeatoria de individuos . . . . .	305
6.13.	Población final . . . . .	306
6.14.	Comparativa del eco incógnita con la solución encontrada . . . . .	306
6.15.	Vista en planta de la solución . . . . .	307
6.16.	Evolución de la función objetivo . . . . .	307
7.1.	Disposición física del equipamiento. . . . .	316
7.2.	Array de sensores . . . . .	316
7.3.	Montaje del experimento . . . . .	317
7.4.	Etapas de amplificación utilizadas . . . . .	318
7.5.	Diagrama de bloques de la emisión-recepción. . . . .	318
7.6.	a)Muestra de eco y b) Envoltente y subecos . . . . .	319
7.7.	Eco a) sin solapamientos, b) con solapamiento en la zona del cálculo del tiempo de vuelo. . . . .	320

## ÍNDICE DE FIGURAS

---

7.8. Solapamiento total del subeco principal con subeco secundario a) anterior, b) anterior y posterior. . . . .	321
7.9. Reconstrucción a partir de a) tiempo de vuelo , b) tiempo de máximo del primer eco . . . . .	324
7.10. Representación de los valores de a) amplitudes máximas , b) energía del primer eco. . . . .	324
7.11. Representación de la distancia correspondiente a a) tiempo de comienzo b) tiempo de máximo del segundo eco. . . . .	326
7.12. Valor de a) amplitudes máximas y b) energía del segundo eco .	326
7.13. Reconstrucción basada en a) TDV ponderado por amplitud, b) TDV por potencia . . . . .	327
7.14. Escena utilizada para la reconstrucción . . . . .	329
7.15. Reconstrucción 3D basada en la información de a) tiempo de vuelo b) tiempo de máximo corregido. . . . .	329
7.16. Valor máximo del primer eco . . . . .	330
7.17. Valor máximo del segundo eco . . . . .	330
7.18. Valor máximo del tercer eco . . . . .	331
7.19. Reconstrucción 3D basada en la información de a) los dos pri- meros ecos, b) los tres primeros ecos . . . . .	332

# Índice de tablas

1.1. Especificaciones transductores Murata 40B8 R/S . . . . .	12
1.2. Especificaciones transductores SensComp 40LT16/40LR16 . . . . .	13
1.3. Parámetros para la caracterización del eco . . . . .	30
2.1. Tipos de redes y parámetros . . . . .	72
2.2. Reconocimiento para 10 clases con red de backpropagation . . . . .	72
2.3. Reconocimiento para 10 clases con red asociativa . . . . .	73
2.4. Reconocimiento para 10 clases con red radial basis . . . . .	74
2.5. Resultados entrenamiento de las redes . . . . .	86
2.6. Combinaciones de entradas y neuronas ocultas analizadas . . . . .	95
2.7. Codificación de las caras . . . . .	96
2.8. Resultados para la clasificación de caras . . . . .	98
2.9. Resultados de entrenamiento sin perturbaciones . . . . .	100
2.10. Resultados de entrenamiento con perturbaciones . . . . .	101
3.1. Conjunto de reglas para reconstrucción . . . . .	128
3.2. Conjunto de reglas para la interpolación . . . . .	129
3.3. Conjunto de reglas para la reducción del ruido . . . . .	132
5.1. Tiempos de vuelo de los subecos . . . . .	187
5.2. Coordenadas de los puntos representativos de la esquina . . . . .	187
5.3. Coordenadas y posición de la esquina de 60 grados con 3 cm de separación . . . . .	221
5.4. Coordenadas y posición de la esquina de 60 grados con 6 cm . . . . .	227

## ÍNDICE DE TABLAS

---

5.5. Coordenadas y posición de la esquina de 60 grados con 12 cm de separación . . . . .	232
5.6. Coordenadas y posición de la esquina de 90 grados con 3 cm de separación . . . . .	237
5.7. Coordenadas y posición de la esquina de 90 grados con 6 cm . .	242
5.8. Coordenadas y posición de la esquina de 90 grados con 12 cm de separación . . . . .	245
5.9. Coordenadas y posición de la esquina de 120 grados con 3 cm de separación . . . . .	250
5.10. Coordenadas y posición de la esquina de 120 grados con 6 cm de separación . . . . .	253
5.11. Coordenadas y posición de la esquina de 120 grados con 12 cm de separación . . . . .	257
6.1. Resultados del análisis del eco incógnita . . . . .	296
6.2. Coordenadas y errores del mejor individuo de cada generación .	301
6.3. Resultados del análisis del eco incógnita . . . . .	304
6.4. Coordenadas y errores del mejor individuo de cada generación .	308

# Capítulo 1

## Conceptos básicos de ultrasonidos.

### 1.1. Introducción.

Las aplicaciones de los ultrasonidos en aire han ido incrementándose desde los comienzos de su utilización, donde solamente se empleaban para medir distancias [52, 6]. Hoy en día existen aplicaciones en el reconocimiento y clasificación de patrones para tareas de clasificación de objetos [5, 10, 9], en el reconocimiento de entornos y generación de mapas de entorno para aplicaciones en robótica móvil [60, 54, 12, 37], en la reconstrucción tridimensional de objetos [81] y en la captura de objetos mediante la pinza del robot [18].

Sin embargo las características propias de los ultrasonidos, tales como su incertidumbre, hace que sea necesario un mayor estudio y el desarrollo de nuevas técnicas para poder trabajar con la información que proporcionan.

En este capítulo se presenta una introducción sobre el empleo de sensores de ultrasonidos para el reconocimiento, la localización y clasificación de objetos en aplicaciones de automatización industrial y robótica. Se muestran a continuación los diferentes tipos de sensores de ultrasonidos para su uso en el aire con sus principales características así como la problemática que presenta este tipo de sensores. También se indican las configuraciones sensóricas empleadas por diversos autores, que van desde los más simples sistemas de bajo coste que

miden distancias por umbral hasta complejas configuraciones formadas por múltiples sensores individuales que requieren de complejas señales de excitación y de un avanzado procesado de señal. Se presentan también los reflectores tipo que se suelen considerar para tareas de reconocimiento de entorno. Y, por último, se indica el método de excitación que se va a emplear, el procesado inicial de la señal del eco que se va a realizar y los principales parámetros que se van a extraer.

## 1.2. Características generales.

Los sensores de ultrasonidos son muy populares en las aplicaciones robóticas debido a su bajo coste, su bajo consumo, ser livianos en peso y no necesitar ni una electrónica demasiado compleja ni un gran coste computacional comparado con otros sensores para medir distancias. Además, debido a la direccionalidad del haz ultrasónico generado por dichos sensores, estos pueden aportar más información que una simple medida de la distancia.

También presentan ventajas en aplicaciones submarinas y en entornos con condiciones ambientales adversas tales como situaciones de iluminación reducida o nula, presencia de humos, etc.

La técnica básica de funcionamiento consiste en excitar a un sensor que actúa como emisor generando una onda ultrasónica y poner a la escucha a él mismo u otro sensor que actúa como receptor para captar el eco resultante. Con esta secuencia de operaciones se puede medir la distancia a un objeto situado frente a dichos sensores ya que dicha distancia es proporcional al tiempo de vuelo del eco. La distancia  $e$  al objeto se calcula a partir del tiempo de vuelo  $t$  como:

$$e = \frac{ct}{2} \tag{1.1}$$

donde:

$c$  es la velocidad del sonido (343 m/s a 25°C).

En la ecuación 1.1 se ha de dividir por dos la distancia obtenida ya que corresponde al viaje del eco de ida y de vuelta desde el sensor emisor hasta el

sensor receptor.

El alcance del sensor, cómo se explicará más detalladamente más adelante, estará limitado por factores como la absorción del medio y las pérdidas por dispersión del haz.

Los sensores de ultrasonidos se emplean en los procesos de fabricación automatizados y en robótica para tres propósitos distintos:

- Reconocimiento de objetos: mediante el procesado de una secuencia de ecos se pueden clasificar objetos. Esta información puede ser utilizada para obtener una imagen 3D del objeto insonificado o para obtener una serie de parámetros a partir de los cuales hacer una clasificación dentro de un grupo prefijado de objetos.
- Evitación de obstáculos: mediante el primer eco recibido se puede conocer la distancia al objeto más próximo. Esta información puede ser utilizada para evitar obstáculos y prevenir colisiones en robótica móvil.
- Creación de mapas de entorno: mediante barridos de la zona se puede realizar una reconstrucción del entorno. Esta información puede ser utilizada para construir mapas para navegación autónoma.

Para obtener un modelo simplificado de la forma del patrón de radiación se aplica la teoría elemental de la acústica según se puede ver en la referencia [33]. El emisor es modelado como la superficie de un pistón circular de radio  $a$  vibrando a una frecuencia  $f$ . La longitud de onda  $\lambda$  será por tanto:

$$\lambda = \frac{c}{f} \quad (1.2)$$

En la figura 1.1 se puede observar el campo de presiones a lo largo del eje axial de un oscilador circular. Se aprecia que en la zona denominada como campo cercano o zona de Fresnel se producen unas bruscas oscilaciones. En esta zona el frente de onda es plano y no se presenta casi apertura del haz, como se puede ver en parte inferior de la figura.

La distancia  $N$  que separa el campo lejano del campo cercano se corresponde con el valor:

$$N = \frac{a^2}{\lambda} - \frac{\lambda}{4} \quad (1.3)$$

Una vez que la señal acústica ha pasado el límite del campo cercano, se llega a lo que se denomina como campo lejano o zona de Fraunhofer. En esta zona se observa que el frente de onda toma, a medida que se incrementa la distancia al emisor, una forma similar al de una onda esférica. A partir del comienzo del campo lejano, la señal acústica emitida comienza a experimentar una divergencia cuyo ángulo de apertura  $\theta_0$  depende del radio  $a$  del oscilador y de la longitud de onda  $\lambda$ :

$$\theta_0 = \arcsin\left(\frac{0,61\lambda}{a}\right) \quad (1.4)$$

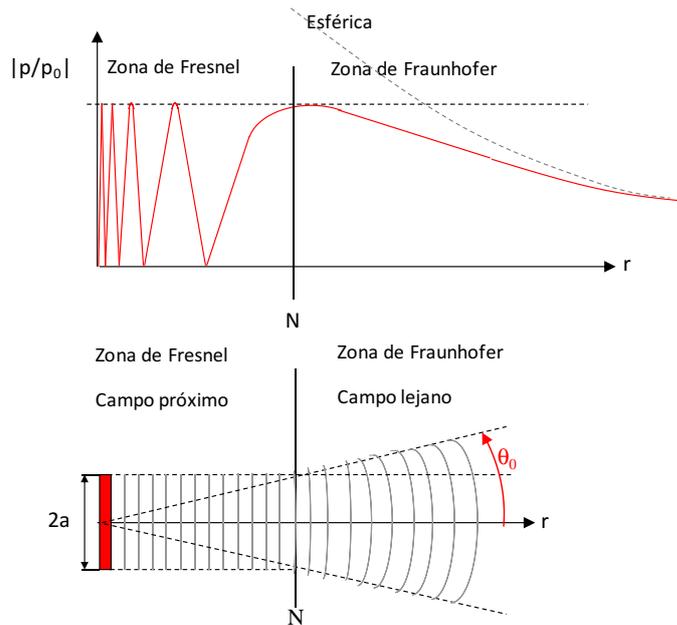


Figura 1.1: Presión acústica y campo de radiación

Cuando  $a > \lambda$ , como ocurre en los sensores comerciales, el campo de presión emitido está formado por lóbulo principal rodeado de lóbulos secundarios. En el campo lejano (distancias mayores de  $\frac{a^2}{\lambda} - \frac{\lambda}{4}$ ) estos lóbulos se representan mediante el patrón de radiación, también llamado patrón de directividad.

Para el emisor la amplitud de presión emitida a una distancia  $r$  y un ángulo  $\theta$  (relativo al eje del sensor) viene dada por:

$$P_{Emitida}(r, \theta) = \frac{\alpha a^2}{r} \left( \frac{2J_1(ka \sin \theta)}{ka \sin \theta} \right) \quad (1.5)$$

$$k = \frac{2\pi}{\lambda} \quad (1.6)$$

donde:

$\alpha$ : constante que es directamente proporcional a la densidad del aire, amplitud de la señal de excitación y la frecuencia del sensor.

$k$ : número de onda

$J_1$ : función de Bessel de primera clase.

En esta expresión puede verse si se incrementan las dimensiones del pistón, la amplitud de la señal de excitación o la frecuencia del sensor, se incrementa la presión emitida. En cambio la presión es inversamente proporcional a la distancia al sensor.

En el receptor, por el teorema de reciprocidad [33], el patrón de directividad tendrá la misma forma que el patrón del emisor.

A la vista de este modelo puede extraerse las siguientes conclusiones:

- El transductor excitado por una senoide presenta lóbulos secundarios debido a los nulos causados por la cancelación de fase. Puede verse su forma para diferentes sensores en las figuras 1.2 a 1.5.
- Este modelo se puede emplear para calcular los parámetros de los lóbulos de radiación aproximados de los transductores de ultrasonidos, aunque por su construcción física (encapsulado, precisión del montaje en su fabricación, etc.) estos parámetros de los lóbulos secundarios pueden variar substancialmente. Puede verse en las figuras 1.2 a 1.5 los patrones de radiación proporcionados por el fabricante para diferentes sensores que trabajan a frecuencias desde los 40 kHz a los 200 KHz. Puede observarse en dichas representaciones cómo se va estrechando el lóbulo de radiación de los sensores según se incrementa la frecuencia a la que trabajan.

1. Conceptos básicos de ultrasonidos.

---

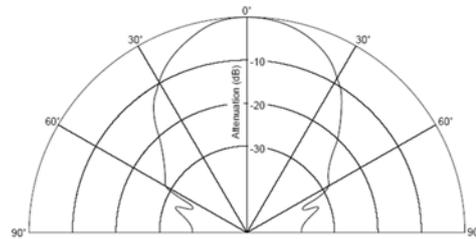


Figura 1.2: Patrón de Radiación para el sensor Murata MA40B8s a 40KHz

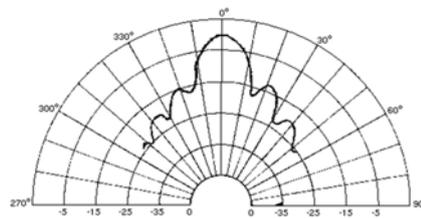


Figura 1.3: Patrón de Radiación para el sensor Polaroid 600 a 50KHz

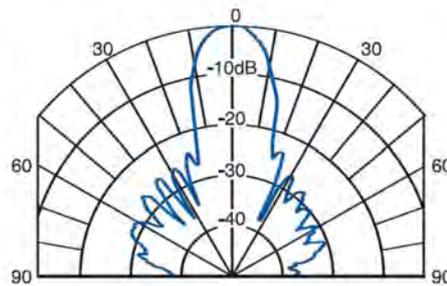


Figura 1.4: Patrón de Radiación para el sensor AIRMAR 75 a 75KHz

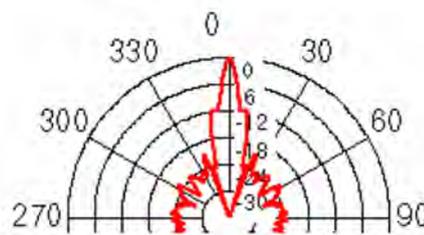


Figura 1.5: Patrón de Radiación para el sensor SensComp200 a 210KHz

Entre las limitaciones del modelo están:

- Sólo sirve para transductores que irradian su energía en un sólo hemisferio. En todo caso la mayor parte de la energía está concentrada en el lóbulo principal.
- Este modelo funciona con una precisión razonable cuando los sensores trabajan en modo pulso-eco con sinusoides de duración finita. Otro tipo de señales de excitación que no sean sinusoidales deben ser descompuestas en sus componentes teniendo cada una su propio patrón de radiación en función de la frecuencia.
- La mayoría de los transductores de ultrasonidos vienen protegidos mediante un encapsulado. Estos encapsulados pueden distorsionar algo las ondas transmitidas.
- El modelo no incluye la absorción acústica dependiente de la frecuencia del medio de transmisión con lo que la amplitud real puede ser menor que la que predice el modelo.
- Este modelo está limitado a configuraciones simples. En casos complejos los emisores, receptores y superficie de los objetos han de ser divididos en arrays de superficies de dos dimensiones, empleando celdas de dimensiones menores de  $\lambda/5$ . Por tanto la respuesta al impulso para una configuración dada se calcula asumiendo emisiones impulso y superponiendo los tiempos de vuelo a lo largo de todos los posibles caminos desde los elementos emisores a los elementos del objeto y de ahí a los elementos receptores.
- La resolución temporal debería ser menor de  $\frac{1}{20f_{max}}$ , donde  $f_{max}$  es la máxima frecuencia de excitación. Así para una señal de excitación de 16 ciclos a 40kHz una resolución de  $1.25\mu s$  sería adecuada. Si se desea emplear excitaciones impulso la resolución empleada debe ser mucho mayor (menor de  $0.125\mu s$ ). En este caso la forma de onda del eco se calcula mediante la convolución de la respuesta al impulso con la forma de onda del pulso transmitido.

Un parámetro de la transmisión en aire que se modifica sustancialmente con las variaciones de los parámetros atmosféricos es la velocidad del sonido. Según las normas ANSI-S1-26 e ISO-9613-1[2, 1] la velocidad del sonido  $c$  varía con la temperatura, la humedad y la presión atmosférica.

La aproximación más sencilla para la velocidad del sonido (en m/s) en aire seco al nivel del mar y una atmósfera de presión viene dada por:

$$c_T = 20,05\sqrt{T_c + 273,16} \quad (1.7)$$

donde  $T_c$  es la temperatura en grados centígrados. La expresión 1.7 suele ser válida para la mayoría de las condiciones, pero si se conoce la humedad relativa se puede utilizar la siguiente expresión que es válida para rangos de temperatura entre  $-30^{\circ}\text{C}$  y  $40^{\circ}\text{C}$  para presiones a nivel del mar:

$$c_H = 20,05\sqrt{T_c + 273,16} + h_r [1,0059 \cdot 10^{-3} + 1,7776 \cdot 10^{-7} (T_c + 17,78)^3] \quad (1.8)$$

Sí también se desea incluir la presión atmosférica  $p_s$  entonces la expresión a emplear será:

$$c_P = 20,05 \sqrt{\frac{T_c + 273,16}{1 - 3,79 \cdot 10^{-3} \left(\frac{h_r p_{sat}}{p_s}\right)}} \quad (1.9)$$

donde  $p_{sat}$  es la presión de saturación dependiente de la temperatura (ver [2, 1]).

Las limitaciones más importantes que se producen al emplear sensores de ultrasonidos son:

- Si se desea alcanzar distancias de medida adecuadas para la robótica móvil es necesario emplear sensores de baja frecuencia que llevan asociados una gran anchura del haz y por tanto producen una pobre resolución direccional.
- La baja velocidad del sonido (comparado por ejemplo con un sensor óptico) reduce la velocidad de detección. Es necesario esperar para enviar

un nuevo pulso a que hayan desaparecido todos los ecos (incluidos los correspondientes a sucesivos rebotes) del pulso anterior, ya que de otra forma se mezclarían y produciría falsas lecturas.

- La incidencia oblicua del eco sobre las superficies puede producir ecos no detectables. Debido a la direccionalidad del haz, las recepciones laterales de señal se ven muy atenuadas.
- Los sensores presentan lóbulos secundarios laterales que pueden producir lecturas erróneas. Producen lecturas de objetos laterales próximos que parecen estar situados en la dirección axial del sensor.
- Las múltiples reflexiones (rebotes) sobre los objetos cercanos pueden mezclarse con reflexiones directas de objetos más lejanos provocando falsas lecturas y pareciendo que hay objetos donde no los hay.
- Las variaciones aleatorias en la velocidad del sonido debido a cambios en los parámetros ambientales, turbulencias, etc. pueden producir variaciones en el tiempo de vuelo y amplitud de los ecos. Aunque generalmente producen pequeñas variaciones pueden causar problemas si se desea realizar un análisis de precisión.

### **1.3. Tipos de transductores de ultrasonidos.**

Para trabajar en aire se emplean generalmente dos tipos de transductores de ultrasonidos: piezoeléctricos y electrostáticos. Puede verse en la figura A continuación se muestran las principales diferencias que existen entre ambas tecnologías.

#### **1.3.1. Transductores electrostáticos.**

Los transductores electrostáticos tienen gran sensibilidad y ancho de banda pero requieren trabajar con tensiones más altas y requieren también altas tensiones de polarización. Su principio de funcionamiento es mediante la vibración de una membrana cargada que hace cambiar la distancia con respecto

a la placa posterior produciendo por tanto un cambio de capacidad. Si la carga es constante la tensión será proporcional a la capacidad.

Los transductores electrostáticos Polaroid, actualmente fabricados por SensComp, son unos de los más empleados. Por ejemplo el transductor SensComp serie 600 (antes Polaroid) trabaja con tensiones de 0-400V y polarización de 200V. Se trata de un transductor que une en un único sensor el emisor y el receptor y tiene como ventaja que el fabricante también facilita el módulo electrónico de control. Dicho módulo viene preparado con su etapa de polarización y excitación para la generación de la señal en modo emisor y las etapas de acondicionamiento de señal para la captura del eco recibido en modo receptor. El inconveniente que presenta es que únicamente facilita información del tiempo de vuelo. Además si se desea trabajar con el eco recibido está preparado con unas etapas de amplificación progresiva que incrementa el nivel de la señal según aumenta la distancia. Esto que pretende ser una ventaja, ya que permite amplificar la atenuación del eco con la distancia, se puede convertir en un inconveniente cuando se desea utilizar la forma del eco, ya que al amplificar muchas veces llega a saturar la señal, y no permite utilizar la máxima amplitud real del eco como parámetro característico. Existen trabajos de aplicación de estos transductores para estimar distancias, generar mapas de entorno, diferenciar bordes, esquinas y paredes como por ejemplo [38]. [17], [64] y [37].



Figura 1.6: Transductores electrostáticos

### 1.3.2. Transductores piezoeléctricos.

Los transductores piezoeléctricos necesitan señales de excitación de bajo voltaje para trabajar (10-20 Vrms) por lo que hacen que las etapas de excitación sean sencillas y de bajo coste. Su principio de funcionamiento es un cristal cerámico resonante al que al aplicarle un voltaje vibra a una determinada frecuencia. Y a la inversa, cuando se le hace vibrar genera un voltaje. Al ser un cristal cerámico el ancho de banda está reducido a unos pocos KHz. Esto limita el tiempo de subida de la envolvente de los pulsos a unos 0.5ms. Pueden encontrarse sensores en un amplio rango de frecuencias que van desde los 20 KHz hasta unos pocos centenares de MHz.

Existe hoy en día otra tecnología piezoeléctrica basada en PVDF (fluoruro de polivinilideno) formando una membrana flexible a la que se puede dar la forma deseada para hacer transductores a medida. Estos transductores poseen una sensibilidad menor que los de cristal cerámico y se suelen emplear en aplicaciones a distancias muy cortas.

Pueden encontrarse en el mercado transductores que se comportan simultáneamente como emisor o receptor y transductores diferenciados para trabajar de forma independiente unos como emisor y otros como receptor.

La ventaja de este tipo de sensores es que no necesitan tensión de polarización, lo que permite una electrónica de control más sencilla. Pero esta ventaja hace que muchos fabricantes ofrezcan dichos transductores sin etapas de excitación y captura por lo que es necesario construirlas para cada aplicación. Este tipo de sensores han sido también ampliamente empleados en trabajos de construcción de mapas de entorno, localización y clasificación de objetos mediante clasificadores como los realizados por G. Benet [12] y M. Martínez [54].

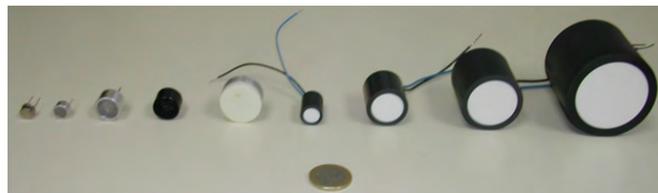


Figura 1.7: Transductores piezoeléctricos

### 1.3.3. Transductores empleados.

De entre la variedad de sensores que podemos encontrar en el mercado se han seleccionado para realizar la experimentación aquellos que trabajan a más baja frecuencia ya que una de las condiciones necesarias para las aplicaciones propuestas es que tengan un rango de alcance de al menos un metro de longitud. También el tamaño que presentan los sensores de baja frecuencia es mucho más reducido lo que facilita su integración en las diferentes estructuras sensoriales que se van a proponer. Y en tercer lugar se han seleccionado de tipo piezoeléctrico, además de su tamaño más reducido, porque no es necesario aplicar tensiones de polarización por lo que la electrónica necesaria para su excitación es menos compleja.

Con todo ello los sensores seleccionados para los trabajos experimentales realizados en esta tesis han sido Murata 40B8 R/S y SensComp 40LT16/40LR16. En la figura 1.8 se muestra su aspecto físico y en las tablas 1.1 y 1.2 se indican las características generales que ofrece el fabricante.



Figura 1.8: a) Sensor Murata 40B8 R/S b) SensComp 40LT16/40LR16

Frecuencia	40 KHz
Longitud de onda $\lambda$ (mm)	8.58
Ángulo lóbulo principal(-6dB)	50°
Diámetro del encapsulado(mm)	16
Diámetro interno aproximado (mm)	13
Radio $a$ (mm)	6.5
Campo lejano $d > \frac{a^2}{\lambda} - \frac{\lambda}{4}$ (mm)	>2.8
Nivel de presión sonora transmitida a 40Khz	120±3dB
Sensibilidad en la recepción a 40Khz	-63±3dB
Capacidad ±20 %	2000 pF
Máximo voltaje de operación (cont)	20Vp-p

Tabla 1.1: Especificaciones transductores Murata 40B8 R/S

Frecuencia	40.0±1.0KHz
Longitud de onda $\lambda$ (mm)	8.58
Ángulo lóbulo principal(-6dB)	55°
Diámetro del encapsulado (mm)	16
Diámetro interno aproximado (mm)	12
Radio $a$ (mm)	6
Campo lejano $d > \frac{a^2}{\lambda} - \frac{\lambda}{4}$ (mm)	>2.1
Nivel de presión sonora transmitida a 40Khz 0dB re 0.0002 $\mu$ bar; para 10Vrms a 30cm	120dB min
Sensibilidad en la recepción a 40Khz 0dB = 1 volt/ $\mu$ bar	-65dB min
Capacidad a 1Khz $\pm 20\%$	2400 pF
Máximo voltaje de operación (cont)	20Vrms

Tabla 1.2: Especificaciones transductores SensComp 40LT16/40LR16

## 1.4. Disposición física de los sensores, estructuras sensoriales y reflectores tipo.

Se analizan a continuación las disposiciones físicas de los sensores más empleadas. En los estudios realizados con ultrasonidos en aire pueden encontrarse variadas configuraciones de sensores buscando las ventajas que cada una de ellas puede aportar. Se pueden encontrar desde configuraciones simples, formada por un único sensor emisor-receptor o un par de sensores en configuración emisor- receptor como las utilizada por R. Kuk y F. Moita en [38, 60], o formadas por una pareja de sensores trabajando sobre un sistema rotatorio como las empleadas por G. Benet y M. Martínez en [12, 54]. En estas configuraciones, si se emplea únicamente el parámetro del tiempo de vuelo del eco, la información recibida del entorno es reducida. Se plantean en este caso mejoras que incrementen la información, como por ejemplo la toma de datos variando la posición física, o la realización de un análisis más profundo de la información contenida en el eco.

Aumentando la complejidad se puede encontrar configuraciones formadas por combinaciones de emisores y receptores. Comenzando por la configuración

mas sencilla, que en este caso estaría formada por tres sensores alineados en configuración receptor-emisor-receptor como la empleada por H. Peremans en [64] .

Otras configuraciones empleadas son las formadas por arrays lineales como la formada por un emisor y cuatro receptores empleada por A.M. Sabatini en [69] o la generalización a un número variable de parejas de emisor-receptor utilizada por B. Barsha en [8].

En [18] M. Brudka emplea un array lineal de 5x2 sensores colocados como cinco parejas de emisor y receptor. En este trabajo además se aprovecha del movimiento de los objetos sobre una cinta transportadora para poder tomar información del objeto en dos dimensiones. En [81] S. Watanabe emplea un array estático de 8x8 sensores para el reconocimiento tridimensional de objetos.

También se han empleado en diversos trabajos configuraciones circulares de sensores de ultrasonidos como las utilizadas por J. Borenstein y D. Baskent en [16, 11].

El modelado del proceso de reflexión de los ultrasonidos ayuda a interpretar la información del eco. Según [38] para aplicaciones de navegación autónoma se pueden agrupar en tres tipos básicos: planos, esquinas y bordes, consiguiéndose mediante su combinación reconstruir una aproximación del entorno. En caso de superficies desiguales, rugosas o formadas por una variedad de pequeños objetos los ecos generados serán complejos, de forma y aspecto variado y de difícil interpretación ya que la forma del eco no corresponde a un eco simple sino a la suma de los ecos individuales de todos los caminos de retorno sobre cada una de las superficies. Por lo tanto este tipo de análisis puede realizarse para entornos simples, ya que si el entorno es muy complejo puede producir señales erróneas. Diversos autores han desarrollado métodos para discernir entre señales reales y erróneas por diferentes métodos. El primero basado en hardware, construyendo sensores inteligentes con la electrónica necesaria para eliminar los falsos ecos, que da como resultado sistemas complejos y muy costosos como por ejemplo [16, 34] donde j. Borenstein modifica las señales de excitación. También variando la estructura sensorial empleada, formando diferentes tipos de arrays como H. Peremans en [65]. O también mediante sistemas basados en post-procesamiento software como por ejemplo realiza R. Kuc en [36].

Para las aplicaciones de los sensores de ultrasonidos al reconocimiento de entornos estructurados se indican a continuación los tipos de reflectores que se han venido utilizando en los trabajos realizados sobre generación de mapas de entorno para su aplicación en robótica móvil.

### **Reflector tipo plano.**

Un reflector plano es una superficie lisa que actúa como un espejo acústico según se muestra en la figura 1.9a). Paredes y puertas actúan como reflectores planos si su superficie es lo suficientemente extensa para contener la totalidad del haz ultrasónico del transductor empleado. Si la superficie es pequeña se producirán ecos más débiles debido a la menor extensión de la superficie reflectante y a la interferencia destructiva con los ecos producidos por la difracción de los bordes del plano. El análisis para reflexiones sobre planos puede realizarse mediante fuentes virtuales.

### **Reflector tipo esquina.**

Un reflector esquina es la intersección de dos planos con un determinado ángulo formado una superficie cóncava según se muestra en la figura 1.9b). Intersecciones de paredes, puertas y demás cerramientos de interior pueden interpretarse como esquinas. Una característica diferencial de las esquinas es que en la reflexión se producen rebotes entre los planos. Las fuentes virtuales se obtienen por la reflexión del transductor primero sobre uno de los planos y después sobre el otro.

### **Reflector tipo borde.**

Un borde corresponde con las esquina convexa y superficies de gran curvatura según muestra la figura 1.9c). En este caso el punto de reflexión es prácticamente independiente de la posición del transductor. A diferencia de los planos y esquinas, los reflectores de tipo borde generar ecos débiles que sólo se detectan a corta distancia.

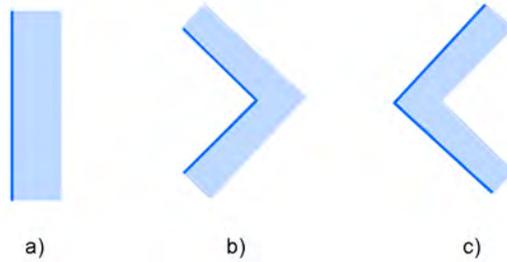


Figura 1.9: Tipos de reflectores básicos: a) plano, b) esquina, c) borde

## 1.5. Procesado del eco ultrasónico.

### 1.5.1. Método pulso-eco.

La mayoría de los módulos comerciales de medida de distancias en aire basados en ultrasonidos, ya sea mediante un único sensor emisor-receptor o una pareja de sensores emisor y receptor próximos entre si, trabajan mediante la técnica pulso-eco. Para ello realizan la excitación del sensor emisor mediante un pulso formado por una serie de ciclos de la señal de emisión. Esta excitación del emisor genera un eco ultrasónico que viaja por el aire, rebota sobre la superficie reflectora y es detectado por el sensor receptor. En la figura 1.10 puede verse un ejemplo de la aplicación de la técnica pulso-eco. Puede verse la señal de excitación, en color cian, aplicada al sensor emisor, y la señal de recepción, en color verde, obtenida del sensor receptor.

De la información contenida en el eco ultrasónico capturado por el sensor receptor, el cálculo del tiempo de vuelo es el parámetro más ampliamente empleado. Este tiempo corresponde al transcurrido desde que comienza a aplicarse la señal de excitación al sensor emisor hasta que comienza a generarse la señal de recepción en el sensor receptor. La obtención de este tiempo de vuelo se puede realizar por diferentes métodos que van desde los más simples, pero más imprecisos, como es el método del umbral, hasta los más complejos, pero más precisos, como son los métodos que emplean la correlación de señales [6].

Para el caso del cálculo del tiempo de vuelo mediante el método de la detección por umbral, la señal recibida por el sensor receptor puede ser tratada mediante una serie de etapas electrónicas que permiten la obtención de dicho tiempo, como pueden verse en la figura 1.11, sin necesidad de capturarse digitalmente.

Para la emisión es necesario implementar una etapa de excitación para el sensor emisor formada por un generador de pulsos y seguidamente un amplificador para aumentar la potencia de la señal de excitación a los niveles que indique la hoja de características de los sensores de ultrasonidos utilizados.

En el caso de la recepción, debido a que el eco ultrasónico se atenúa con la distancia, la señal que se captura puede ser bastante débil, por lo que comúnmente se emplea una etapa de amplificación para aumentar el nivel de señal. Esto es así porque en la detección por umbral es necesario que todos los ecos válidos superen el valor de umbral.

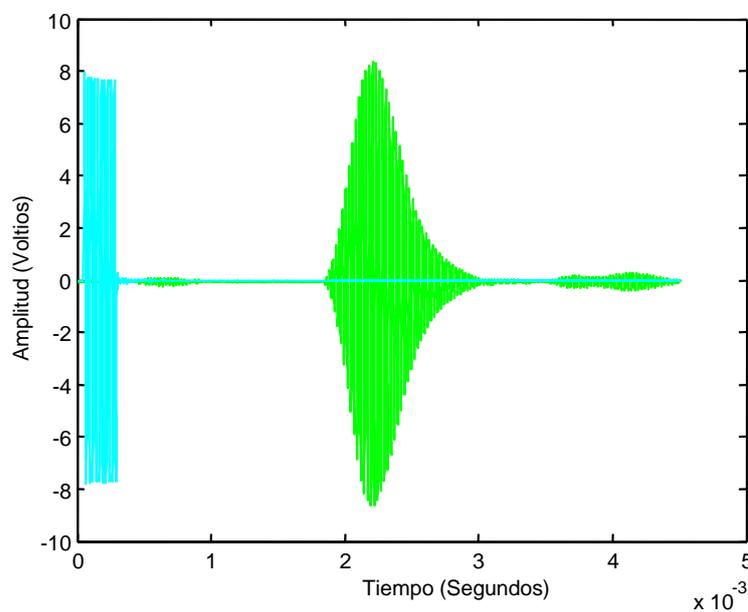


Figura 1.10: Ejemplo de señal de excitación y señal de recepción mediante pulso-eco.

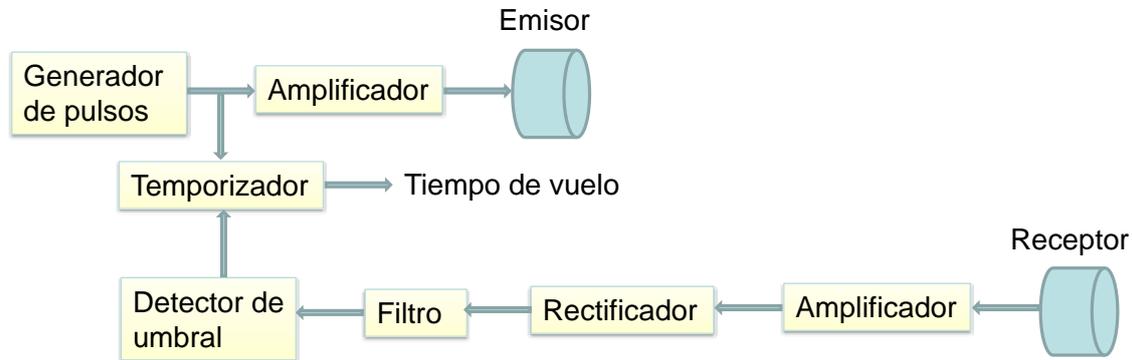


Figura 1.11: Diagrama bloques del proceso de obtención del tiempo de vuelo

Seguidamente a la etapa de amplificación se pasa por una etapa de rectificación y por una etapa de filtrado para quedarse únicamente con la envolvente del eco y finalmente aplicar a dicha señal un detector de umbral. Simultáneamente se necesita incluir un temporizador que mida el tiempo transcurrido desde el comienzo de la emisión -instante en que comenzó la excitación del sensor emisor- y el comienzo de la recepción -instante de tiempo en que la envolvente de la señal recibida alcanza el umbral de tensión- denominando a dicho tiempo como "tiempo de vuelo"  $t_0$  (TDV, time of flight TOF).

De esta forma la distancia entre un par de sensores emisor y receptor muy próximos entre sí, o un sensor emisor-receptor, y la superficie reflectora será la mitad de la distancia recorrida por el eco:

$$d = \frac{c t_0}{2} \quad (1.10)$$

Los sistemas de medición del tiempo de vuelo mediante umbral obtendrán siempre un tiempo mayor que el valor real y dependiente del valor de umbral empleado. La medición de este tiempo de llegada también está afectada por la amplitud del eco. Puede verse en la figura 1.13 como respecto a un umbral constante, los ecos de mayor amplitud tendrán una pendiente de crecimiento del eco mayor lo que se traducirá en un alcance rápido del nivel de umbral fijado. Mientras que ecos débiles, con amplitudes pequeñas tendrán una pendiente de subida menor con lo que le lleva mayor tiempo alcanzar el nivel de umbral.

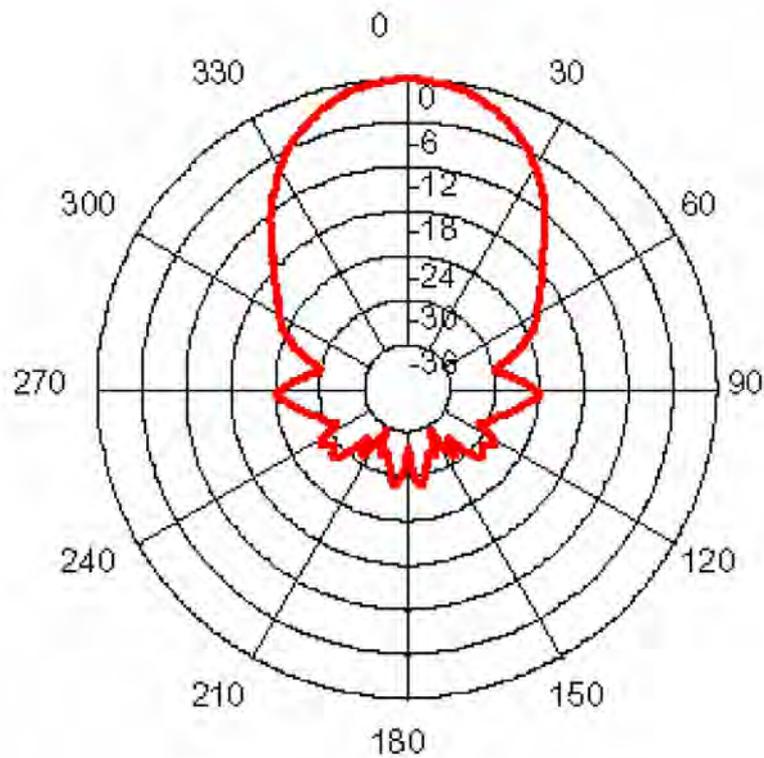


Figura 1.12: Diagrama de radiación de los sensores SensComp 40LR16/LT16

Los sensores de ultrasonidos se modelan como pistones planos que producen un patrón de radiación como por ejemplo el mostrado en la figura 1.12.

Según R. Kuc [38] se asume que el tiempo de llegada del eco (TDV) no cambia significativamente con la orientación del transductor pero si con la amplitud del eco. Los ecos de mayor amplitud presentan una pendiente de subida mayor que los ecos de menor amplitud, y cuando se calcula el tiempo de vuelo por comparación con un umbral producen grandes diferencias. Puede verse en la figura 1.13 cómo al calcular el tiempo de llegada por comparación con el umbral  $h$  en el eco de la figura 1.13 a) se obtiene un tiempo  $t_1$  inferior al tiempo  $t_2$  obtenido en el eco de la figura 1.13b).

Para el cálculo del tiempo de llegada del eco  $t_0$  puede aproximarse la envolvente al eco en esa zona por una función lineal de pendiente proporcional a la amplitud del eco.

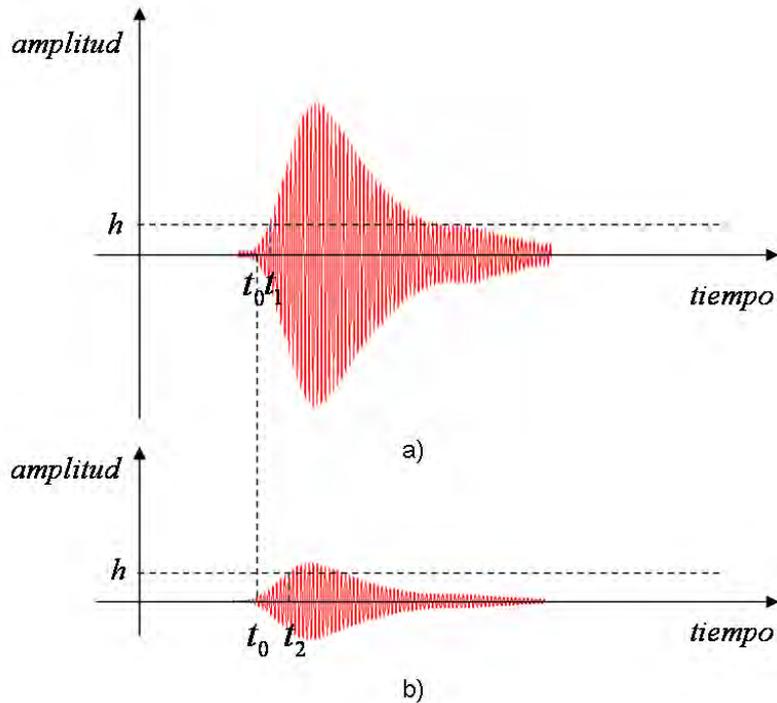


Figura 1.13: Cálculo del tiempo de vuelo por umbral

Luego puede verse que para un valor determinado del umbral  $h$  el retardo incluido en el cálculo del tiempo de llegada del eco será función del ángulo de incidencia sobre la superficie e inversamente proporcional a la amplitud del eco.

Otros métodos de cálculo del tiempo de vuelo, como por ejemplo los basados en la correlación de señales [52], precisan de un procesamiento digital de la señal para poder ser aplicados. En este caso el tiempo de vuelo corresponde al tramo temporal necesario para que exista un determinado nivel de correlación entre la señal portadora y la señal del eco recibido, siendo por tanto independiente de la amplitud que tenga el eco y evitándose los errores debidos al umbral.

En los trabajos experimentales realizados en esta tesis se ha utilizado mayoritariamente la correlación de señales para el cálculo del tiempo de vuelo, para evitar lo más posible los problemas que se han indicado sobre imprecisiones y variabilidad de los resultados debido a las amplitudes de las señales.

### 1.5.2. Procesado digital del eco.

La mayoría de los módulos de control y medida mediante ultrasonidos se quedan exclusivamente en el cálculo del tiempo de vuelo mediante la recepción del primer eco, como por ejemplo el módulo 6500 de Polaroid. De esta forma se pierde mucha información importante que está contenida en la forma del eco ultrasónico.

Generalmente también estos módulos contienen una etapa de ganancias programables que amplifican el eco en función de la distancia para compensar la atenuación de la señal, con lo que generalmente la señal del eco llega saturada perdiéndose también la información sobre la forma del eco.

Antes de realizar ningún tipo de procesado de la señal, el eco ultrasónico recibido por el sensor receptor está formado por una señal modulada en frecuencia. En este trabajo se han empleado sensores de ultrasonidos cuya señal portadora es de 40KHz.

En todos los ensayos experimentales realizados se ha muestreado la señal completa para guardar toda la información del eco, pero en muchas de las aplicaciones propuestas es suficiente con trabajar con la señal moduladora que es la que nos da la información de la forma del eco y que podemos recuperar calculando su envolvente.

Por tanto, en la aplicaciones desarrolladas al eco completo capturado se le va a someter a un proceso de rectificación y filtrado para quedarse únicamente con la envolvente.

Para el calculo de la envolvente se ha utilizado un filtro digital Butterworth. Este filtro se emplea para cancelar la señal portadora a 40KHz y obtener la envolvente del eco. Este tipo de filtros tiene una ganancia prácticamente plana en la banda de paso sin ningún tipo de rizado y en general monótona decreciente.

La función de transferencia de un filtro Butterworth analógico de paso bajo viene dada por:

$$|F(\omega)|^2 = \frac{1}{1 + \left(\frac{\omega}{\omega_c}\right)^{2N}} \quad (1.11)$$

donde:

N: orden del filtro

$\omega$ : frecuencia

$\omega_c$ : frecuencia de corte (caída de 3dB respecto de la banda de paso).

Para convertir el filtro analógico en un filtro digital se ha empleado la transformación bilineal con prewarping entre el plano s y el plano z, que garantiza la misma respuesta frecuencial para la frecuencia elegida:

$$s = c \frac{z - 1}{z + 1} \quad (1.12)$$

donde c viene dado por:

$$c = \frac{\omega}{tg\left(\frac{\omega T}{2}\right)} \quad (1.13)$$

donde:

T: periodo de muestreo.

En nuestro caso el filtro utilizado ha sido un filtro Butterworth de paso bajo de tercer orden con frecuencia de corte de 5KHz cuya función de transferencia es:

$$\frac{Y(z)}{X(z)} = \frac{10^{-4}(0,0376 + 0,1127z^{-1} + 0,1127z^{-2} + 0,0376z^{-3})}{1 - 2,9372z^{-1} + 2,8763z^{-2} - 0,9391z^{-3}} \quad (1.14)$$

Este filtro implementado mediante su ecuación en diferencias queda:

$$y_k = 2,9372y_{k-1} - 2,8763y_{k-2} + 0,9391y_{k-3} + 0,0376 \cdot 10^{-4}x_k + 0,1127 \cdot 10^{-4}x_{k-1} + 0,1127 \cdot 10^{-4}x_{k-2} + 0,0376 \cdot 10^{-4}x_{k-3} \quad (1.15)$$

donde:

k: número de muestra.

En los trabajos experimentales realizados en esta tesis se han empleado tarjetas de adquisición de datos National Instruments de muestreo simultáneo modelo PCI-6115, tanto para la generación de las señales de excitación como

para su captura. Dichas señales se almacenan en el computador para su posterior procesamiento de señal. De esta forma no se pierde información contenida en las señales recibidas y dependiendo de la aplicación permite calcular diferentes parámetros del eco más allá de la simple obtención del tiempo de vuelo.

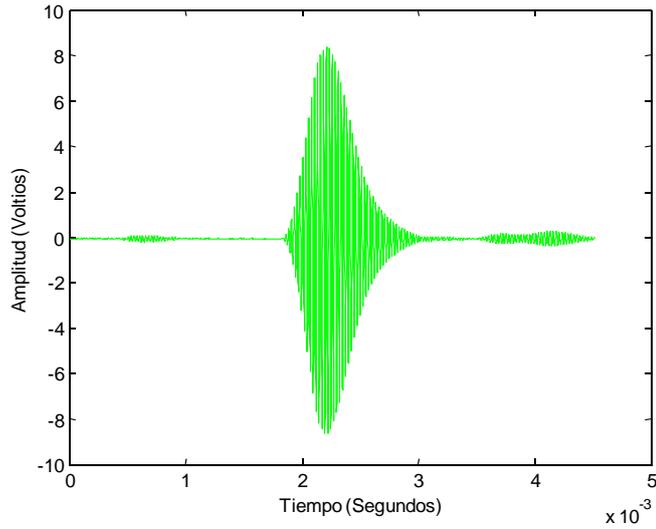


Figura 1.14: Ejemplo de eco recibido

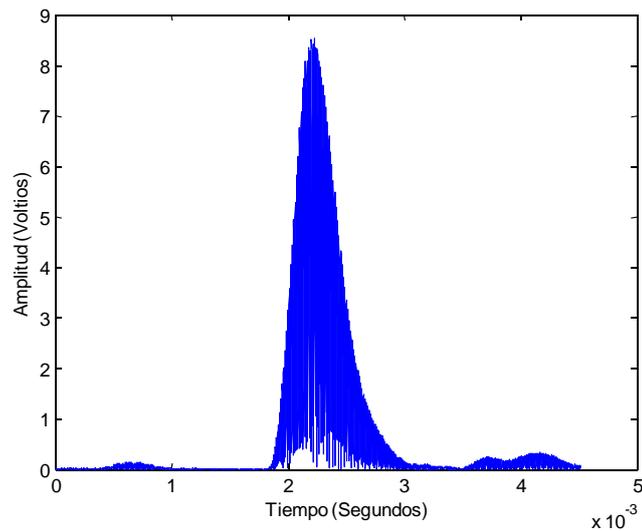


Figura 1.15: Ejemplo de eco rectificado

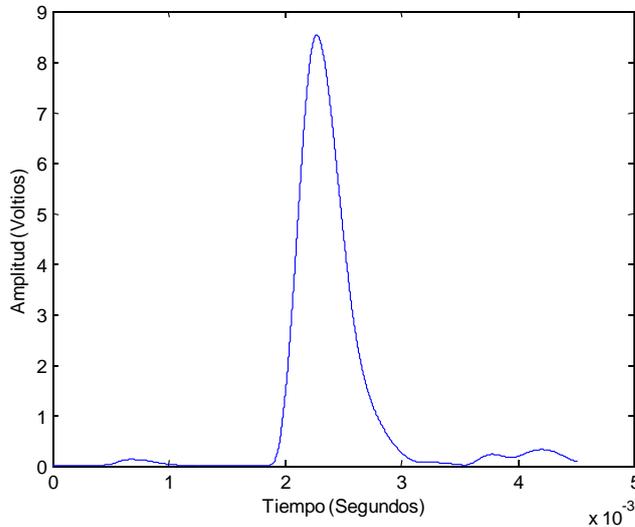


Figura 1.16: Ejemplo de envolvente del eco

En la figura 1.14 puede verse un ejemplo de una señal capturada de un sensor receptor. En la figura 1.15 puede verse dicha señal después del proceso de rectificación, y por último en la figura 1.16 puede verse la envolvente  $e(kT)$  obtenida empleando el filtro de la ecuación 1.15.

### 1.5.3. Parámetros del eco

En muchas de las aplicaciones que se presentan en este trabajo de tesis, se van a emplear diferentes modelos paramétricos basados en características extraídas de los ecos tal como se emplea en la referencia [19, 50, 41] con el fin de reducir el tamaño de la información procedente de los ecos. De esta forma, se pretende conseguir un conjunto de características de los ecos recibidos que permitan después ser comparadas sin necesidad de comparar el eco completo. Para poder extraer la mayor información posible del eco se incluyen a continuación un listado de posibles parámetros a emplear. En función de la aplicación de que se trate se seleccionarán aquellos que aporten mayor información en cada caso. Estos parámetros pueden proceder de un análisis temporal o frecuencial del eco. En este trabajo se han considerado únicamente los parámetros temporales, para reducir el tiempo de procesado y la carga

computacional. Además muchos parámetros frecuenciales tienen una relación directa con otros parámetros temporales, por lo que en muchos de los casos no aportan más información.

En la figura 1.17 se muestra la señal de excitación del sensor emisor y el eco recibido empleando la técnica pulso-eco.

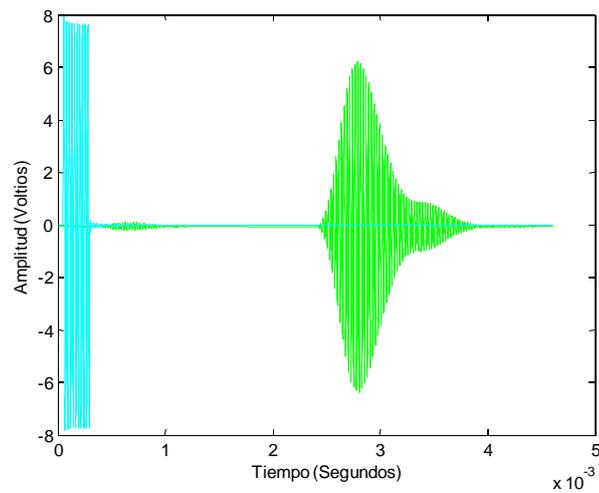


Figura 1.17: Señal de emisión y recepción

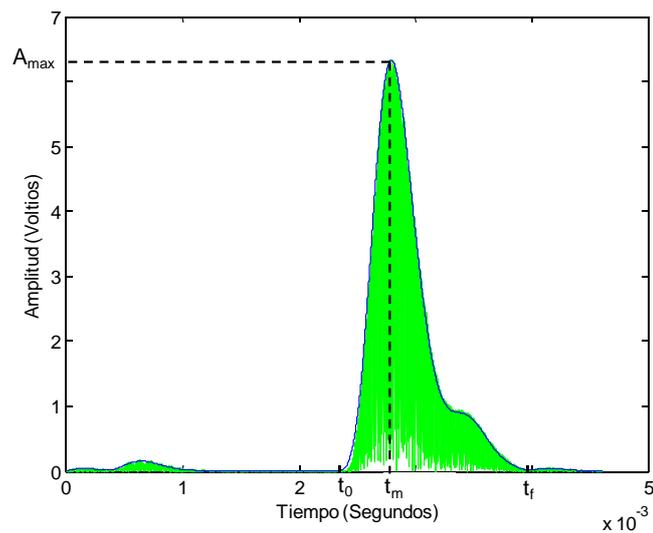


Figura 1.18: Eco rectificado y envolvente

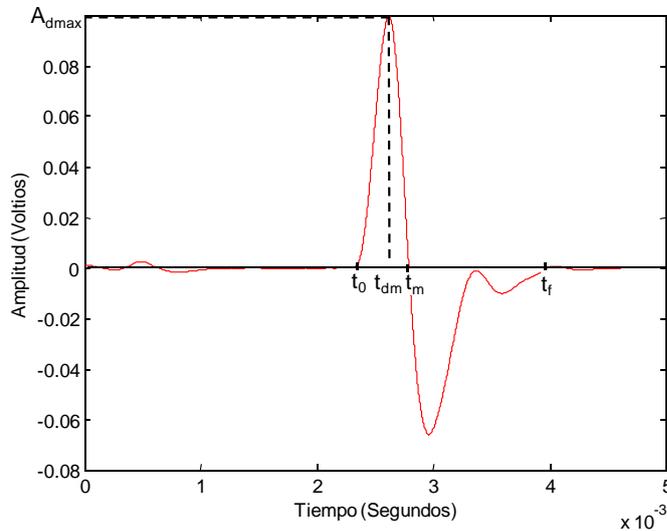


Figura 1.19: Derivada de la envolvente

Mediante la tarjeta de adquisición de datos, empleando un periodo de muestreo  $T$ , se muestrea la señal del eco, se rectifica y se calcula aplicando el filtro digital de la expresión 1.15 su envolvente  $e(kT)$ , donde  $k$  es el número de muestra. Puede verse en la figura 1.18 la representación del eco rectificado y su curva envolvente  $e(kT)$  y en la figura 1.19 la derivada de dicha envolvente.

Se presentan a continuación los parámetros en el espacio temporal extraídos de la envolvente discreta  $e(kT)$  y la derivada  $d(kT)$  de la envolvente del eco:

1. Tiempo de vuelo  $t_0$ : Tiempo transcurrido desde el comienzo de la emisión, instante en se comienza a emitir el tren de pulsos que excita el sensor emisor, hasta el comienzo de la recepción, instante de tiempo en que se empieza a detectar la señal del eco en el sensor receptor.
2. Tiempo de finalización  $t_f$ : Tiempo transcurrido desde el comienzo de la emisión, instante en que se comienza a emitir el tren de pulsos que excita el sensor emisor, hasta el final de la recepción, instante de tiempo en que se termina de detectar la señal del eco en el sensor receptor.
3. Tiempo de máxima amplitud  $t_m$ : Tiempo transcurrido desde el comienzo de la emisión, instante en que se comienza a emitir el tren de pulsos

que excita el sensor emisor, hasta el máximo de la recepción, instante de tiempo en que se alcanza el máximo de señal del eco en el sensor receptor.

4. Máxima amplitud  $A_{max}$ : Amplitud máxima del eco recibido.
5. Área desde  $t_0$  a  $t_m$  : Área bajo la envolvente desde el comienzo del eco hasta el punto de amplitud máxima del eco.
6. Área desde  $t_m$  a  $t_f$  : Área bajo la envolvente desde el punto de amplitud máxima del eco hasta el final del eco.
7. Área desde  $t_0$  a  $t_f$  : Área total bajo la envolvente del eco.
8. Longitud desde  $t_0$  a  $t_m$ : Longitud de la envolvente desde el comienzo del eco hasta el punto de máxima amplitud del eco.
9. Longitud desde  $t_m$  a  $t_f$  : Longitud de la envolvente desde el punto de máxima amplitud del eco hasta el final del eco.
10. Longitud desde  $t_0$  a  $t_f$ : Longitud total de la envolvente desde el comienzo del eco hasta el final del eco.
11. Pendiente entre  $t_0$  y  $t_m$ : Pendiente de la envolvente desde el comienzo del eco hasta el punto de máxima amplitud del eco:

$$p = \frac{A_{max}}{t_m - t_0} \quad (1.16)$$

12. Máxima amplitud de la derivada  $A_{dmax}$ : Valor máximo de la derivada de la envolvente del eco.
13. Tiempo de máxima amplitud de la derivada  $t_{dm}$ : Tiempo transcurrido desde el comienzo de la emisión, instante en que se comienza a emitir el tren de pulsos que excita el sensor emisor, hasta el máximo de la derivada de la envolvente, instante de tiempo en que se alcanza el máximo de señal la derivada de la envolvente del eco.
14. Área de la derivada desde  $t_0$  a  $t_m$  : Área bajo la derivada de la envolvente desde el comienzo del eco hasta el punto de amplitud máxima del eco.

15. Área de la derivada desde  $t_m$  a  $t_f$  : Área bajo la derivada de la envolvente desde el punto de amplitud máxima del eco hasta el final del eco.
16. Área de la derivada desde  $t_0$  a  $t_f$  : Área total bajo la derivada de la envolvente del eco.
17. Longitud de la derivada desde  $t_0$  a  $t_m$ : Longitud de la derivada de la envolvente desde el comienzo del eco hasta el punto de máxima amplitud del eco.
18. Longitud de la derivada desde  $t_m$  a  $t_f$  : Longitud de la derivada de la envolvente desde el punto de máxima amplitud hasta el final del eco.
19. Longitud de la derivada desde  $t_0$  to  $t_f$ : Longitud total de la derivada de la envolvente desde el comienzo del eco hasta el final del eco.
20. Pendiente entre  $t_0$  y  $t_{dm}$ : Pendiente de la envolvente desde el comienzo del eco hasta el punto de máxima amplitud del eco:

$$p = \frac{A_{dmax}}{t_{dm} - t_0} \quad (1.17)$$

21. Tiempo de comienzo del primer eco: Tiempo transcurrido entre el comienzo de la emisión y el comienzo de la recepción del primer subeco dentro del eco. Coincide con  $t_0$ . Se van a denominar subecos, a los diferentes ecos que forman la respuesta total recibida y que se generan al estar recibiendo el sensor rebotes de distintas superficies.
22. Tiempo de máximo del primer eco: Tiempo transcurrido entre el comienzo de la emisión y el máximo del primer subeco dentro del eco de la recepción.
23. Energía del primer eco: Energía de la envolvente discreta del primer subeco.

$$E = \sum_{kT=t_0}^{kT=t_1} \left[ \frac{e((k-1)T) + e(kT)}{2} T \right]^2 \quad (1.18)$$

24. Potencia del primer eco: Potencia media de la envolvente discreta del primer subeco:

$$P = \frac{E}{t_1 - t_0} \quad (1.19)$$

25. Tiempo de comienzo del segundo eco  $t_1$ : Tiempo transcurrido entre el comienzo de la emisión y el comienzo de la recepción del segundo subeco dentro del eco.

26. Tiempo de máximo del segundo eco  $t_{1m}$ : Tiempo transcurrido entre el comienzo de la emisión y el máximo del segundo subeco dentro del eco de la recepción.

27. Energía del segundo eco: Energía de la envolvente discreta del segundo subeco.

$$E = \sum_{kT=t_1}^{kT=t_f} \left[ \frac{e((k-1)T) + e(kT)}{2} T \right]^2 \quad (1.20)$$

28. Potencia del segundo eco: Potencia media de la envolvente discreta del segundo subeco:

$$P = \frac{E}{t_f - t_1} \quad (1.21)$$

En la tabla 1.3 se resumen los diferentes parámetros que se extraen de los ecos capturados por los sensores receptores para su posterior empleo en las diferentes aplicaciones prácticas desarrolladas. Posteriormente en cada aplicación se irán indicando el subconjunto empleado en cada caso.

## 1.6. Resumen y conclusiones del capítulo

En este primer capítulo se ha mostrado una breve introducción a los ultrasonidos en la que se han presentado sus conceptos básicos, su problemática y los principales tipos de sensores de ultrasonidos para trabajar en aire que pueden encontrarse.

Se ha descrito a continuación las diferentes estructuras sensoriales que diversos autores han ido empleando en sus trabajos de investigación, partiendo

desde la configuración más simple formada únicamente por un sensor emisor y un sensor receptor, hasta las más complejas formadas por arrays de sensores de variadas formas.

A continuación se ha realizado una pequeña introducción a la reflexión ultrasónica, indicando aquellos elementos que se consideran tipo para el reconocimiento de entornos estructurados.

Número	Parámetro
1	Tiempo de vuelo
2	Tiempo de finalización
3	Tiempo de máxima amplitud
4	Máxima amplitud
5	Área desde $t_0$ a $t_m$
6	Área desde $t_m$ a $t_f$
7	Área desde $t_0$ a $t_f$
8	Longitud desde $t_0$ a $t_m$
9	Longitud desde $t_m$ a $t_f$
10	Longitud desde $t_0$ to $t_f$
11	Pendiente entre $t_0$ y $t_m$
12	Máxima amplitud de la derivada
13	Tiempo de máxima amplitud de la derivada
14	Área de la derivada desde $t_0$ a $t_m$
15	Área de la derivada desde $t_m$ a $t_f$
16	Área de la derivada desde $t_0$ a $t_f$
17	Longitud de la derivada desde $t_0$ a $t_m$
18	Longitud de la derivada desde $t_m$ a $t_f$
19	Longitud de la derivada desde $t_0$ a $t_f$
20	Pendiente de la derivada entre $t_0$ y $t_{dm}$
21	Tiempo de comienzo del primer eco
22	Tiempo de máximo del primer eco
23	Potencia del primer eco
24	Energía del primer eco
25	Tiempo de comienzo del segundo eco
26	Tiempo de máximo del segundo eco
27	Potencia del segundo eco
28	Energía del segundo eco

Tabla 1.3: Parámetros para la caracterización del eco

Se dedica la última sección a mostrar el método de funcionamiento empleado para la generación de las señales ultrasónicas como es la técnica pulso-eco. Se incluye la descripción del proceso que va desde la generación de la señal ultrasónica en el sensor emisor hasta la captura del eco en el sensor receptor. Seguidamente se muestra también el procesado digital que se va a realizar tras la captura del eco para la obtención de su envolvente y finalmente se incluye la serie de parámetros característicos del eco que se van a emplear en la experimentación.



## Capítulo 2

# Reconocimiento de patrones mediante redes neuronales.

### 2.1. Introducción

El reconocimiento de objetos y su clasificación es una parte fundamental de muchos procesos de automatización como por ejemplo aquellos que requieren la intervención de manipuladores. A la hora de poder realizar la captura de una pieza por un manipulador es necesario saber de qué objeto se trata y en qué posición se encuentra para poder generar la trayectoria de acercamiento apropiada y posicionar la pinza adecuadamente para su captura. Pensando en ese tipo de operaciones automatizadas se propone en este capítulo el diseño de diferentes clasificadores utilizando las redes neuronales.

Los métodos de reconocimiento de patrones a partir de datos obtenidos, en nuestro caso de un objeto, se encargan de extraer aquellas regularidades, es decir patrones, que son significantes para poder realizar su discriminación cuando el objeto a reconocer se encuentra en un entorno complejo o con presencia de ruidos. Por este motivo el reconocimiento de patrones es de gran aplicación en las tareas de reconocimiento automático en el entorno industrial.

En este capítulo se presenta el análisis de una de las técnicas de inteligencia artificial que mayor interés ha despertado en los últimos años, aunque ya tiene unos sesenta años de antigüedad, y de la que existen innumerables aplicaciones

en los más diversos campos científicos. Parte de su enorme interés está en que se inspiran en el funcionamiento, al menos en los principios básicos de funcionamiento, de las redes neuronales biológicas.

Se propone en este capítulo el desarrollo mediante redes neuronales de sistemas de reconocimiento de patrones basado en la información proveniente de sensores de ultrasonidos.

Se presenta en primer lugar una introducción a las redes neuronales, donde se muestra su filosofía de funcionamiento, los elementos que las integran, sus diferentes arquitecturas, sus métodos de aprendizaje y por último los tipos de redes más estandarizados.

A continuación se detallan las propuestas y resultados de la experimentación realizada para el reconocimiento de formas y orientación de piezas.

En cada uno de los casos analizados se realizará en primer lugar el desarrollo de la estructuras sensorial que nos provea de la información necesaria del objeto para poder abordar la tarea de la clasificación, en segundo lugar se realizará el tratamiento y análisis de esos datos para poder extraer y seleccionar aquellos parámetros que mejor discriminen en cada caso y por último se realizarán los diseños de los clasificadores mediante redes neuronales para tareas tanto de reconocimiento de objetos como de identificación de su posición.

## **2.2. Introducción a las redes neuronales.**

Al igual que las redes de neuronas biológicas, las redes neuronales artificiales tienen como punto de partida la idea del procesado en paralelo. Así, la estructura de cada red esta basada en una serie de bloques constructivos denominados “neuronas” y que son los encargados de realizar las tareas de procesado. Estos bloques procesadores independientes están conectados entre sí, transmitiéndose información de unos a otros.

Ya a principios de los años cuarenta aparecen las primeras redes neuronales, a través de los trabajos de W. McCulloch y W. Pitts [55], en los que observaron el incremento computacional obtenido al combinar pequeños elementos computacionales independientes, esto es, una neurona, formando una

red neuronal. En este caso, los pesos (base de conocimiento de la neurona) se ajustaban de forma que cada procesador (neurona) realizase una función lógica determinada.

En torno a los años cincuenta, D. Hebb presenta la primera regla de aprendizaje [29], en la que plantea que si dos neuronas están activas al mismo tiempo la conexión entre ambas debe reforzarse. Esta idea, que en principio puede ser algo general, ha sufrido sucesivos refinamientos [35, 3], que permiten el aprendizaje automático de la red neuronal en base a la presentación de sucesivos ejemplos.

Los investigadores Block, Minsky y Papert [15, 59], entre otros, introdujeron y desarrollaron, a finales de los años cincuenta y primeros de los sesenta, una clase de red neuronal denominada “perceptrón”. Esta red permite la clasificación de problemas linealmente separables y presenta una regla de aprendizaje que utiliza un ajuste iterativo de las conexiones entre neuronas (pesos).

A primeros de los sesenta, B. Widrow y M. Hoff presentaron una regla de aprendizaje [82] que permite el ajuste de las conexiones entre las neuronas mediante la aplicación de un algoritmo de mínimos cuadrados, dando lugar a nuevas redes de neuronas de comportamiento lineal, denominadas “adaline” (adaptive linear neuron).

En la década de los años setenta algunos investigadores tales como T. Kohonen y J. Anderson, estudiaron otro tipo de redes con memoria asociativa [35, 3].

Durante la década de los años ochenta, las investigaciones sobre redes neuronales experimentaron un fuerte auge y aparecieron nuevos desarrollos, tales como las reglas de propagación del aprendizaje para redes más complejas (más de una capa), denominado “backpropagation” [68]. Este fuerte auge se mantiene hoy en día y viene motivado en parte por la disponibilidad de elevadas capacidades computacionales a bajo coste, lo cual permite desarrollar algoritmos de aprendizaje más potentes, redes más complejas y, sobretodo, utilizar todos estos nuevos desarrollos en aplicaciones reales.

En los últimos años se han desarrollado aplicaciones de las redes neuronales artificiales en los más diversos campos científicos. Como breves ejemplos se pueden presentar los siguientes.

Las redes neuronales pueden entrenarse para el diagnóstico médico en base

a la utilización de expedientes médicos como elementos de entrenamiento y ajuste de la red. Una vez entrenada, y en función del conjunto de síntomas introducidos, la red proporcionará el diagnóstico.

En los procesos automatizados de producción es muy común la necesidad de controlar el comportamiento de un sistema complejo y no lineal del que se desconoce perfectamente la formulación matemática que describe su comportamiento, pero sí que se dispone de un histórico de las actuaciones realizadas por un operador humano y las respuestas del sistema a estas. Estos históricos se utilizan como patrones de aprendizaje y ajuste automático de los pesos de la red, de forma que se pueden obtener redes que modelen de comportamiento del sistema y redes que actúen tal y como lo haría el experto humano.

Existe un gran número de problemas que están asociados al reconocimiento de patrones, por ejemplo cabe citar el reconocimiento de matriculas de vehículos para acceso a edificios, de caracteres escritos a mano, de personas para control de accesos, reconocimiento de la palabra hablada, etc. Para este tipo de problemas existen redes multicapa (backpropagation) que pueden ser utilizadas con éxito en la mayoría de estas aplicaciones.

El número de aplicaciones en procesamiento de señal crece día a día, impulsado por el fuerte crecimiento que han experimentado los sistemas de comunicaciones. Así, las redes neuronales se aplican con gran éxito en supresión de ruido de las líneas telefónicas (mediante filtros adaptativos con redes de tipo lineal), en asignación de canales en comunicaciones móviles, en detectores de secuencias, para establecimiento secuencial ordenado de tareas, etc.

Las redes neuronales han sido empleadas como clasificadores de patrones en numerosas aplicaciones [40] como una alternativa a otros tipos de clasificadores tradicionales como los estadísticos.

Su uso aplicado a las señales de ultrasonidos trata de emular las capacidades de percepción y reconocimiento de los seres humanos y los animales, como puede verse en los trabajos de W.W. Au [4] y H.L. Roitblat [66]. También B. Barshan en [7] emplea las redes neuronales para procesar información proveniente de sensores de ultrasonidos en aire empleando la amplitud y el tiempo de vuelo de los ecos, demostrando además su robustez ante falta parcial de la información de los ecos. Recomendando ampliamente el uso de redes neuronales

como clasificador de patrones para robótica.

Además, la robustez en el funcionamiento de las redes neuronales permite trabajar con información que presente ruido como es el caso de las señales provenientes de sensores de ultrasonidos. Como características de los ecos ultrasónicos predominantemente empleadas en multitud de estudios han estado el tiempo de vuelo y la máxima amplitud de la señal recibida.

Entre las aplicaciones de redes neuronales a los ultrasonidos en aire pueden encontrarse el trabajo de S. Watanabe [81] donde se realiza un sistema de reconocimiento 3-D de objetos combinando la imagen acústica recibida de un array de 8x8 sensores con tres tipos de redes neuronales. La primera se emplea para identificar la categoría del objeto, la segunda para estimar su posición y la tercera para mejorar la imagen. En [21] A. Carullo plantea una mejora del cálculo del tiempo de vuelo mediante la combinación de dos redes neuronales, primero una de tipo competitivo supervisada y segundo un perceptron multicapa. También Y.H. Tseng [77] emplea una red neuronal feedforward estándar para realizar un reconocimiento de objetos a partir de vistas parciales empleando directamente la información del eco sin extracción de características. En el trabajo publicado por R. Gutierrez Osuna [28] se emplean una red de backpropagation para generar un modelo que devuelve información de la probabilidad de detectar un objeto en el entorno de navegación de un robot móvil dada su posición y orientación relativa.

En [51] X. Ma emplea una red neuronal para controlar un robot móvil basado en las distancias entre el robot y los diferentes obstáculos que se encuentra calculados a partir de sensores de ultrasonidos.

En [18] M. Brudka aplica las redes neuronales para realizar tareas de clasificación de objetos y tareas de planificación de captura de objetos mediante la pinza del robot.

En [61] N. Achour emplea las redes neuronales en dos etapas para construir mapas de entorno para su empleo en robótica móvil autónoma en interiores. La primera red se emplea para escanear el espacio de trabajo y realizar el reconocimiento del entorno y la segunda para la generación del mapa.

## 2.3. Redes Neuronales Artificiales

Las redes neuronales artificiales pretenden emular el comportamiento básico de las biológicas. Así, cada neurona es un procesador independiente que es capaz de conectarse con muchas otras neuronas para formar una red neuronal artificial.

Tal y como se puede ver en la figura 2.1, cada neurona tiene un conjunto de entradas que simulan el comportamiento de las dendritas en las biológicas. Estas entradas vienen ponderadas por unos valores que se denominan *pesos* y que, a través de la selección de su valor, es posible establecer la fortaleza de la conexión entre neuronas.

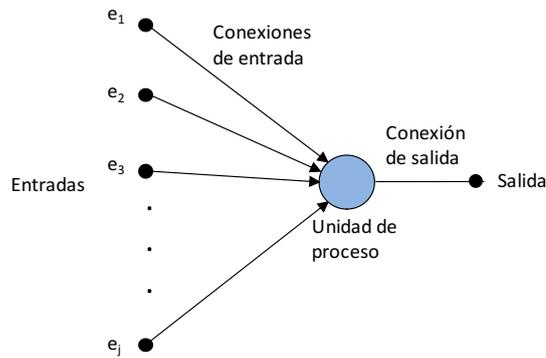


Figura 2.1: Diagrama de neurona artificial

Así mismo, la neurona presenta una unidad de proceso local que simula el comportamiento del núcleo de la neurona biológica y que realiza la suma algebraica de las aportaciones recibidas por las diferentes conexiones de entrada. Tal y como se mostrará en apartados posteriores, en esta unidad de proceso se integran diferentes tipos de funciones, denominadas “funciones de activación”, que permiten obtener neuronas con diferentes características y comportamientos.

Finalmente, la salida de la neurona, que simula el axón y las terminaciones de este en una neurona biológica, recoge el resultado de la unidad de procesado y lo transmite a todas aquellas neuronas que se conecten a ella.

Sin embargo, y al igual que en las biológicas, la potencialidad de una única

neurona es mínima por lo que es necesario agruparlas en redes de neuronas para obtener suficiente capacidad de aprendizaje.

A diferencia de las redes biológicas, en las redes neuronales artificiales solo se establecen topologías planas, esto es, en dos dimensiones y, tal y como se verá más adelante, se establecen ciertas limitaciones en las conexiones entre neuronas. Así, una vez establecida una neurona, la siguiente arquitectura más compleja que se puede establecer es lo que se denomina “una capa de neuronas”, que presenta una agrupación lineal de neuronas, tal y como indica la figura 2.2. En este caso, y de forma genérica, cada una de las entradas está conectada a todas las neuronas de la capa.

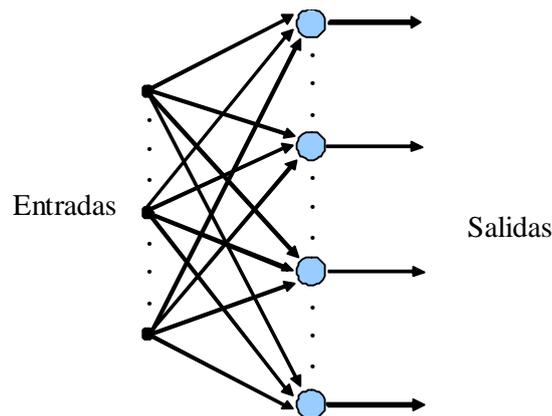


Figura 2.2: Agrupación de neuronas en una capa

Así, la forma de obtener redes de neuronas artificiales es mediante la conexión sucesiva de capas de neuronas, consiguiendo una red neuronal formada por  $n$  capas de neuronas interconectando las salidas de una en las entradas de las siguientes. La figura 2.3 muestra una estructura general de una red neuronal. Si bien en la figura señalada el número de neuronas en cada capa es idéntico, esto no tiene por que ser así, si no que puede variar el número, y el tipo, de neuronas en cada capa.

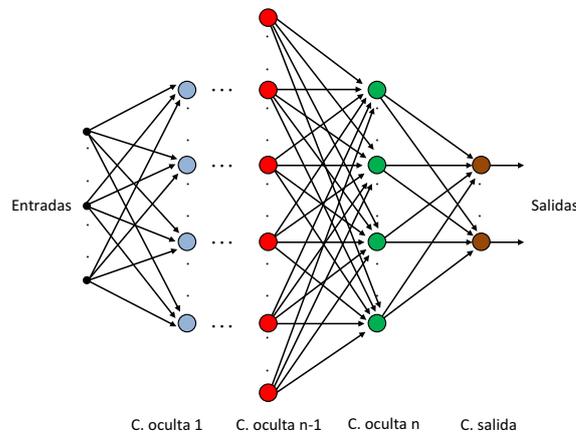


Figura 2.3: Agrupación de neuronas formando una red neuronal

De esta forma, se dispone de una red neuronal artificial formada por procesadores locales distribuidos por toda la red, capaces de operar en paralelo. Las características y comportamiento de estos procesadores depende de la función de activación seleccionada para cada uno de ellos y de las señales de entrada recibidas.

La base de conocimiento está formada por los pesos (valores de ponderación) que se establecen en las conexiones entre neuronas, con lo cual, el conocimiento no está concentrado en un determinado punto si no que se encuentra distribuido por toda la red.

La labor del ingeniero de conocimiento, en este caso, está en la selección de la arquitectura de la red neuronal, definiendo el número de capas, las neuronas y el tipo de estas por cada capa, y en seleccionar el conjunto de información adecuada para que la red neuronal sea capaz de aprender la tarea requerida. Raramente es el ingeniero de conocimiento el que aporta la base de conocimiento directamente a la red mediante el ajuste de los pesos, si no que, aunque como se verá más adelante existen diferentes modos de aprendizaje, es el propio algoritmo de aprendizaje el que se encarga de ajustar de forma automática los pesos de todas las conexiones de las neuronas, para conseguir seguir un determinado patrón de comportamiento. Para esto, es común el proporcionar a la red ejemplos de comportamiento, formados por un conjunto de valores de entrada y sus salidas correspondientes.

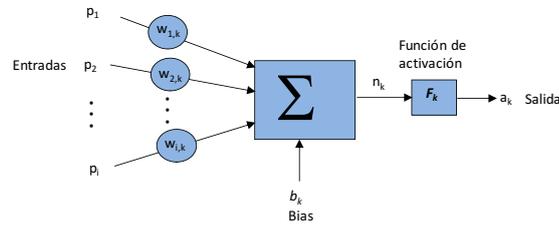


Figura 2.4: Estructura de una neurona artificial.

## 2.4. Elementos de una red neuronal

Como se ha indicado, una red neuronal está formada por un conjunto de unidades simples de procesamiento llamadas neuronas, las cuales se comunican entre sí a través del envío de señales de una a otras mediante una serie de conexiones ponderadas, establecidas en función de la topología y tipo de red.

Las redes neuronales se organizan en forma de capas de neuronas conectadas entre sí lo que facilita el procesamiento en paralelo de la información puesto que muchas neuronas pueden realizar sus cálculos al mismo tiempo. En cualquiera de las posibles topologías de redes neuronales existe una serie de parámetros y elementos que van a formar parte de la red y que son sumamente importantes para entender su funcionamiento. A continuación se presentan los elementos básicos de que está formada una neurona simple.

**Neuronas** A cada unidad simple de una red neuronal se le denomina neurona, celda o unidad de procesamiento. Cada una de las unidades de procesamiento recibe las entradas, que serán las salidas de unidades de proceso vecinas o nuevas entradas y realiza el cálculo de la salida. Para que las salidas de las neuronas sean las deseadas es necesario realizar el ajuste de los elementos que unen unas neuronas con otras llamados pesos. En la figura 2.4 se presenta la estructura típica de una de estas celdas o neuronas así como los componentes que la constituyen. En la citada figura puede verse cómo las entradas  $x_i$  a la neurona vienen ponderadas por los pesos de las conexiones  $w_{i,k}$  y cómo todas estas señales son sumadas y su salida enviada a la función de activación para obtener la salida correspondiente a esta neurona.

## 2.5. Elementos de una neurona

A continuación se indican detalladamente los elementos fundamentales de que está formada una neurona:

**Entradas:** Las entradas  $x_i$  a una neurona pueden provenir de entradas directas a la red neuronal, es decir, entradas del exterior de la red, o también pueden provenir de salidas de una neurona vecina.

**Bias:** El bias  $b_k$  es otra entrada de una neurona  $k$  que durante su funcionamiento permanece fijada a un valor constante. Esta entrada se denomina también como umbral u offset y se emplea para modificar el valor resultante de la composición del resto de las señales de entrada a la neurona. La entrada de bias se mantiene en un valor constante y el efecto que produce es un desplazamiento del valor global en una cantidad constante  $b_k$ .

**Salidas:** La salida  $a_k$  de una neurona  $k$  corresponde con el estado de activación de dicha neurona. Por ejemplo, para una neurona con salidas en el rango  $[0,1]$ , que la salida sea 0 corresponde con que la neurona está totalmente desactivada y que la salida sea 1 corresponde con que esté totalmente activada, y valores intermedios darán niveles de activación intermedios.

**Conexiones entre neuronas:** Cada una de las posibles conexiones entre las neuronas que constituyen la red viene ponderada por un factor llamado peso  $w_{ik}$  que determina el efecto que la señal procedente de unidad  $i$  tiene sobre la neurona  $k$  a la que envía su señal, es decir, la fuerza de las conexiones existentes. A partir de todas las señales de entrada que le llegan a una neurona se ha de obtener un único valor global de entrada.

Se denomina entrada global  $n_k$  al valor obtenido como suma de todas las entradas externas que le llegan a una neurona  $k$  ponderadas cada una de ellas por el valor de su peso más la suma del valor del bias  $b_k$ . La expresión matemática que define su comportamiento es.

$$n_k = \sum_{i=1}^n w_{ik} \cdot p_i + b_k \quad (2.1)$$

donde:

$n_k$ : Entrada global para la neurona  $k$

$p_i$ : Entrada  $i$  de la neurona

$w_{ik}$ : Peso para la entrada  $i$  de la neurona  $k$

$b_k$ : Bias de la neurona  $k$

Ésta es la función más estándar para el cálculo de la entrada global a la neurona pero existen otras posibilidades. A las contribuciones debidas a pesos positivos se las suele denominar excitaciones y a las correspondientes a pesos negativos inhibiciones.

**Función de activación:** La función de activación representa la diferencia fundamental que distingue la respuesta de unas neuronas a otras. Esta función se emplea para calcular la salida de la neurona una vez que se tiene la entrada global.

La función de activación  $F_k$  normalmente toma como entrada la entrada global ponderada  $n_k$  y calcula el nuevo estado de activación, es decir, su salida  $a_k$ .

$$a_k = F_k n_k = F_k \sum_{i=1}^n w_{ik} \cdot p_i + b_k \quad (2.2)$$

Debido a que las entradas a la neurona  $k$  son las salidas de las neuronas a las que están conectadas sus entradas, esta expresión se suele poner como también como:

$$a_k = F_k \sum_i w_{ik} \cdot a_i + b_k \quad (2.3)$$

El caso más general sería aquel en que la función de activación depende de la entrada global  $n_k$  y del último valor de activación de la neurona. En este caso la expresión sería:

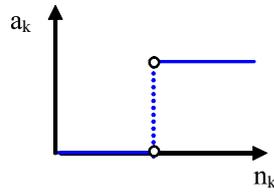


Figura 2.5: Función de activación umbral.

$$a_k(t + 1) = F_k a_k(t), n_k(t) \quad (2.4)$$

Como ya se ha indicado la función de activación va a proporcionar a la neurona unas características propias dependiendo del tipo de función de activación que se seleccione. Normalmente las funciones de activación son funciones no decrecientes, pero no está restringido sólo a ellas. Existen gran cantidad de funciones que se emplean normalmente como funciones de activación, entre ellas están por ejemplo la función umbral, funciones lineales, o semi-lineales como una lineal con saturación, o funciones con variaciones más suaves como la función sigmoidea. A continuación se presentan la representaciones gráfica y expresiones matemáticas correspondiente a algunas de las funciones de activación más empleadas. Por ejemplo para la función de activación umbral la representación gráfica se presenta en la figura (2.5).

La expresión matemática para dicha función de activación umbral es la siguiente.

$$F(n) = \begin{cases} 1 & \text{si } n > 0 \\ 0 & \text{si } n \leq 0 \end{cases} \quad (2.5)$$

La representación gráfica para la función de activación lineal es la mostrada en la figura 2.6:

Y su expresión matemática es:

$$F(n) = n \quad (2.6)$$

Otra función de activación muy empleada también es la función de activación sigmoidea, como la mostrada en la figura 2.7:

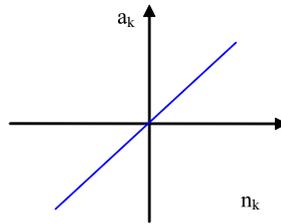


Figura 2.6: Función de activación lineal.

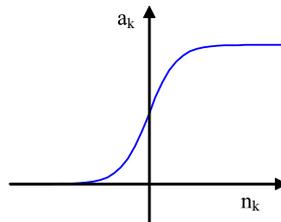


Figura 2.7: Función de activación sigmoidea.

Y su representación matemática:

$$F(n) = \frac{1}{1 + e^{-x}} \quad (2.7)$$

## 2.6. Tipos de neuronas

Existen tres tipos de unidades de procesamiento dependiendo de la posición en la que se encuentren:

### 2.6.1. Neuronas de entrada.

Las neuronas de entrada son aquellas que reciben los datos del exterior de la red neuronal. Las conexiones de estas neuronas son directamente entradas exteriores de la red.

### 2.6.2. Neuronas ocultas.

Las neuronas ocultas son aquellas cuyas entradas y salidas permanecen dentro de la red. No tienen ninguna conexión directa con el exterior de la red.

### 2.6.3. Neuronas de salida.

Las neuronas de salida son las que envían los resultados finales fuera de la red. Las salidas de dichas neuronas son directamente salidas de la red neuronal.

## 2.7. Arquitecturas de las Redes

El caso más simple de red neuronal sería aquel en que la red está formada por una sola neurona, como era el caso representado en la figura (2.1). En este caso la neurona es a la vez de entrada y de salida. La capacidad de almacenamiento de información que puede tener una red de este tipo es muy limitada.

### 2.7.1. Capa de neuronas

Las neuronas dentro de una red no se sitúan de forma aleatoria sino que se distribuyen de manera organizada. La forma más normal de distribuir las neuronas es formando agrupaciones llamadas capas. Las condiciones, con respecto a sus conexiones, que deben cumplir unas neuronas para formar una capa son las siguientes:

1. Dentro de una capa las neuronas no tienen conexiones entre sí.
2. Las conexiones de entrada a las neuronas irán conectadas únicamente a neuronas de la capa anterior. Si no existe una capa anterior serán directamente entradas de la red.
3. Las conexiones de salida de las neuronas irán conectadas únicamente a las conexiones de entrada de la capa siguiente. Si no existe una capa siguiente irán serán directamente salidas de la red.

Si una red tiene una única capa de neuronas, las entradas de éstas serán directamente entradas a la red y las salidas serán también directamente las salidas de la red neuronal. En la figura 2.2 puede verse un ejemplo de red formada por una sola capa de neuronas.

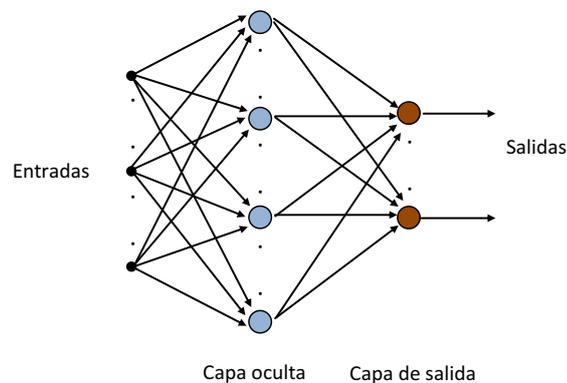


Figura 2.8: Red neuronal de dos capas.

Si una red tiene dos capas la primera irá directamente conectada a las entradas de la red y la segunda capa serán las salidas de la red. A la primera capa que toma directamente las entradas del exterior se denomina “capa oculta”, y a la última capa que forma las salidas de la red se la denomina “capa de salida”. En la figura 2.8 puede verse una red neuronal de dos capas.

Si una red tiene tres o más capas las capas intermedias que quedan tendrán sus conexiones de entrada conectadas a salidas de la capa anterior y sus conexiones de salida conectadas a entradas de la capa siguiente. A todas las capas exceptuando la capa de salida se las denomina capas ocultas. En la figura 2.3 puede verse una red de múltiples capas.

## 2.8. Entrenamiento de las redes neuronales

Una red neuronal tiene que estar configurada de tal forma que al aplicar un conjunto de entradas produzca el conjunto deseado de salidas. El objetivo del entrenamiento de las redes neuronales es ajustar los pesos y bias de todas las neuronas que forman la red con objeto de obtener la salida deseada ante una determinada entrada. Existen varios métodos para ajustar los valores de los pesos y bias para conseguir el citado objetivo que se pueden clasificar de forma general en dos grandes grupos: aprendizaje supervisado y aprendizaje no supervisado.

### 2.8.1. Aprendizaje Supervisado

El aprendizaje supervisado, también llamado asociativo, se basa en ajustar los pesos de forma explícita usando conocimiento a priori. En este método la red es entrenada a base a proporcionar a la misma pares de datos *entrada - salida deseada* que serán los patrones de aprendizaje. Y para ello se emplea alguna regla de aprendizaje que ajuste los pesos de la red de forma que sea capaz de reproducir de forma autónoma estas parejas de datos. Estos pares de datos *entrada-salida* generalmente serán suministrado externamente por el usuario. Pero existen casos en que esta información es suministrada mediante un sistema interno de la red como será el caso de las redes autosupervisadas.

### 2.8.2. Aprendizaje No Supervisado

El aprendizaje no supervisado, también llamado autoorganizado, es aquel en el cual las neuronas son entrenadas para responder a determinados conjuntos de la entrada, de forma que se tengan agrupaciones de patrones, también llamados clusters. Esta metodología trata de extraer, de una forma estadística, ciertas características del conjunto total de las entradas. A diferencia de la metodología de aprendizaje anterior, no existe un conjunto de categorías a priori en el que los patrones deban ser clasificados, si no que el propio sistema desarrolla la subdivisión en categorías.

### 2.8.3. Regla de aprendizaje básica

Tanto el aprendizaje supervisado como el autosupervisado producen un ajuste de los pesos de las conexiones entre neuronas de la red, de acuerdo a alguna regla de modificación. Casi todas las reglas de aprendizaje pueden considerarse como variantes de la *Regla de Hebb* [29].

La idea básica de la Regla de Hebb es que, si dos neuronas  $j$  y  $k$  están activas simultáneamente, su interconexión debe ser reforzada.

Si la neurona  $k$  recibe una entrada desde la neurona  $j$ , la versión más simple de la Regla de Hebb indica que el peso  $w_{jk}$  debe modificarse según la expresión:

$$\Delta w_{jk} = \gamma \cdot a_j \cdot a_k \quad (2.8)$$

donde:

$\Delta w_{jk}$ : incremento a añadir al peso de la conexión entre la neurona  $j$  y  $k$ .

$\gamma$ : constante de proporcionalidad positiva denominada “*factor de aprendizaje*”.

$a_j$ : salida de la neurona  $j$

$a_k$ : salida de la neurona  $k$

En este caso si las salidas de las dos neuronas están activas simultáneamente el valor en que se ha de incrementar el peso que las une es alto, con que una de ellas no está activa o tenga un valor de activación bajo el incremento en el peso será un valor bajo o incluso nulo.

Otra de las reglas de aprendizaje muy utilizada es la “*Regla Delta*” o la “*Regla de Widrow-Hoff*” [82]. En esta regla no se utiliza el valor de salida de la neurona  $k$  para ajustar los pesos, si no la diferencia entre la salida actual y la salida deseada:

$$\Delta w_{jk} = \gamma \cdot a_j \cdot (t_k - a_k) \quad (2.9)$$

Donde:

$\Delta w_{jk}$ : incremento a añadir al peso de la conexión entre la neurona  $j$  y  $k$ .

$\gamma$ : constante de proporcionalidad positiva denominada “*factor de aprendizaje*”.

$a_j$ : salida de la neurona  $j$

$a_k$ : salida de la neurona  $k$

$t_k$ : salida deseada para la entrada actual

Esta regla se suele denominar la Regla Delta porque a la diferencia  $t_k - a_k$  se le suele representar mediante la letra  $\delta$ .

A partir de estas dos reglas fundamentales han ido surgiendo diferentes métodos de aprendizaje.

## 2.9. Topologías de las redes

Las diferentes topologías de redes que se pueden obtener dependen de la forma de conexión entre neuronas que se realice. Así dependiendo de la forma que tengan estas conexiones, el flujo de datos tendrá una dirección u otra. Principalmente existen dos tipos de topologías claramente diferenciadas, unas son las redes llamadas “*feedforward*” y otras las redes llamadas “*recurrentes*”.

### 2.9.1. Redes feedforward

Las redes “*feedforward*” son redes formadas por una o más capas donde el flujo de datos va exclusivamente desde las entradas a las salidas, atravesando las capas de neuronas, pero no permitiendo en ningún caso que los datos vayan en sentido contrario. Las entradas de una determinada capa están únicamente conectadas a las salidas de la capa anterior, y sus salidas únicamente conectadas a las entradas de la capa siguiente. El procesamiento de los datos puede extenderse por múltiples neuronas y capas, pero no hay ni conexiones entre neuronas de la misma capa, ni conexiones de realimentación con capas anteriores. Es decir, ningún dato va de salidas de neuronas a entrada de neuronas de la misma capa o capas anteriores. La figura 2.8 muestra un ejemplo de este tipo de topología.

### 2.9.2. Redes recurrentes

En las redes recurrentes, el flujo de datos puede ir tanto de las entradas hacia las salidas como a la inversa, ya que en este tipo de topología las redes presentan conexiones de realimentación. Estas realimentaciones pueden ser del tipo de conectar una neurona oculta consigo misma mediante una conexión con un peso, o conectar las salidas de neuronas ocultas a las entradas de neuronas de entrada, o conectar las salidas de la red a las entradas o incluso conectar todas las neuronas con todas. Aunque la capacidad de aproximación de tales redes no se incrementa, sí que se puede obtener una disminución de la complejidad de la red y del tamaño de la red para resolver un problema comparándola por ejemplo con una red de tipo feedforward que también resuelva dicho problema.

Las redes recurrentes pueden emplearse con varios fines. Por ejemplo, gracias a sus realimentaciones estas redes pueden emplearse para generar y también para reconocer patrones temporales y espaciales, con lo que pueden representar propiedades dinámicas de los sistemas. Trabajando de esta forma se tiene una propagación continua de las señales a través de la red durante todo el tiempo de funcionamiento. Este tipo de redes tienen como principal diferencia con las feedforward el que las características dinámicas de la red, y el orden de entrada de los datos es fundamental para el aprendizaje de la red. Como ya se ha comentado, el comportamiento dinámico constituye la salida de la red, es decir, corresponde con las variaciones que se producen en los valores de activación de las salidas. Por este motivo una de sus fundamentales aplicaciones es el reconocimiento o aprendizaje de patrones temporales.

Otro tipo de aplicación de las redes recurrentes es para el almacenamiento de patrones estables. En este caso se presenta a la red un conjunto de entradas en un momento determinado y se la deja evolucionar hasta que su salida se estabiliza a un determinado valor. Este tipo de funcionamiento se denomina “*basado en un atrayente*”. En este caso los valores de activación de las neuronas experimentan un proceso de relajación tal que la red evolucionará a un estado estable en el cual las salidas no volverán a cambiar.

En la figura 2.9 se representa un caso de red neuronal recurrente donde pueden observarse conexiones de realimentación entre las neuronas de la capa de salida y las entradas a la red.

## 2.10. Tipos de redes estándar

En este apartado se van a ver los principales tipos de redes que clásicamente se han ido utilizando a lo largo de la historia de las redes neuronales. Se irá evolucionando en complejidad de las redes empezando por las más simples de una capa, y aumentando posteriormente su número de capas. Se comenzará por las redes de tipo feedforward, y después se estudiarán ejemplos de redes recurrentes. En cada caso se irá analizando la capacidad de representación que presenta cada red y los algoritmos de aprendizaje empleados.

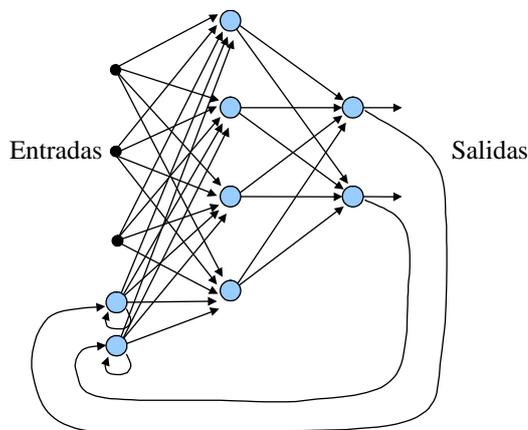


Figura 2.9: Red neuronal recurrente

### 2.10.1. Perceptron

El modelo más clásico de red neuronal es el Perceptron. Este tipo de red fue propuesta por Rosenblatt [67]. El Perceptron pertenece al grupo de las redes feedforward, y su metodología de entrenamiento está basada en la Regla de Hebb. Sus neuronas son binarias, es decir, utiliza la función umbral como función de activación de las neuronas (ver figura 2.5 y expresión 2.5), con lo cual su salida sólo puede tomar dos posibles valores. En la figura 2.10 puede verse la versión más simple de esta red que está formada por una sola capa consistente en una o más neuronas de salida  $j$ , cada una de las cuales está conectada mediante un factor de ponderación o peso  $w_{ij}$  a todas las entradas  $p_i$ .

La aplicación principal del Perceptron es aprender clasificaciones binarias, es decir, aprender transformaciones de la forma indicada en (2.10) usando muestras de aprendizaje dadas por un vector  $p$  que contiene las entradas y un vector  $t(p)$  que contiene las correspondientes salidas deseadas.

$$\mathfrak{R}^N \rightarrow -1, 1^M \quad (2.10)$$

La estructura seleccionada para el Perceptron básico de clasificación está formada por una única capa de neuronas, que tendrá  $m$  neuronas para diferen-

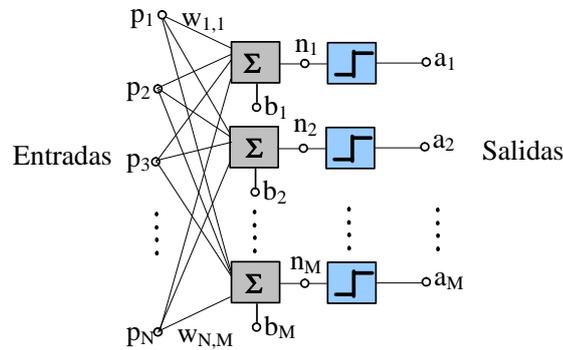


Figura 2.10: Representación de un Perceptrón

ciar  $2m$  clases, vista cada clase como una combinación binaria de las salidas. De forma que se activará en cada caso las salidas correspondientes a la clase que corresponda para el conjunto de entradas. Este tipo de redes presenta varias limitaciones que pueden impedir su correcto funcionamiento, siendo la más importante el que sólo permite clasificar conjuntos de vectores linealmente separables.

**Regla de aprendizaje del Perceptron** Una vez seleccionado un problema que tenga solución mediante un perceptron de una capa el siguiente paso es definir el modo en que se ajustarán los pesos y el bias para que la red neuronal responda de la forma deseada. Esto es lo que se va a denominar aprendizaje o entrenamiento de la red. Por medio de un proceso iterativo se irán modificando los valores de los pesos y bias hasta que la respuesta sea la deseada. Para ello se necesitan dos conjuntos de datos que serán por un lado los valores de las entradas y por otro las salidas deseadas para esas entradas. Es decir, el aprendizaje se basa en históricos de datos de correcto funcionamiento del sistema, en pares de datos de entrada-salida deseada. En cada iteración  $k$  del proceso de aprendizaje se mostrará a la red un par de datos entradas-salidas deseadas y se calculará el valor en que se han de modificar cada uno de los pesos  $\Delta w_i$  y bias  $\Delta b$  para que la red responda correctamente a dicha entrada.

$$w_i(k+1) = w_i(k) + \Delta w_i(k) \quad (2.11)$$

$$b(k+1) = b(k) + \Delta(k) \quad (2.12)$$

En el caso de emplear perceptrones cuya función de activación sea la indicada en (2.13) .

$$F(n) = \begin{cases} 1 & \text{si } s > 0 \\ -1 & \text{si } s \leq 0 \end{cases} \quad (2.13)$$

se puede emplear para el aprendizaje una regla muy simple basada en la regla de Hebb, en la que en cada iteración se le presenta un patrón de entradas-salidas deseada y calcula las modificaciones en los pesos  $\Delta w_i$  y en los bias  $\Delta b$  para que se cumpla dicha relación. El proceso de aprendizaje se realiza para cada una de las neuronas que forman la red, considerando para cada una su salida correspondiente. Para comenzar el proceso de aprendizaje se inicializan los valores de los pesos y de los bias con valores aleatorios y se organiza cada combinación de datos patrón de aprendizaje en un vector de entradas  $p$  y un vector de salidas deseadas  $t$ . Se coge el primer par de vectores de entradas y salidas deseadas y se le presenta el vector de entradas a la red, con lo que se obtendrá un vector de salida. Ahora se compara la salida que ha dado la red con el vector de salidas deseadas. Como se están empleado funciones de activación umbral todas las salidas serán -1 a 1. Si la salida obtenida es correcta no se modifican los pesos y bias, pero si la salida obtenida no coincide con la deseada se modifican los valores de los pesos según la expresión (2.14).

$$\Delta w_i = t(p) \cdot p_i \quad (2.14)$$

Para actualizar los bias, se emplea la misma expresión que para los pesos con la diferencia de que el bias no tiene entrada externa, con lo que se considera fija al valor 1, según se muestra en (2.15).

$$\Delta b = t(p) \quad (2.15)$$

En el caso en que se emplee para la función de activación la expresión (2.5) donde la salida puede ser 0 o 1, el aprendizaje de los perceptrones puede

realizarse mediante una variante más simple de la Regla Delta indicada en la expresión (2.9):

$$\Delta w_{jk} = (t(p) - a(p)) \cdot p_j \quad (2.16)$$

$$\Delta b_k = t(p) - a(p) \quad (2.17)$$

Donde:

$\Delta w_{jk}$ : incremento a añadir al peso de la conexión entre la neurona j y k.

$p_j$ : entrada j a la neurona

$a(p)$ : salida de la neurona para la entrada actual

$t(p)$ : salida deseada para la entrada actual

### 2.10.2. Redes Lineales

Estas redes fueron definidas por Widrow and Hoff que además también plantearon la regla de entrenamiento. Este tipo de redes también pertenecen al grupo de las redes tipo feedforward. Las neuronas de tipo lineal presentan una función de activación de tipo lineal, tal como la que se muestra en la figura (2.6) y expresión (2.6). Esto hace que su comportamiento sea muy diferente a las neuronas de tipo Perceptron. En primer lugar, las salidas pueden tomar cualquier valor desde  $-\infty$  a  $+\infty$  y, otro lado, el hecho que esta función sea de tipo lineal hace que el valor de salida de la neurona sea una combinación lineal del conjunto de entradas a la neurona según puede verse en la expresión (2.18).

$$a = F \left( \sum_j w_j p_j + b \right) = \sum_j w_j p_j + b \quad (2.18)$$

De esta forma, es posible aplicar la regla de aprendizaje denominada como “regla Delta”, de “Regla de Widrow\_Hoff” o “Regla de los mínimos cuadrados”. Las redes de este tipo están formadas por una única capa de neuronas tal como se muestra en la figura (2.11) y se emplean normalmente para tareas de aproximación de funciones. El caso más simple y que puede verse gráficamente sería una red formada por una única neurona con dos entradas. En este caso la

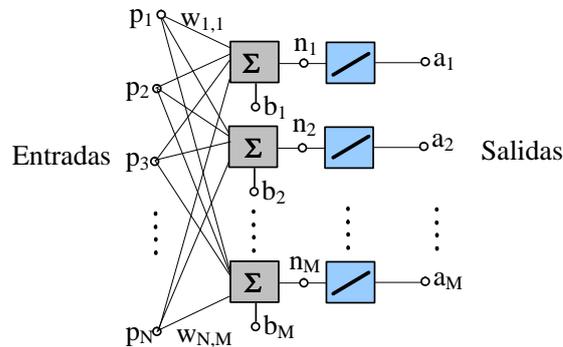


Figura 2.11: Representación de una red lineal.

representación de la función podría verse en un espacio tridimensional en el que la red, por medio de una regla de aprendizaje, ajustará un plano al conjunto de muestras de entrenamiento formado por los pares “valores de entrada”-“salida deseada” que pase por los puntos. En caso de tener mayor número de entradas y salidas la representación gráfica del problema en tres dimensiones ya no sería posible y la red por medio del entrenamiento lo que ajustará será los datos de entrenamiento a un hiperplano.

Este tipo de red a veces se denomina como ADALINE, que viene de neuronas lineales adaptativas. Se denominan adaptativas debido al hecho de que es una red lineal que utiliza una regla de aprendizaje que ajusta automáticamente el ritmo de variación de los pesos. El origen de la regla de los mínimos cuadrados parte de la comparación entre el vector de salida proporcionado por la red y la salida deseada por el usuario para esta entrada. A esta diferencia se la denomina error de la red. El propósito del aprendizaje es llegar a un error cero para todas las entradas, pero cuando no se puede alcanzar ese valor una forma muy usual de trabajar es tratar de minimizar el error cuadrático medio según la expresión (2.19).

$$E_{cm} = \sum_P E^P = \frac{1}{2} \sum_P (t^P - a^P)^2 \quad (2.19)$$

Donde:

$E_{cm}$  : Error cuadrático medio de la salida de la red.

$E^P$  : Error cuadrático para el patrón p.

$t^P$  : Valor de salida deseado para el patrón p.

$a^P$  : Valor real de la salida para el patrón p.

Mediante la aplicación del método del descenso del gradiente, se procede a cambiar los pesos de tal forma que se minimice la función de error definida. La forma de modificar los pesos debe ser tal que se produzca una variación negativa del error. Es decir, para cada patrón  $p$  presentado a la red se procede a cambiar cada uno de los pesos de forma proporcional negativa a la derivada del error respecto a dichos pesos según la expresión (2.20).

$$\Delta_P w_j = -\gamma \cdot \frac{\partial E^P}{\partial w_j} \quad (2.20)$$

Donde:

$\gamma$ : constante de proporcionalidad llamada “learning rate” o “tasa de aprendizaje”.

Calculando la derivada del error como:

$$\frac{\partial E^P}{\partial w_j} = \frac{\partial E^P}{\partial a^P} \cdot \frac{\partial a^P}{\partial w_j} \quad (2.21)$$

Por un lado según se ha definido la función de error se tiene que:

$$\frac{\partial E^P}{\partial a^P} = \frac{\partial}{\partial a^P} \left( \frac{1}{2} \sum_P (t^P - a^P)^2 \right) = -(t^P - a^P) = -\delta^P \quad (2.22)$$

donde:

$\delta^P$ : diferencia entre la salida deseada y la salida actual para el patrón de entrada “p”, es decir, el error que presenta la red para el patrón “p”.

Y por otro lado al ser la función de activación lineal se tiene:

$$\frac{\partial a^P}{\partial w_j} = \frac{\partial}{\partial w_j} (w_j p_j + b) = p_j \quad (2.23)$$

Luego, la regla de aprendizaje queda:

$$\Delta_P w_j = -\gamma \cdot (t^P - a^P) \cdot p_j = -\gamma \cdot \delta^P \cdot p_j \quad (2.24)$$

Queda entonces claro que el paso de modificación de los pesos es variable y

se adapta al error  $\delta$  que presente la red, de aquí su nombre de Regla Delta. La limitación fundamental de este tipo de redes es el limitado poder de representación ya que sólo se pueden representar relaciones lineales entre las variables de entrada. Pero esto tiene la ventaja de que a causa de la linealidad del sistema, el algoritmo de entrenamiento converge siempre a la solución óptima, es decir, existe un único mínimo en la función de error (función que presenta el valor del error frente a variaciones de los pesos).

### 2.10.3. Redes de Backpropagation

Las redes vistas hasta ahora tienen grandes limitaciones en los tipos de problemas que pueden resolver. Las posibles modificaciones que se pueden hacer a una red feedforward para aumentar su capacidad son aumentar el número de capas de neuronas y emplear otras funciones de activación tales como las funciones de activación no lineales. El hacer estos cambios en la arquitectura de la red lleva a que las reglas de entrenamiento empleadas hasta ahora ya no sean válidas. Será necesario hacer una nueva generalización de la regla delta empleada hasta ahora para que sea aplicable a redes con función de activación diferentes de la lineal y que permita también el entrenamiento de los pesos de varias capas. Por tanto el nuevo tipo de redes que se van a estudiar son también del tipo feedforward, es decir, la información siempre fluye desde las entradas de la red hacia las salidas, pero el número de capas podrá ser modificable así como el tipo de funciones de activación, con la única limitación de que dichas funciones han de ser derivables. Más adelante cuando se analice el proceso de aprendizaje se justificará esta limitación. En la figura 2.3 se representa la arquitectura genérica de este tipo de redes neuronales.

La idea central para encontrar la solución está en que los errores para las neuronas ocultas serán determinados por medio de la realimentación (backpropagation) de los errores producidos en las neuronas de la capa de salida. Por esta razón a este método se le denomina muchas veces regla de aprendizaje de Backpropagation. El método de aprendizaje será una generalización de la aplicación de la regla de mínimos cuadrados vista para redes de una capa aplicado a redes multicapa con neuronas derivables. En este método se cal-

culan las variaciones en los pesos de las capas ocultas a partir del error para las capas ocultas, obtenido mediante la propagación hacia atrás de los errores desde la capa de salida. Cuando se presenta un patrón de aprendizaje a la red, los valores de activación de las diferentes neuronas son propagados hacia las neuronas de salida. Los valores obtenidos a la salida de la red se comparan con los valores de salida deseados para ese patrón. Normalmente estos dos valores no van a coincidir, con lo que existirá un error en cada una de las salida. Lo que se desea es llegar al error nulo y la forma de hacerlo es tratar de modificar los pesos mediante un proceso iterativo de tal forma que en la siguiente iteración el error sea cero para este patrón. De la expresión de la Regla Delta se sabe que para reducir el error se han de modificar los pesos de acuerdo con la expresión (2.24). Este proceso no es suficiente ya que si aplicamos esta regla, sólo se modifican los pesos de la última capa con lo que los pesos de las neuronas ocultas nunca se modifican. Para modificar estos pesos habría que aplicar de nuevo la regla delta, pero no se tienen los valores de  $\delta$  para las neuronas ocultas. Esto se resolverá transmitiendo los errores de las neuronas de salida a todas las neuronas ocultas a las que está conectada ponderada por sus pesos y teniendo en cuenta la función de activación de las neuronas.

Para ello partiendo de la expresión (2.20) vista para la modificación de los pesos de una red de una capa, se plantea ahora la misma expresión pero aplicable a cualquier número de capas (para ello se amplían los subíndices de tal forma que  $w_{j,k}$  es el peso entre la salida  $j$  de la capa anterior y la neurona  $k$  de la capa actual).

$$\Delta_P w_{jk} = -\gamma \frac{\partial E^P}{\partial w_{jk}} \quad (2.25)$$

Si se modifican los pesos de acuerdo con la expresión (2.25) se producirá un descenso del gradiente sobre la superficie del error. El término  $\gamma$  corresponde con el coeficiente de aprendizaje (learning rate) que ajusta en qué proporción se aplica la modificación calculada por la regla de aprendizaje. Según puede verse en la expresión (2.25) este procedimiento de aprendizaje requiere que los cambios en los pesos sean proporcionales al gradiente del error. La constante de proporcionalidad es el learning rate  $\gamma$ . El valor de este coeficiente afecta a

la velocidad de aprendizaje, es decir, si el learning rate es grande esto hace que las variaciones en los pesos sean también grandes con lo que de una iteración a la siguiente variarán mucho los valores de los pesos. Y si es pequeño de una iteración a la siguiente habrá muy poca variación. Es interesante utilizar algoritmos que modifiquen este valor de tal forma que cuando se está lejos de la solución buscada este valor sea grande para que se acerque rápidamente hacia la solución, pero cuando ya está cerca de ella es mejor que tenga un valor bajo para poder afinar lo más posible a la hora de encontrar el mínimo del error.

## **2.11. Propuestas y resultados en el reconocimiento de formas y orientación de piezas.**

Se incluyen a continuación diferentes propuestas de arquitecturas emisor-receptor y posiciones relativas entre objeto y sensor para el reconocimiento de formas y orientación de objetos mediante ultrasonidos. Para estas arquitecturas se han propuesto una serie de casos de reconocimiento de formas y posiciones de objetos empleando las redes neuronales como clasificadores de patrones.

Se han ordenado dichos experimentos según la configuración de la estructura sensorica empleada, empezando por las configuraciones más sencillas y terminando con las más complejas.

### **2.11.1. Reconocimiento de formas y orientación de piezas empleando una configuración sensor-emisor.**

Se ha propuesto un método de reconocimiento de formas y orientación de piezas aplicable a entornos de producción industrial [73]. En este caso se utiliza una configuración sensorica sencilla estando formado el sistema por una pareja de sensores ultrasónicos (emisor y receptor) Murata 40B8 R/S tal como se muestra en las figuras 2.12 y 2.13. Esta configuración se emplea para distinguir, dentro de un conjunto de objetos limitado, el tipo de objeto y su orientación.

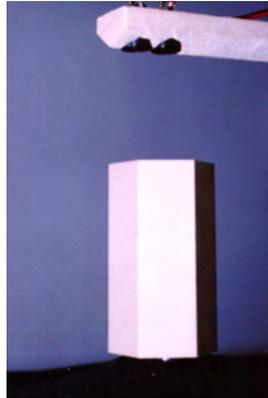


Figura 2.12: Sistema sensórico.

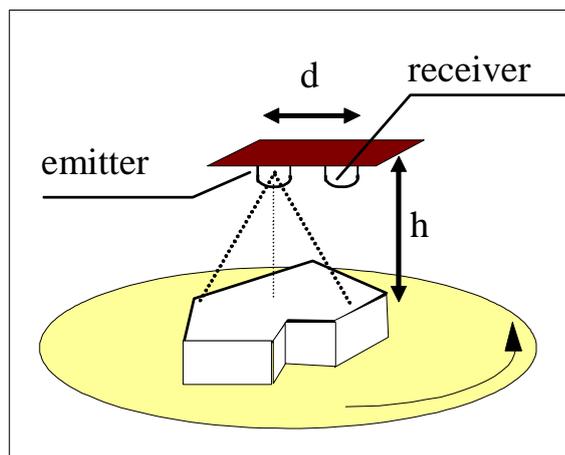


Figura 2.13: Esquema de la configuración del sistema sensórico.

Las piezas se sitúan debajo de la cabeza sensora y se realiza una rotación de  $0^{\circ}$  a  $360^{\circ}$  tomando datos cada  $3.6^{\circ}$ , es decir, tomando 100 datos de los ecos recibidos en una vuelta completa.

Para este ensayo la generación de los pulsos de señal a 40 KHz para la excitación del sensor emisor se ha realizado mediante el generador de funciones HP 33120A que se muestra en la figura 2.14 y se han diseñado dos etapas amplificadoras mediante amplificadores operacionales LF353 de alto slew rate ( $16V/\mu s$ ), una para la señal de emisión, necesaria para llegar a los niveles de tensión a los que trabaja dicho sensor (max 20Vpp), y otra en la recepción,

## 2. Reconocimiento de patrones mediante redes neuronales.

---

para la amplificación de la, débil en muchos casos, señal obtenida. Para la toma de datos se ha empleado un osciloscopio digital HP 54615B mostrado en la figura 2.15.

El control, tanto del generador de señal como del osciloscopio digital, se ha realizado a través de un bus HP-IB. Para ello se han programado en C las funciones dll, que llamadas desde Matlab, permiten el manejo y control tanto del osciloscopio como del generador desde el entorno Matlab para poder integrarlo en el resto de la programación.

Para el movimiento rotatorio de la pieza se ha empleado un motor paso a paso de cuatro hilos con 3.6 grados de resolución trabajando a a 12V. Para el control de su movimiento se ha empleado el puerto paralelo de un PC. Para ello se ha diseñado la etapa hardware de interface mediante un driver darlington ULN2003 que permite convertir los niveles TTL del puerto paralelo en señales de 12 V y 500mA suficientes para alimentar al motor y poder gobernarlo.



Figura 2.14: Generador de funciones HP 33120A



Figura 2.15: Osciloscopio digital HP 54615B

Se ha programado también mediante una función dll en C el interface con la secuencia del control para generar el movimiento en dicho motor y poder integrar su manejo en el programa general en Matlab. Mediante una nueva función de Matlab se han sincronizado los movimientos del motor con la generación y captura del eco ultrasónico.

Una vez realizada la toma de datos para cada posición se analiza el eco recibido. Para ello de cada eco se calcula su envolvente y la derivada de la envolvente según se muestra en la figura 2.16 y de éstas se extraen un total de veinte características según indica E. Caicedo en [19] las cuales corresponden a las veinte primeras características listadas en la tabla 1.3. Si se representa gráficamente la información correspondiente a la posición angular frente a los valores de cada parámetro analizado puede verse que dichas curvas presentan una variación sin discontinuidades. Es decir, pequeñas variaciones en la posición angular llevan a pequeñas variaciones del parámetro analizado. La figura 2.17 muestra cómo varía a) la amplitud máxima del eco, b) el área de la envolvente y c) el área de la derivada de la envolvente, cuando una de las piezas va girando desde  $0^{\circ}$  grados a  $360^{\circ}$  (100 posiciones). Así se obtendrán las curvas de variación para cada uno de los parámetros indicados de forma que se tenga una completa caracterización del objeto respecto a su posición angular. La figura 2.18 muestra el mismo estudio para una pieza que presenta dos ejes de simetría en la cara visualizada y la figura 2.19 para una pieza con tres ejes de simetría.

Para implementar este método es necesario almacenar la información obtenida de los parámetros para cada pieza y para cada una de las posibles orientaciones. Para, posteriormente, comparando los valores obtenidos de un caso concreto con esta información, se pueda conocer el tipo de objeto y la posición angular que presenta. Debido a que la información obtenida a través de los sensores de ultrasonidos no es determinista se debe implementar un sistema que sea capaz de manejar cierto nivel de incertidumbre en los datos. Para resolver estos posibles problemas se ha empleado como herramienta matemática para su implementación las redes neuronales [44, 49].

La modelización a través de redes neuronales aporta capacidad de generalización, es decir, son capaces de responder ante datos de entrada que difieren, por la existencia de ruido, de los reales e incluso ante valores de entrada cuya

respuesta no se encuentra entre los casos de aprendizaje. Otra ventaja de las redes neuronales en esta aplicación frente a un modelado matemático de las curvas de características es la capacidad de autoaprendizaje que presentan, aprendiendo nuevos patrones con sólo presentar a la red un número suficiente de casos para su entrenamiento.

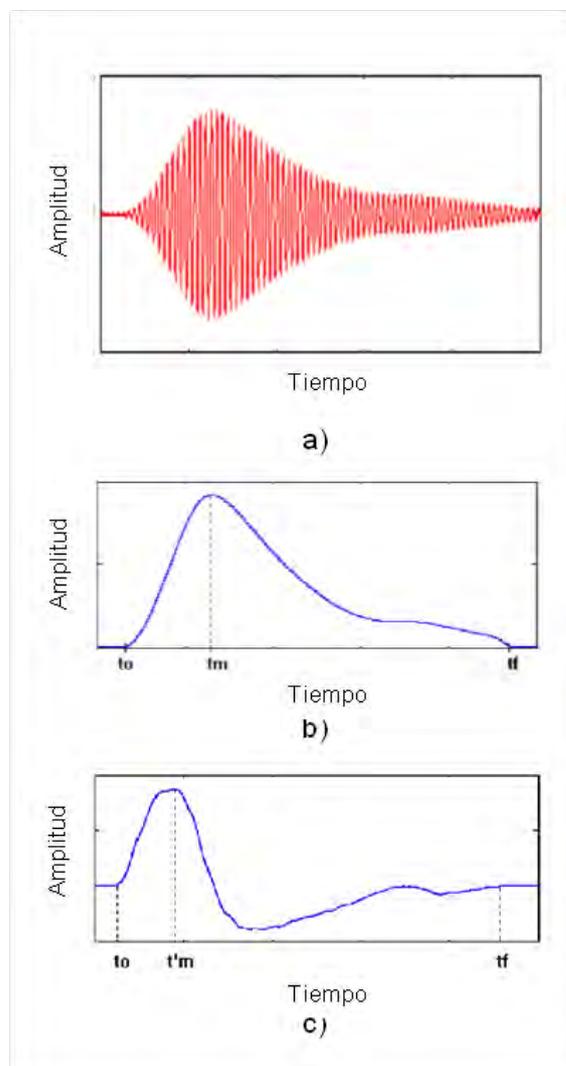
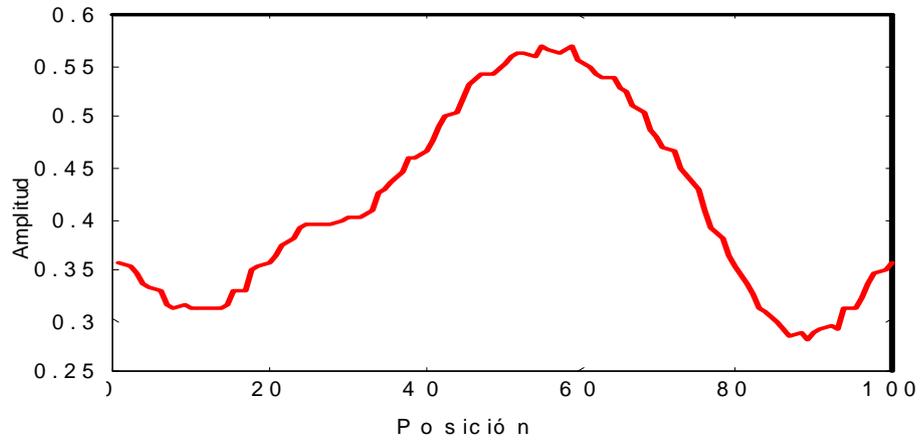
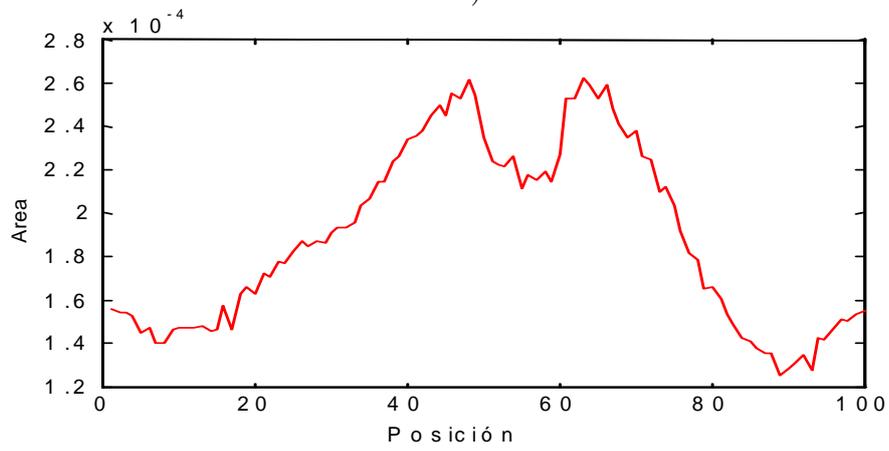


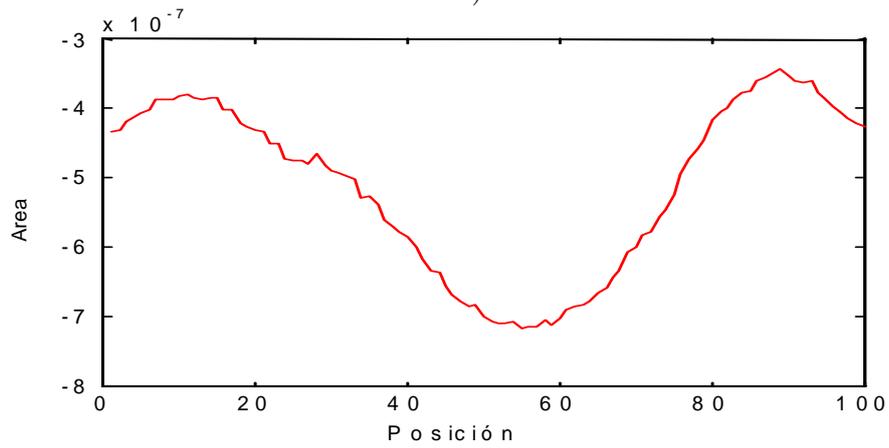
Figura 2.16: a) Eco recibido, b) envolvente del eco y c) derivada de la envolvente.



a)



b)

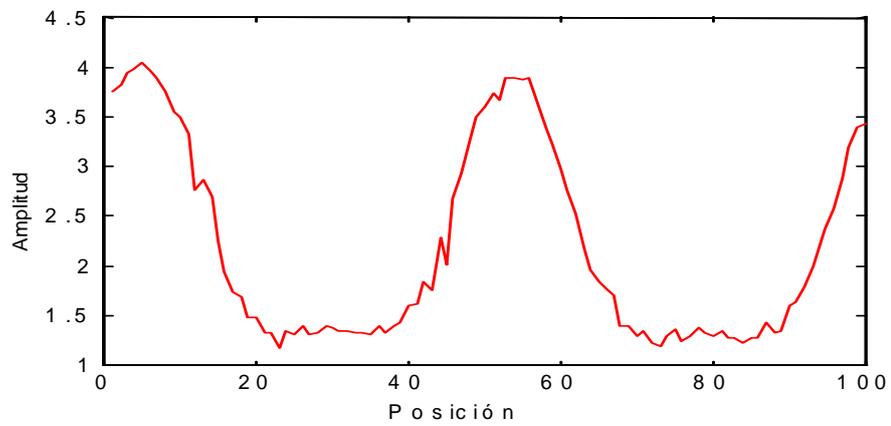


c)

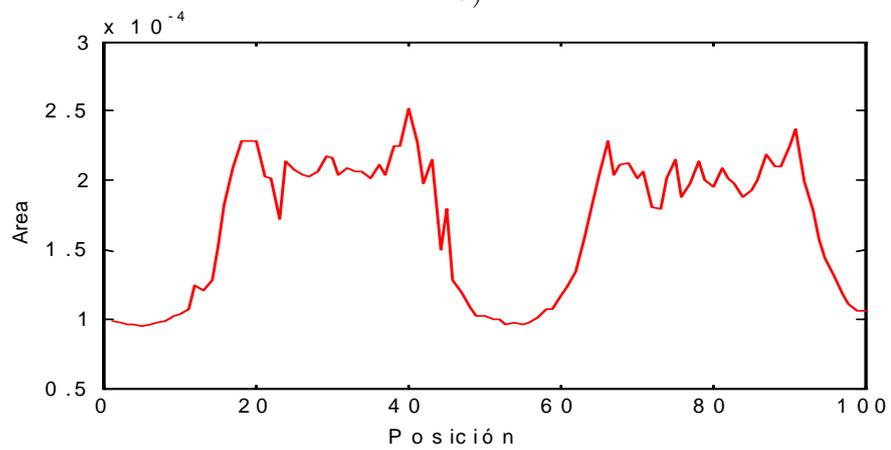
Figura 2.17: Gráficos de los parámetros a) amplitud, b) área de la envolvente y c) área de la derivada de la envolvente.

2. Reconocimiento de patrones mediante redes neuronales.

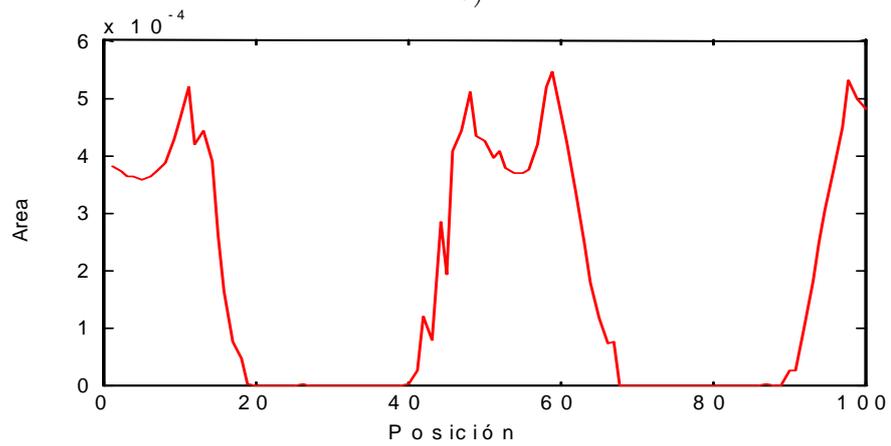
---



a)

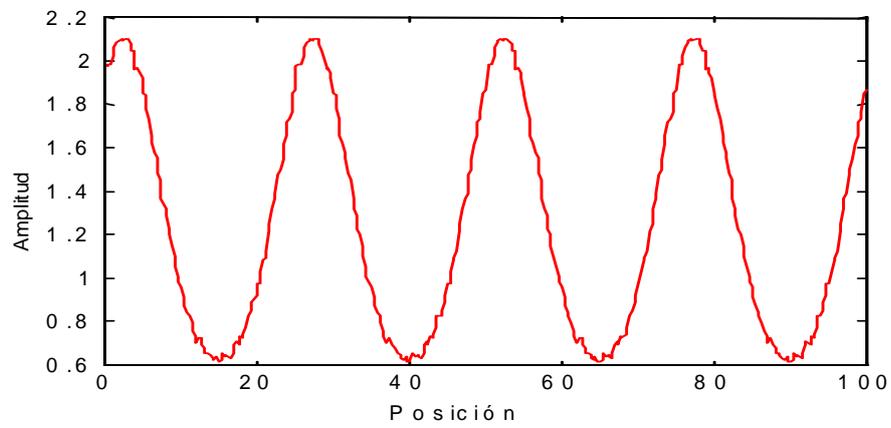


b)

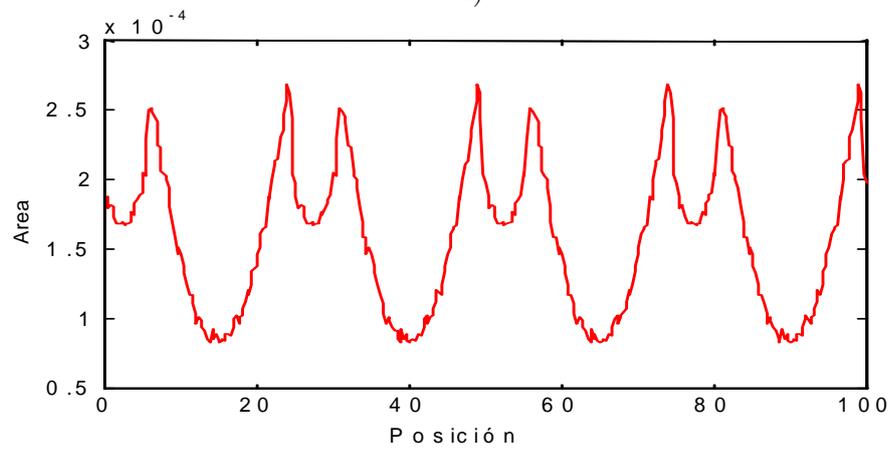


c)

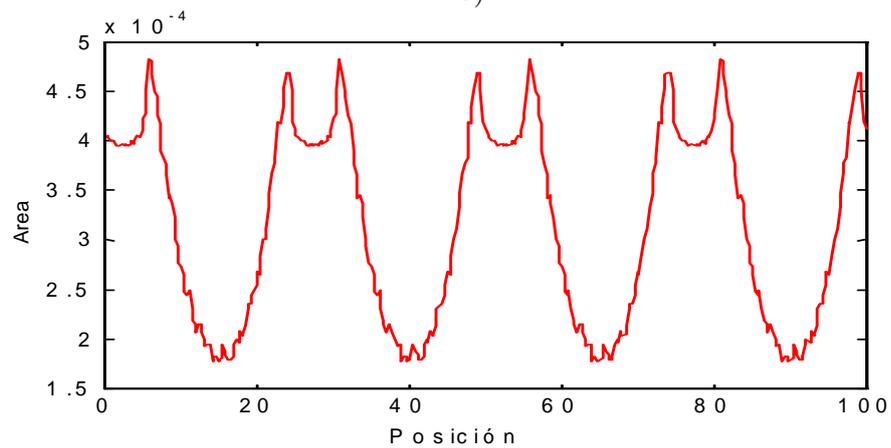
Figura 2.18: Gráficos de los parámetros a) amplitud, b) área de la envolvente y c) área de la derivada de la envolvente para una pieza con dos simetrías.



a)



b)



c)

Figura 2.19: Gráficos de los parámetros a) amplitud, b) área de la envolvente y c) área de la derivada de la envolvente para una pieza con cuatro simetrías.

Se ha utilizado en primer lugar una arquitectura de red de tipo backpropagation para el reconocimiento de la clase de objeto.

Y en segundo lugar, una vez definido el objeto, se ha empleado una nueva red para conocer su orientación. Para la selección de esta segunda red se han analizado diferentes tipos como son las redes de backpropagation, redes de tipo radial basis y redes formadas por memorias asociativas de tipo instar. Para aproximar dichas funciones se han empleado arquitecturas de dos y tres capas con funciones de activación lineales, sigmoideas y radial basis. En particular las funciones sigmoideas aportan grandes beneficios a la hora de manejar señales con ruido. Para el entrenamiento de dichas redes se ha empleado un amplio número de casos para poder ofrecer capacidad de generalización ante la presencia de señales con ruido.

El entrenamiento de las redes se ha realizado empleando el algoritmo de optimización de Levenberg-Marquardt [39, 53] que permite incrementar la velocidad de convergencia en el aprendizaje de la red.

También se ha fijado como parámetro del entrenamiento el valor mínimo de la suma de los cuadrados del error, *sse* (*sum squared error*), buscando un equilibrio entre la capacidad de generalización y memorización de la red:

$$sse = \sum_{n=1}^t e(n)^2 = \sum_{n=1}^t (t(n) - a(n))^2 \quad (2.26)$$

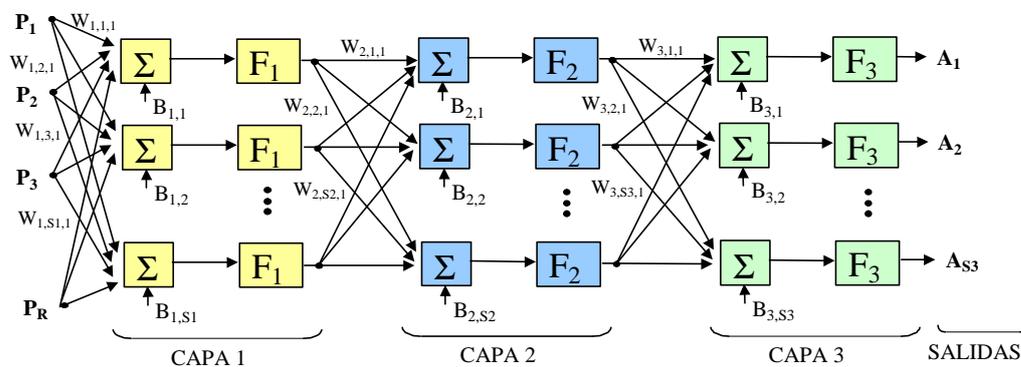


Figura 2.20: Red para aprendizaje de clases binarias

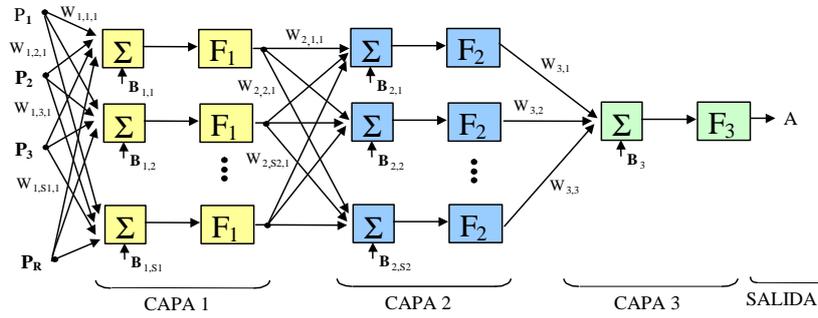


Figura 2.21: Red neuronal para clasificación

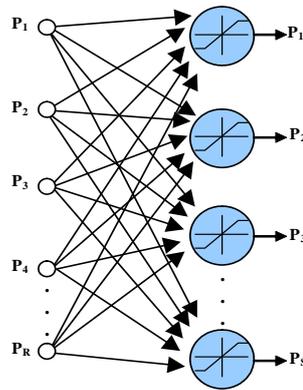


Figura 2.22: Red neuronal asociativa instar

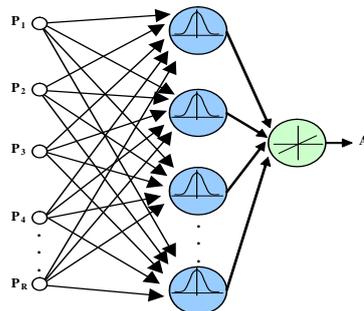


Figura 2.23: Red radial basis

Como conclusiones puede verse que el tipo de red que presenta mejores

resultados varía en función del número de clases de objetos a identificar. Para el entrenamiento se analizaron piezas con diferentes grados de simetrías empleando un total de 10000 ecos (5000 para entrenamiento y 5000 para test) llegándose a la conclusión de que si el número de clases es muy elevado, porque la pieza presenta pocas o ninguna simetría, las redes de tipo backpropagation presentan los mejores resultados. Sin embargo, si el número de simetrías es más elevado (se ha comprobado con piezas de hasta seis simetrías), las redes de tipo memoria asociativa o radial basis pueden producir mejores resultados. También se trató de reducir el número de características empleadas a las más significativas, puesto que algunas presentaban información redundante y se analizó el tipo de funciones de activación y número de neuronas [46].

Para el aprendizaje de la clase de objeto se emplearon redes de tipo backpropagation multicapa capaces de realizar el mapeado no lineal entre el espacio  $c$ -dimensional de los vectores de entrada (donde  $c$  es el número de características de la envolvente empleadas) y el espacio unidimensional de los vectores de salida, siendo la salida la orientación de la pieza.

Dado el gran volumen de datos que se manejan es muy importante reducir el número de parámetros de entrada a las redes. No todos los parámetros son necesarios puesto que muchos de ellos están relacionados entre sí y por tanto contienen la misma información o muy similar observándose curvas de variación prácticamente iguales que no aportan mayor conocimiento al sistema.

Otro aspecto que ayudó a mejorar el entrenamiento y funcionamiento de estas redes fue separar la información en clases en vez de abordar el problema en conjunto. Ha dado mejor resultado emplear redes diferentes para el aprendizaje de cada clase de objeto y para el aprendizaje de la orientación dentro de cada clase que intentar abordar el problema completo con una sola red.

Para el caso de la discriminación entre clases de objetos, debido a la gran cantidad de datos que deben manejar, las redes de backpropagation mostraron mejores resultados. Se llegó a un buen equilibrio entre complejidad de la red, capacidad de generalización y valor de error de entrenamiento empleando redes de tres capas con diez neuronas en sus capas ocultas. Puede verse en la tabla 2.1 las redes denominadas Backpr 1.1 y Backpr 1.2 donde se presentan los mejores resultados obtenidos. En esta tabla se muestra el número de capas de

la red, el número de neuronas de cada capa, el número de entradas a la red, la funciones de activación, el número de epochs, el *sse* y la tasa de reconocimiento obtenida sobre el conjunto de test.

Para la red Backprop 1.1 se utilizó una única salida lineal que variaba dentro del rango de clases existentes. En cambio en la red Backprop 1.2 se empleó cuatro salidas binarias para obtener la clase correspondiente. Puede verse por el número de epochs necesarios para el aprendizaje que romper la continuidad de los datos en categorías binarias hace más difícil el entrenamiento. Estas redes se han empleado para clasificar cuatro objetos distintos con tres, cuatro, cinco y seis simetrías respectivamente. Para comprobar su funcionamiento se han presentado a la red mil muestras diferentes obteniéndose un 99.89% y un 99.79% de resultados correctamente clasificados según se muestra en la tabla 2.1.

Para la discriminación entre posiciones angulares, se analizó el funcionamiento tanto de redes de backpropagation como redes de tipo asociativo, y radial basis. Puede verse los resultados obtenidos en la tabla 2.1 en los tipos de redes denominados respectivamente Backprop 2.x, Asociativa y Radial Basis. Para reducir la complejidad se empleó una red diferente para cada objeto. Se incluye en la última columna las tasas de reconocimiento para un rango de diez orientaciones consecutivas del objeto. En primer lugar se emplearon redes de backpropagation con dos capas y diez neuronas ocultas, tipo Backprop 2.x, con las que pudo resolverse el problema de clasificación cumpliendo los mismos parámetros de generalización y error de entrenamiento que para la clasificación por objetos inicial. La tabla 2.2 muestra un ejemplo de clasificación para la red que presenta los mejores resultados, Backprop 2.1, comparando los valores reales y los obtenidos por la red para diez posiciones angulares consecutivas del objeto. Esta tabla muestra el detalle de la tasa de reconocimiento para un subconjunto de trescientos casos de test correspondientes a diez posiciones consecutivas. La utilización de neuronas lineales en la capa de salida permite incrementar la capacidad de generalización de las redes pudiendo estimar posiciones intermedias entre las entrenadas. Otra posible forma de resolver el problema de clasificación fue mediante la utilización de redes asociativas. La tabla 2.1 muestra también, en el tipo de red Asociativa, los resultados obtenidos

## 2. Reconocimiento de patrones mediante redes neuronales.

con una red de tipo asociativo de una sola capa empleando para el aprendizaje la regla Instar. En este caso al mostrar un nuevo patrón de entrada a la red ésta nos indicará la pertenencia o no a cada una de las clases fijadas, en este caso orientaciones, de forma independiente. Este resultado vendrá dado por un valor de similitud con respecto a los patrones entrenados. La clase ganadora será aquella que presente un valor de similitud mayor. Si el número de simetrías se incrementa, el número de clases disminuirá inversamente, disminuyendo por tanto la complejidad de la red.

Tipo de red	Nº de capas	Nº de neuronas	Nº de entradas	Función de activación	Epochs	sse	% Recon
Backpr 1.1	3	10+10+1	3	sigmoide / lineal	95	0.1	99.89
Backpr 1.2	3	10+10+4	3	sigmoide / sigmoide	137	0.1	99.79
Backpr 2.0	2	10+1	4	sigmoide / sigmoide	480	0.1	81.5
Backpr 2.1	2	10+1	5	sigmoide / lineal	570	0.1	83.3
Backpr 2.2	2	10+1	6	sigmoide / lineal	750	0.1	78.3
Backpr 2.3	2	10+1	8	sigmoide / lineal	450	0.1	71.3
Backpr 2.4	3	10+10+1	4	sigmoide / lineal	380	0.1	70.7
Asociativa	1	10	5	lineal saturada	3	-	75.3
Radial Basis	1	84.	5	radial basis	84	0.1	87.3

Tabla 2.1: Tipos de redes y parámetros

		Clasificación por la red										% Reconocido
		1	2	3	4	5	6	7	8	9	10	
Clasificación Real	1	26	4	0	0	0	0	0	0	0	0	86.7
	2	0	28	2	0	0	0	0	0	0	0	93.3
	3	0	2	27	1	0	0	0	0	0	0	90.0
	4	0	0	1	29	0	0	0	0	0	0	96.7
	5	0	0	0	1	29	0	0	0	0	0	96.7
	6	0	0	0	0	1	28	1	0	0	0	93.3
	7	0	0	0	1	0	3	24	2	0	0	80.0
	8	0	0	0	0	0	0	2	22	5	1	73.3
	9	0	0	0	0	0	0	1	8	19	2	63.3
	10	0	0	0	0	0	0	1	5	6	18	60.0
<b>Total</b>												<b>83.3</b>

Tabla 2.2: Reconocimiento para 10 clases con red de backpropagation

		Clasificación por la red										% Reconocido
		1	2	3	4	5	6	7	8	9	10	
Clasificación Real	1	23	7	0	0	0	0	0	0	0	0	76.7
	2	0	26	4	0	0	0	0	0	0	0	86.7
	3	0	0	16	14	0	0	0	0	0	0	53.3
	4	0	0	0	12	18	0	0	0	0	0	60.0
	5	0	0	0	0	25	5	0	0	0	0	83.3
	6	0	0	0	0	0	28	2	0	0	0	93.3
	7	0	0	0	0	0	0	23	6	1	0	76.7
	8	0	0	0	0	0	0	0	19	5	6	63.3
	9	0	0	0	0	0	0	0	0	24	6	80.0
	10	0	0	0	0	0	0	0	0	6	24	80.0
<b>Total</b>											<b>75.3</b>	

Tabla 2.3: Reconocimiento para 10 clases con red asociativa

La tabla 2.3 muestra los resultados de clasificación obtenidos para el mismo subconjunto de datos de test correspondientes a diez clases consecutivas. Puede verse que presenta más errores entre clases adyacentes que el mismo problema mostrado en la tabla 2.2 y resuelto mediante redes de backpropation.

El tercer tipo de redes empleadas fueron las redes Radial Basis donde el número de neuronas depende directamente del número de casos de entrenamiento y del error deseado. Así se irán añadiendo neuronas a la estructura hasta que el valor del error *sse* sea el deseado. La tabla 2.4 contempla como comparativa el mismo caso resuelto mediante backpropagation y redes asociativas.

Como conclusión final puede decirse que las redes de backpropagation superan en prestaciones a las asociativas y radial basis cuando el objeto no presenta ningún tipo de simetrías dando lugar a una gran cantidad de clases diferentes y a redes muy complejas. En cambio cuando las piezas presentan simetrías y el número de clases se reduce considerablemente las redes asociativas y radial basis resultantes son más simples y el aprendizaje de patrones más rápido que las de backpropagation.

		Clasificación por la red										% Reconocido
		1	2	3	4	5	6	7	8	9	10	
Clasificación Real	1	30	0	0	0	0	0	0	0	0	0	100
	2	1	29	0	0	0	0	0	0	0	0	96.7
	3	0	1	29	0	0	0	0	0	0	0	96.7
	4	0	0	3	27	0	0	0	0	0	0	90.0
	5	0	0	0	0	26	4	0	0	0	0	86.7
	6	0	0	0	1	3	25	1	0	0	0	83.3
	7	0	0	0	0	2	2	25	1	0	0	83.3
	8	0	0	0	0	0	0	0	24	5	1	80.0
	9	0	0	0	0	0	0	3	2	25	0	83.3
	10	0	0	0	0	0	0	1	4	3	22	73.3
<b>Total</b>											<b>87.3</b>	

Tabla 2.4: Reconocimiento para 10 clases con red radial basis

### 2.11.2. Reconocimiento de formas y orientación de piezas empleando una configuración de array circular.

Otro estudio realizado ha sido el reconocimiento de objetos empleando un array circular de sensores ultrasónicos modelo Murata 40B8 R/S y redes neuronales [46]. Las figuras 2.24 y 2.25 muestran el array ultrasónico empleado formado veinticinco sensores colocados en un array circular. En esta aplicación se ha utilizado un sensor emisor central rodeado de tres aros concéntricos de sensores receptores a diferentes distancias del sensor central lo que permite realizar diversas configuraciones en función de las dimensiones del objeto a identificar. Esta configuración, la cual se muestra en la figura 2.26, unida a la utilización de redes neuronales permite una identificación de piezas rápida con un hardware sencillo y de bajo coste. En esta figura se indican también los límites en las dimensiones de los objetos para la configuración mostrada. La distancia entre el array de sensores y el objeto a identificar debe ser correctamente ajustada para obtener la mejor definición posible del objeto bajo estudio. Para el caso analizado se puede ver que la superficie que cubre el array sobre el espacio de trabajo, con atenuación de la presión inferior a 6dB, corresponde a un círculo de radio máximo dado por:



Figura 2.24: Array circular

$$b = r \cdot \tan\left(\frac{\gamma - 6dB}{2}\right) = 400 \cdot \tan\left(\frac{50^\circ}{2}\right) = 186,5mm \quad (2.27)$$

donde:

r: distancia del array a la superficie de trabajo

$\gamma$ : ángulo del lóbulo principal (-6dB).

Añadido a las etapas hardware diseñadas para el ensayo anterior, ha sido necesario diseñar una nueva etapa de multiplexado de señales que permita la toma de datos, mediante el osciloscopio digital, de forma secuencial de los veinticinco receptores de que consta el array. Para ello se ha diseñado una etapa multiplexora mediante multiplexores analógicos HEF4051B la cual es controlada nuevamente desde el puerto paralelo del PC, mediante una etapa de drivers SN54LS07 para evitar sobrecargar de intensidad al puerto. Igualmente se ha programado en C una función dll que permita su manejo desde Matlab para poder sincronizar la selección de sensores con la adquisición de datos.

Como el fin de reducir al mínimo la carga computacional de esta aplicación se ha empleado únicamente la información de la presión de la señal ultrasónica. Según los trabajos previos [43] el empleo de esta única característica permite discriminar entre el conjunto de objetos seleccionados para el estudio.

La modificación de la forma del eco y por tanto la amplitud recibida de los veinticuatro sensores que forman el array aportan suficiente información para distinguir entre el conjunto de clases de objetos utilizadas.

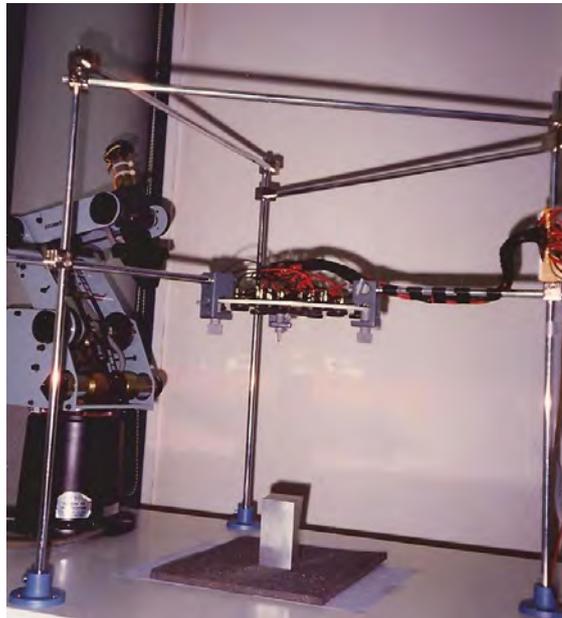


Figura 2.25: Array circular

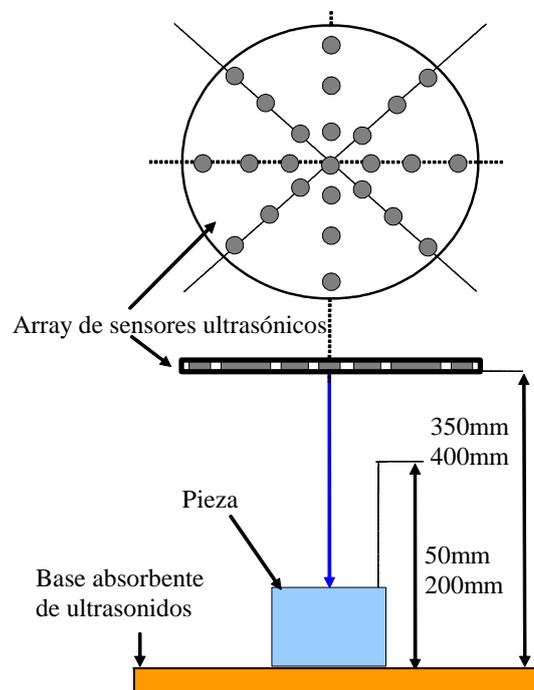


Figura 2.26: Esquema array circular

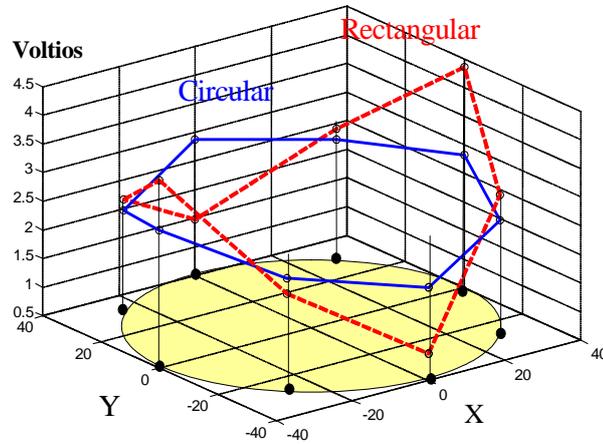


Figura 2.27: Presiones para objetos rectangulares y circulares

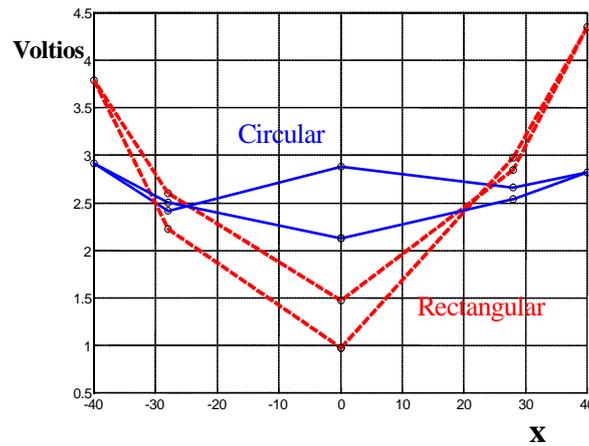


Figura 2.28: Vista lateral presiones para objetos rectangulares y circulares

Las figuras 2.27 y 2.28 muestran las presiones recibidas en el anillo de los ocho sensores centrales del array para un objeto rectangular y circular respectivamente.

En este caso para la clasificación del objeto se han entrenado un conjunto de redes neuronales de dos capas de tipo backpropagation empleando funciones de activación de tipo lineal y sigmoidea. La figura 2.29 representa el número de neuronas frente al número de epochs requeridos para alcanzar una determinada

tasa de error (*sse* de 0.01) en el entrenamiento con diferentes combinaciones de funciones de activación. Puede observarse que las mejores configuraciones corresponden a aquellas que emplean funciones de activación lineales en la capa de salida. Además puede verse también que incrementar el número de neuronas en la capa oculta no produce una mejora en la convergencia de la red visto desde el punto de vista del número de epochs necesarios para alcanzar el error fijado. Pero en cambio el incrementar el número de neuronas si que produce un gran incremento de la carga computacional y del tiempo de aprendizaje. Por tanto se selecciona como mejor opción aquella que cumpla las especificaciones de error con el menor número de neuronas.

Se han analizado también diferentes configuraciones de redes formadas por dos capas ocultas y una capa de salida combinado diferentes números de neuronas en cada capa oculta. La figura 2.30 muestra el resultado de dicho análisis donde pueden verse el número de epochs de entrenamiento de las redes frente al número de neuronas de cada capa. Puede observarse que con un número que oscila entre quince y veinticinco neuronas en la primera capa oculta y entre diez y veinte neuronas en la segunda capa oculta se alcanza el error deseado en un número reducido de epochs.

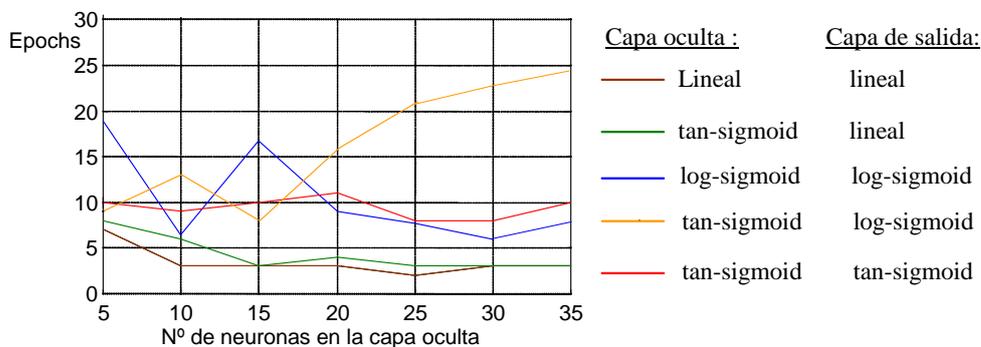


Figura 2.29: Comparativa n<sup>o</sup> de neuronas frente a epochs

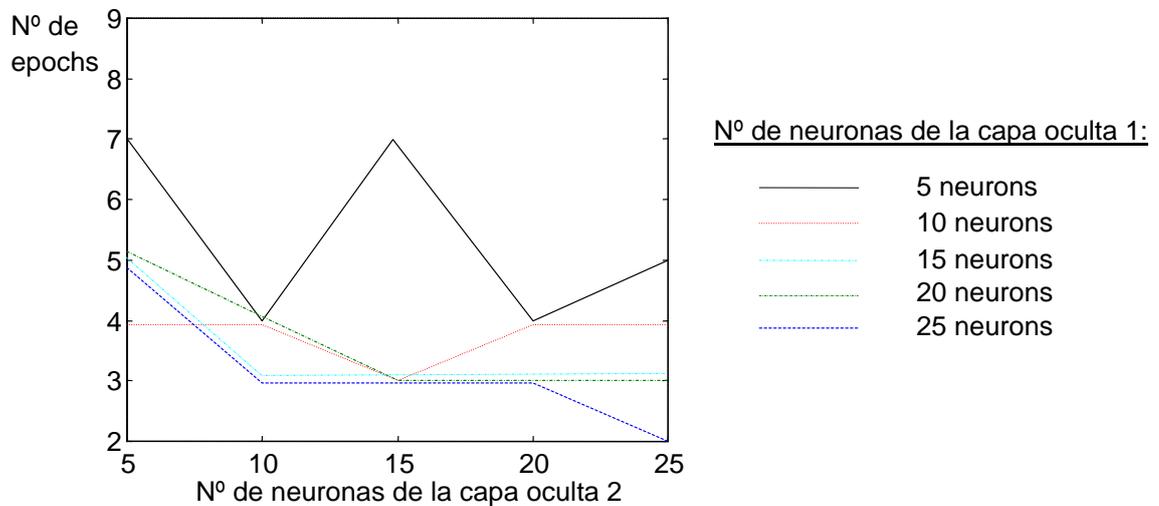


Figura 2.30: Diferentes combinaciones para redes de dos capas

### 2.11.3. Reconocimiento de formas y orientación de piezas empleando una configuración de array lineal.

Otro ensayo realizado ha sido el reconocimiento y clasificación de piezas de fundición en un proceso de fabricación utilizando un array lineal de sensores de ultrasonidos y redes neuronales [71, 72] . Las piezas a identificar pueden verse en la figura 2.38. La identificación se realiza durante el transporte de la pieza sobre una cinta transportadora. Esta solución es útil para aplicaciones donde no es recomendable el uso de cámaras de visión artificial ya sea por las condiciones ambientales, por ejemplo la presencia de humos más o menos opacos, falta de iluminación o porque la aplicación requerida no justifique el coste más elevado del equipo.

En esta aplicación se ha empleado un array lineal estático. Puede verse en las figuras 2.32 y 2.33 la estructura del array al paso de una pieza de fundición. El sistema desarrollado está formado por una estructura de array lineal con ocho pares de sensores emisor-receptor modelo Murata 40B8 R/S . Este array se sitúa en la dirección normal a la dirección de movimiento del array. La estructura de este array ha sido diseñada en forma de cuña para eliminar los sucesivos rebotes entre el objeto y el array. La distancia  $h$  entre

## 2. Reconocimiento de patrones mediante redes neuronales.

---

el array y los objetos debe ser ajustada en función de las dimensiones de los objetos a identificar, la frecuencia de trabajo de los sensores y el ángulo total del lóbulo principal. En este caso se ha situado a 70 mm por encima de la pieza más alta, de 15 cm de altura. Esto significa que la zona insonificada por cada emisor, suponiendo una superficie plana, será aproximadamente, en la superficie superior de la pieza más alta un círculo de 3cm de radio y en la zona del suelo un círculo de unos 10 cm de radio.



Figura 2.31: Piezas de fundición

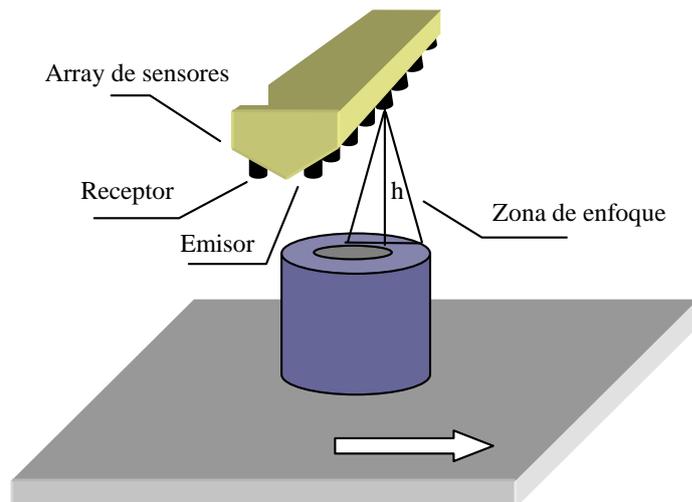


Figura 2.32: Esquema del sistema

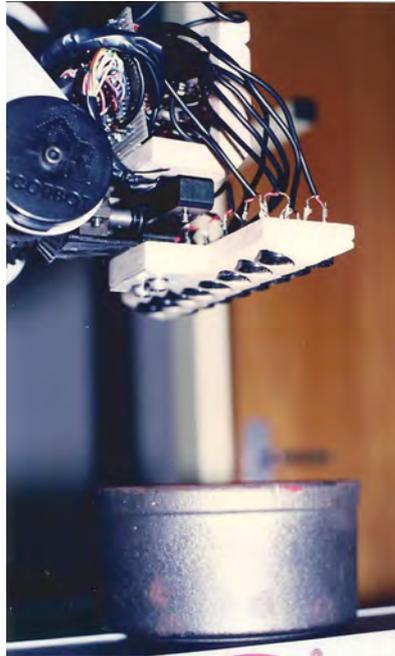


Figura 2.33: Array lineal

En este caso se han diseñado las etapas amplificadora para ir situadas junto al array de sensores, y una por sensor, como puede verse en la figura 2.33. Se ha realizado este cambio debido a que el funcionamiento del motor eléctrico que desplaza la cinta transportadora causaba perturbaciones en las señales al pasar el cableado próximo al motor. Se optó por amplificar nada más es capturado el eco por el sensor receptor, ya que así permite que la señal tenga más ganancia y le afecten en menor medida las perturbaciones.

También ha sido necesario añadir una nueva etapa de multiplexado mediante multiplexores analógicos HEF4051B la cual es controlada nuevamente desde el puerto paralelo del PC, mediante una etapa de drivers SN54LS07. Igualmente se ha programado en C una función dll que permita su manejo desde Matlab para poder sincronizar la selección de sensores con la adquisición de datos.

La captura de datos se realiza de forma secuencial para cada par sensor-emisor para evitar interferencias de las señales reflejadas por otros pares de sensores. De las señales recibidas se calcula su envolvente eliminando la señal

portadora de 40KHz mediante el filtrado del eco con el filtro Butterworth mostrado en 1.15.

De la amplia variedad de parámetros característicos que se pueden extraer de dicha envolvente (ver tabla 1.3) se han seleccionado inicialmente el tiempo de vuelo, tiempo de amplitud máxima y máxima amplitud. En esta aplicación debido a la existencia de múltiples rebotes se ha visto que el tiempo de vuelo presentaba múltiples problemas, siendo más robusta la medida del tiempo de amplitud máxima como parámetro para la toma de decisiones. Éste parámetro permite seleccionar automáticamente el eco más importante de la respuesta y obtener una estimación de la distancia a la que se produce, evitando seleccionar siempre el que aparece en primer lugar como sería en el caso de emplear el tiempo de vuelo. La información del tiempo de amplitud máxima puede traducirse a distancia relativa entre el array y el objeto. Esto permite hacer una estimación de las dimensiones 3D de la pieza insonificada. Puede verse en las figuras 2.34 y 2.35 la representación espacial de dicho tiempo traducida a distancia.

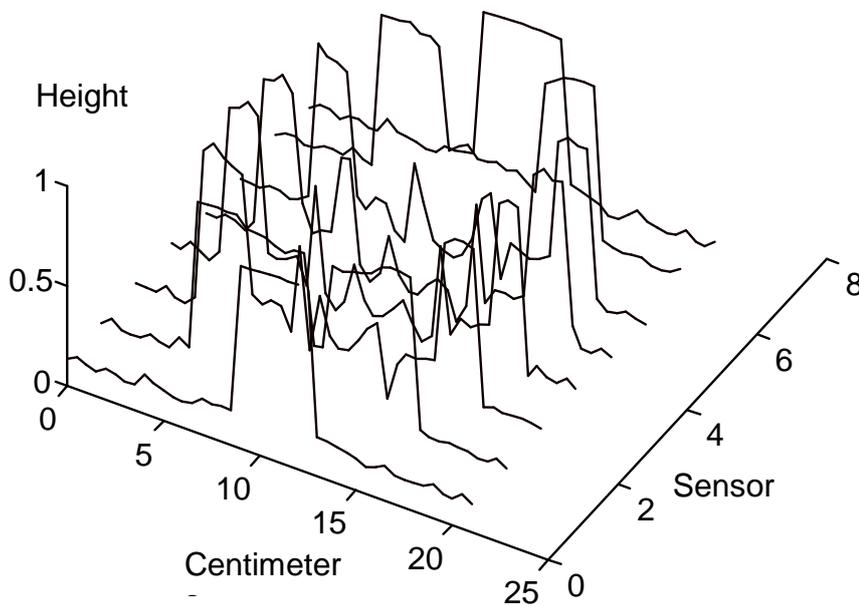


Figura 2.34: Representación 3D del parámetro tiempo de amplitud máxima traducido a distancia

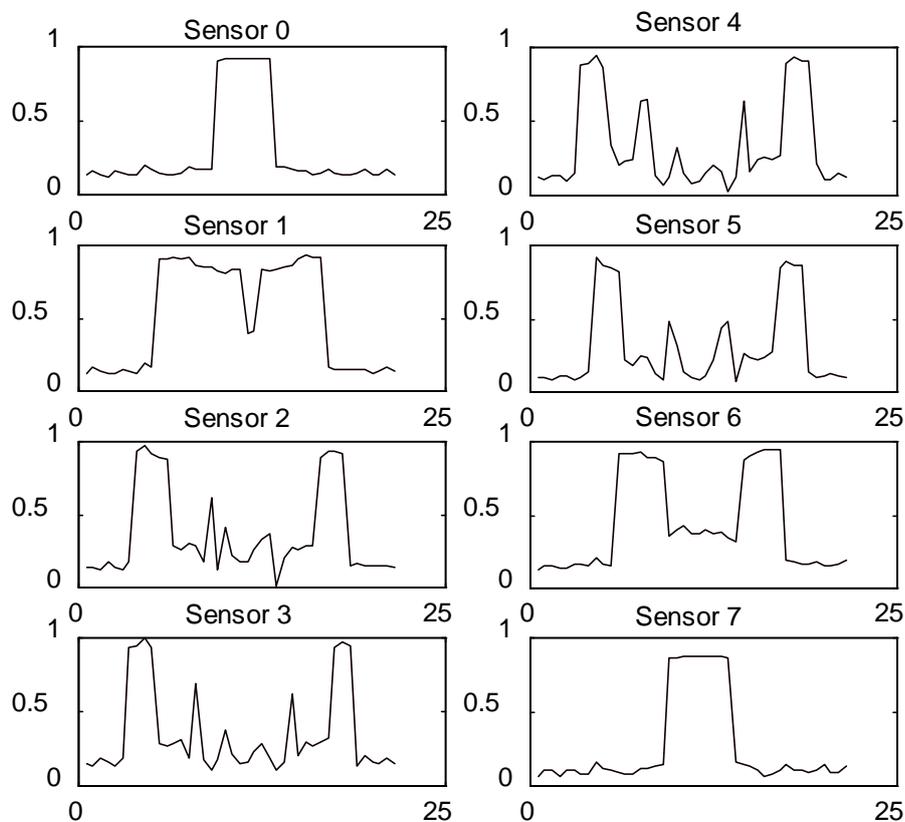


Figura 2.35: Representación 2D del parámetro tiempo de amplitud máxima

La información recibida de los sensores, una vez tratada, es utilizada para entrenar un sistema de redes neuronales para realizar la clasificación entre los diferentes objetos que puedan presentarse. Se plantea un sistema de redes simples donde la información de cada par emisor-receptor se utiliza para entrenar una red independiente.

La primera estructura de redes planteada se entrena para reconocer el tipo de pieza dentro de un grupo conocido de ellas. En este caso la red ha de aprender toda la información recibida por el par de sensores correspondiente al camino recorrido por el sensor. Con este esquema se necesita una red diferente para cada pieza a reconocer. La configuración utilizada se muestra en la figura 2.36. En el caso de emplear redes de tipo asociativo el sistema es capaz de reconocer la pieza fácilmente empleando un número reducido de neuronas ya que sólo necesita una neurona asociativa para aprender una secuencia completa de

datos. Sin embargo para obtener los mismos resultados si se emplean redes de tipo backpropagation es necesario una estructura de dos capas con un mínimo de veinte neuronas o una estructura de tres capas con cinco neuronas por capa. Las redes de tipo Radial Basis fueron desechadas debido a que para un entrenamiento adecuado el número de datos es elevado y por tanto el número de neuronas prohibitivamente alto.

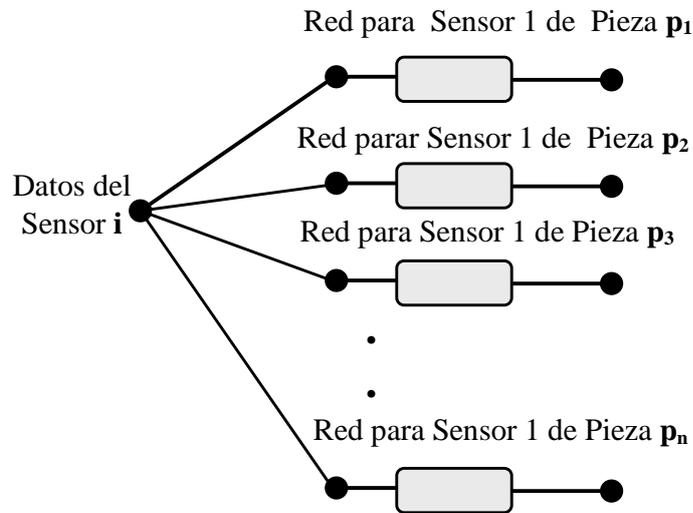


Figura 2.36: Red neuronal esquema 1

En el segundo caso el sistema se ocupa de reconocer la posición relativa de la pieza respecto a su posición base. En este caso la información proveniente de todos los sensores es utilizada simultáneamente por todas las redes como puede verse en la figura 2.37. En estas figuras, por simplificar el esquema, se muestran sólo las conexiones para una sola pieza, pero todos los datos correspondientes a las diferentes piezas entrenadas deben conectarse a todas las redes. En este caso el sistema necesita una alta interconexión entre las diferentes redes entrenadas ya que los datos provenientes de cada sensor van conectados a todas las redes. Así, cada red responde con la posición del sensor de entrenamiento que es más similar al dato presentado. Como las piezas empleadas en esta aplicación son cuerpos de revolución que siempre presentan simetría respecto al eje central, las redes pueden activar más de una salida con la misma probabilidad.

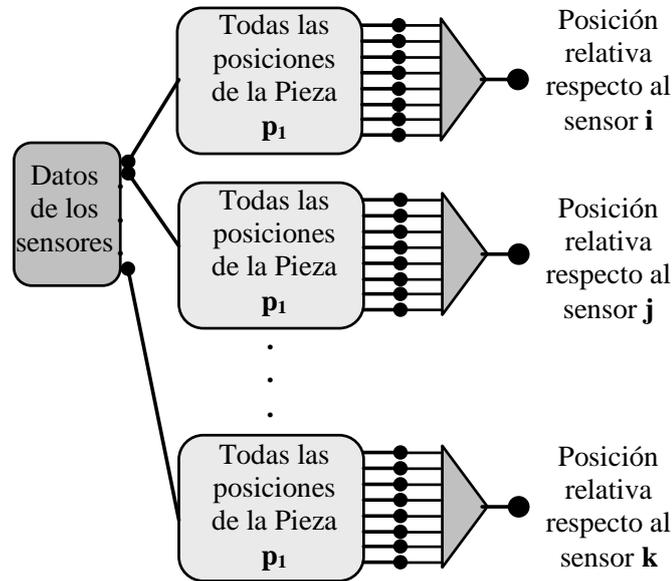


Figura 2.37: Red neuronal esquema 2

Se han usado redes de backpropagation y redes asociativas para realizar los aprendizajes. La tabla 2.5 muestra una comparación de los resultados obtenidos. El entrenamiento se ha llevado a cabo de tal forma que la red responda con un 1 cuando el resultado es cierto y con un 0 cuando el resultado es falso. Como las funciones de activación de las neuronas no son de salida binaria se pueden obtener valores intermedios entre 0 y 1. Esto dará una medida de la incertidumbre en la respuesta. Cuanto más próximo esté la salida a 0 o 1 equivaldrá a que la red está más segura de su respuesta, mientras que valores intermedios dirán que la incertidumbre en la respuesta de la red es mayor.

Los resultados mostrados en la tabla corresponden a los valores medios obtenidos a partir de los datos todas las redes independientes entrenadas. Estos resultados se han obtenido entrenando cuatro piezas diferentes tomando datos de cincuenta posiciones consecutivas a lo largo del desplazamiento de la pieza y repitiendo dicho experimento ciento sesenta veces para tener en cuenta variaciones por ruido.

	BACKPROP. 1 CAPA	BACPROP. 2 CAPAS	BACKPROP. 3 CAPAS	ASOCIATIVA INSTAR	RADIAL BASIS
Nº. NEURONAS	1	20	5 por capa	1	infinito
Nº. EPOCHS	8	8	10	2	-
RESULTADOSS	5%	95%	95%	98%	-
Nº PESOS	50	1020	280	50	-

Tabla 2.5: Resultados entrenamiento de las redes

#### 2.11.4. Reconocimiento de formas y orientación de piezas empleando una configuración de array 3x3.

En esta aplicación el objetivo consiste en identificar la postura de una pieza, cuando ésta reposa sobre la superficie de trabajo, para poder ser más fácilmente capturada por la pinza de un robot (ver [76, 75]). Los objetos empleados como muestra en esta aplicación son piezas de fundición, todas de la misma forma y tamaño, tal como se muestran en la figura 2.38. En esta aplicación la pieza es única pero puede presentar cualquier disposición sobre la superficie de trabajo. Es decir, puede estar en cualquiera de las cuatro posiciones estables y puede estar rotada en cualquier posición angular. El detector de posición debe devolver información sobre estas dos condiciones: cara estable sobre la que está apoyada la pieza y ángulo rotado de la pieza respecto a una posición base. Esta información permitirá calcular la trayectoria de desplazamiento y la posición de la pinza del brazo robotizado que debe coger la pieza.



Figura 2.38: Pieza de fundición

El sistema propuesto emplea para la toma de información sobre el objeto

un array de sensores de ultrasonidos Murata 40B8 R/S, que podrá ir montado sobre el mismo brazo robotizado o en otra estructura anexa. Dicho array está formado por nueve sensores dispuestos en una configuración cuadrada 3x3. En la figura 2.39 puede verse una vista frontal del mismo donde se observa la disposición de los sensores, y en la figura 2.40 puede verse una vista lateral donde se aprecia también la electrónica de control que se ha desarrollado para las etapas de excitación de los sensores emisores y la etapa de adecuación de la señal capturada por el sensor receptor.

Nuevamente se han diseñado las etapas amplificadora situadas junto al array de sensores y una por sensor, como puede verse en la figura 2.40. Se ha vuelto a utilizar esta alternativa porque la puesta en movimiento del robot también causa perturbaciones en las señales.

La toma de datos se realiza de forma secuencial por lo que también ha sido necesario añadir una nueva etapa de multiplexado mediante multiplexores analógicos HEF4051B la cual es controlada también desde el puerto paralelo del PC, mediante una etapa de drivers SN54LS07. Igualmente se ha programado en C una función dll que permita la integración de su control en Matlab.

Para realizar la rotación de la pieza se ha empleado un motor paso a paso de 200 pasos lo que permite una resolución de 1.8 grados por paso.

El tamaño del array debe ser dimensionado de acuerdo al tamaño y características de los sensores empleados y al tamaño de los objetos a identificar (ver [42, 47]) También puede observarse en las figuras 2.39 y 2.41 que la superficie del array no es plana sino que está diseñada para evitar los sucesivos rebotes no deseables de los ecos ultrasónicos sobre su superficie.

Se emplea un pulso de diez ciclos para generar la señal de excitación en el sensor central que funciona como emisor. El eco recibido es capturado por los ocho sensores que le rodean. Posteriormente se analiza la información de dichos ecos para extraer una serie de parámetros que caractericen al eco. En este caso los parámetros utilizados han sido: el tiempo de vuelo del eco desde su emisión hasta su recepción, el tiempo transcurrido desde la emisión hasta el máximo del eco recibido y la máxima amplitud del eco recibido.



Figura 2.39: Array 3x3

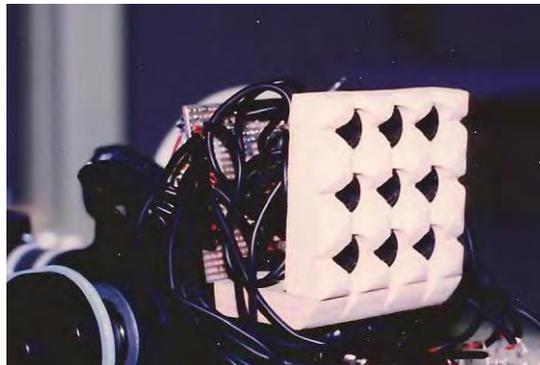


Figura 2.40: Array 3x3 con electrónica de control

Puede verse en la figura 2.41 una muestra de los ecos recibidos por los ocho sensores para un caso particular de posición de la pieza.

Para obtener la información necesaria con que realizar el aprendizaje de las redes, se ha rotado la pieza con incrementos de 1.8 grados hasta completar una vuelta completa de la pieza. Esto da lugar a un registro de doscientas posiciones angulares en una vuelta completa.

Las figuras 2.42, 2.43 y 2.44 presentan una muestra del conjunto de curvas obtenidas para los ocho sensores receptores simultáneamente, particularizadas para una de las caras estables. El eje de abscisas indica las doscientas posiciones angulares y el de ordenadas el valor de la característica seleccionada escaladas todas ellas en el mismo rango de valores. Además se ha repetido la toma de datos diez veces para contemplar también la dispersión de las medidas, realizando la toma de datos bajo diferentes situaciones de perturbaciones.

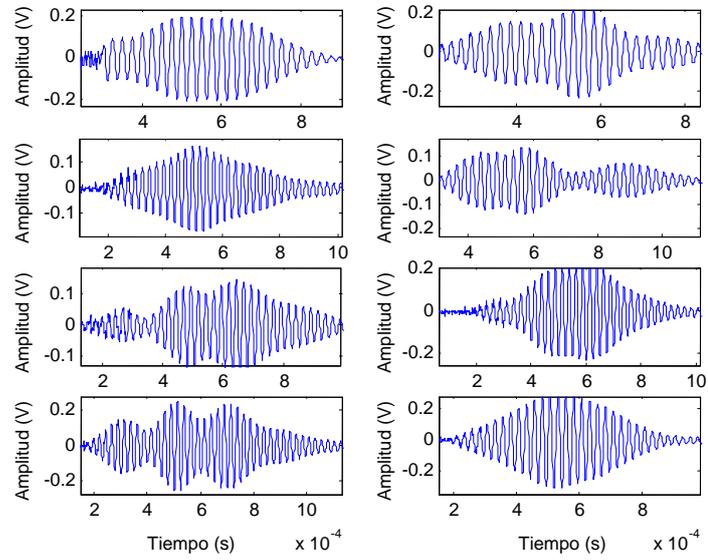


Figura 2.41: Ejemplo ecos recibidos desde los ocho sensores del array.

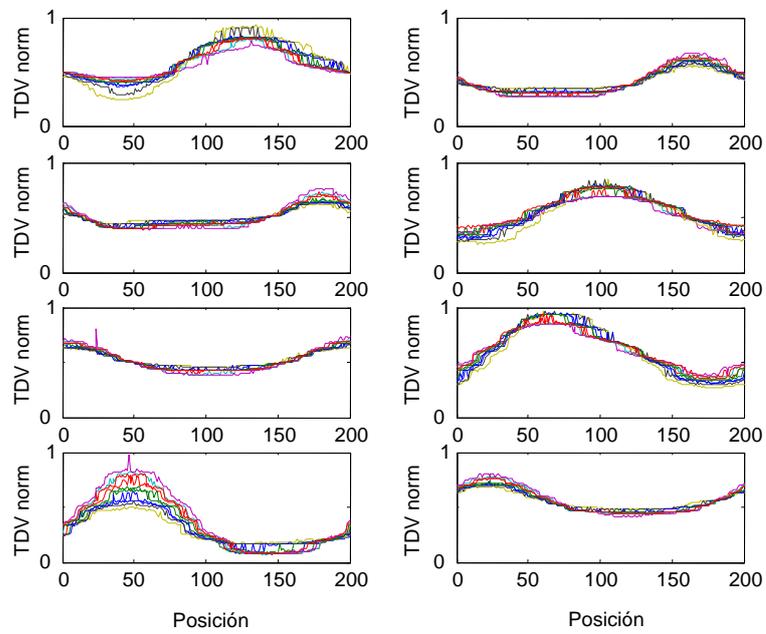


Figura 2.42: Evolución del tiempo de vuelo en los ocho sensores

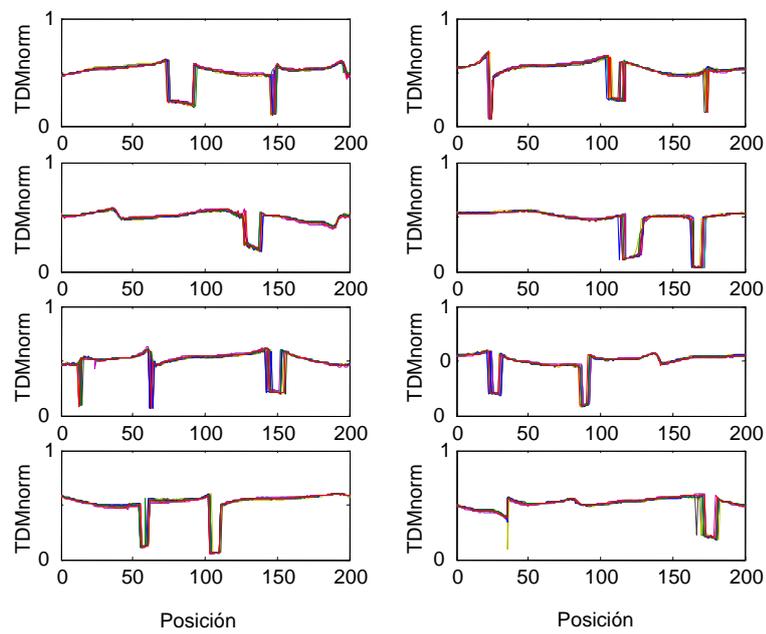


Figura 2.43: Evolución del tiempo de máximo en los ocho sensores

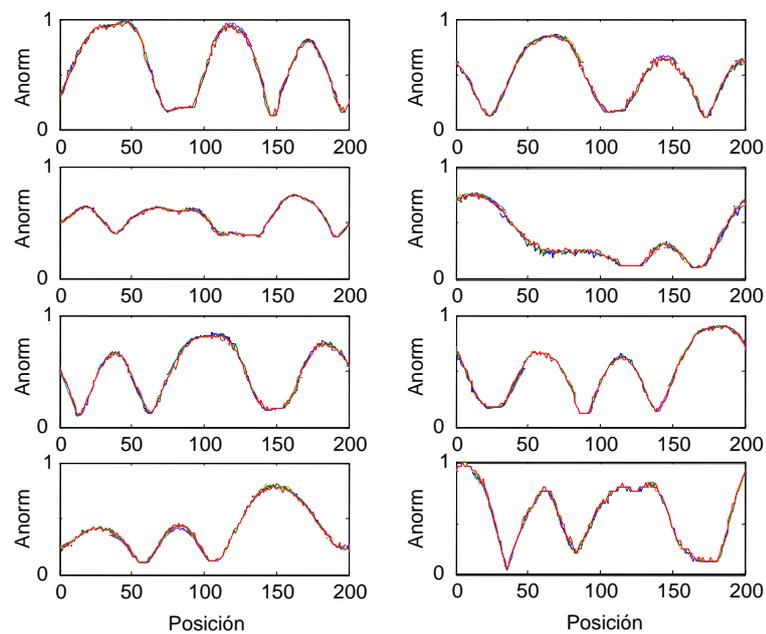


Figura 2.44: Evolución de la máxima amplitud en los ocho sensores

Analizando dichas gráficas puede verse que los resultados obtenidos pa-

ra cada repetición del experimento presentan un cierto nivel de ruido debido fundamentalmente a las variaciones de parámetros ambientales tales como temperatura, humedad o perturbaciones en el aire. Se desea obtener una aplicación robusta capaz de gestionar la incertidumbre contenida en los datos provenientes de sensores ultrasónicos debido a los efectos de los parámetros ambientales. Los efectos de la temperatura y humedad son ampliamente conocidos y documentados (ver apartado 1.2). Por ejemplo, suponiendo una presión de 1 atmósfera ( $1.013 \times 10^5$  Pa) y que la presión del vapor de agua a  $20^\circ\text{C}$  es de 2338 Pa, una variación de la temperatura de  $0^\circ\text{C}$  en aire seco a  $20^\circ\text{C}$  en aire al 40%RH produce un incremento en la velocidad de transmisión de las ondas del 3.75%. De este valor, 3.6% corresponde a la variación de la temperatura y 0.15% a la variación de humedad. Por tanto, la velocidad de transmisión es mucho más sensible a los cambios de temperatura que de humedad.

También hay que tener en cuenta que la atenuación de los ultrasonidos en el aire se incrementa con la frecuencia y que, a una frecuencia dada, la atenuación varía en función de la humedad. Estas variaciones de la atenuación debidas a la humedad cuando la frecuencia central del sensor es de 40 kHz son muy bajas. En concreto, para variaciones de humedad relativa entre el 35% y 65% apenas es apreciable. Por tanto si se tiene en cuenta la temperatura y la humedad y se corrigen sus efectos sobre los parámetros analizados, se puede suponer que el resto de variaciones que sufren las señales son debidas a las posibles perturbaciones aleatorias que se produzcan en el aire. Manteniendo constantes la temperatura y humedad durante la toma de datos se puede obtener el rango de variación, difícilmente modelizable, de dichos parámetros ante estas turbulencias del aire que añaden cierto grado de incertidumbre a las medidas.

La figura 2.45 muestra un ejemplo del grado de variación que puede presentar la curva del tiempo de vuelo ante la presencia y ausencia de este tipo de perturbaciones. En este ejemplo se han representado las curvas correspondientes a diez barridos de posición completos observándose este alto grado de dispersión que presentan los datos en el primer caso. Por tanto ha de tenerse en cuenta este factor de incertidumbre en las medidas a la hora de diseñar el sistema.

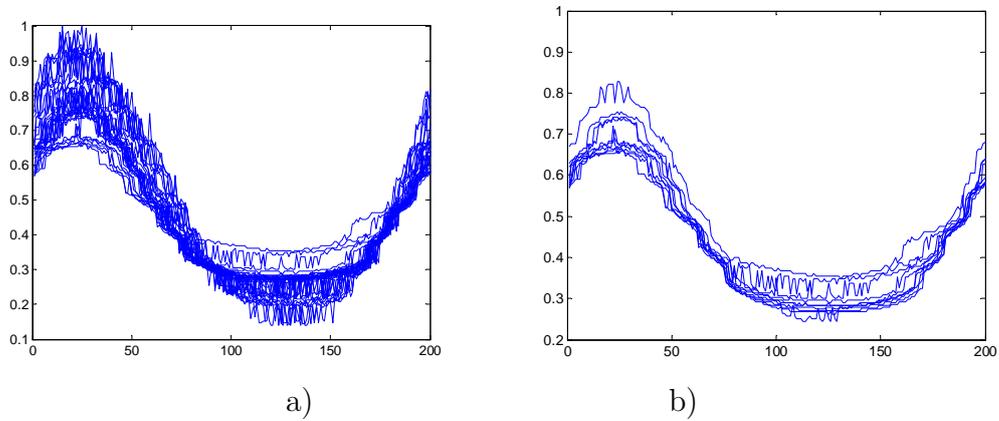


Figura 2.45: Ejemplo de datos del tiempo de vuelo a) con perturbación y b) sin perturbación

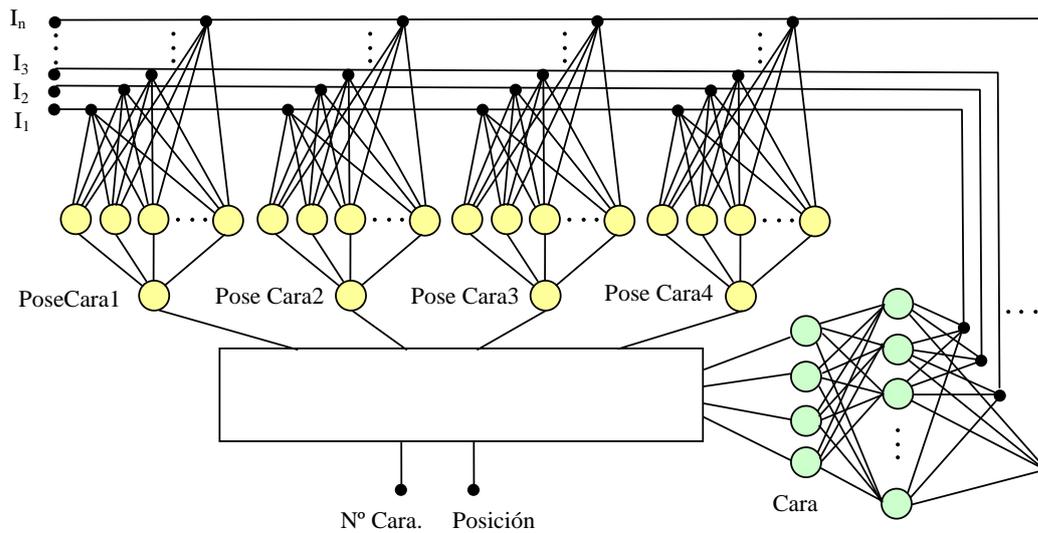


Figura 2.46: Configuración de redes

Para identificar la posición estable en la que reposa la pieza y su ángulo de giro relativo a la posición de referencia, se han empleado un conjunto de redes neuronales tal como se muestra en la figura 2.46.

Como entrada a dichas redes se han empleado los parámetros seleccionados anteriormente. Como puede verse en los ejemplos de representación de dichos parámetros mostrados en las figuras 2.42, 2.43 y 2.44 dichas características

tienen una variación no lineal por lo que se emplearán redes neuronales que sean capaces de aprender esta naturaleza no lineal de los parámetros intentando aproximar lo más posible el modelo real de comportamiento.

Para reducir la carga computacional se pretende reducir el número de sensores empleado. En cada caso, la selección de sensores ha sido realizada basándose en el análisis de dispersión de los datos, ya que la forma del objeto insonificado influye en gran medida la repetibilidad de los mismos. A partir de un análisis estadístico de las curvas normalizadas para el total de sensores del array, se han seleccionado aquellos cuyas curvas de parámetros presentaron la menor dispersión y el mayor rango de variación para el total de las caras de la pieza.

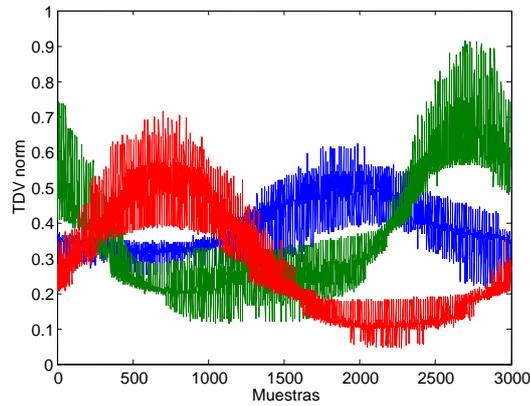


Figura 2.47: Sensores 1, 3 y 7

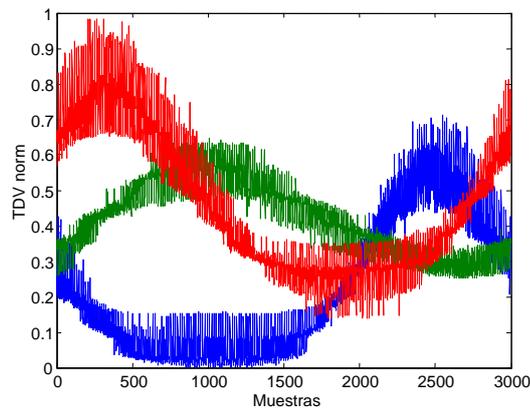


Figura 2.48: Sensores 2, 6 y 8

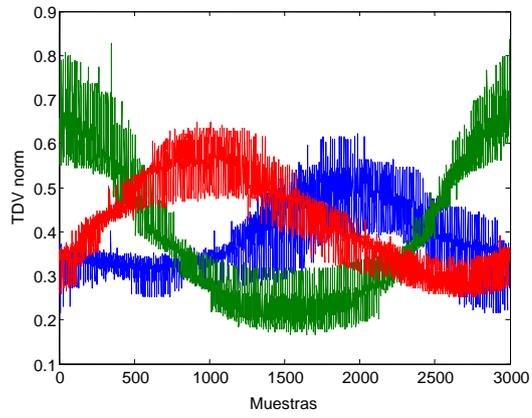


Figura 2.49: Sensores 1, 5 y 6

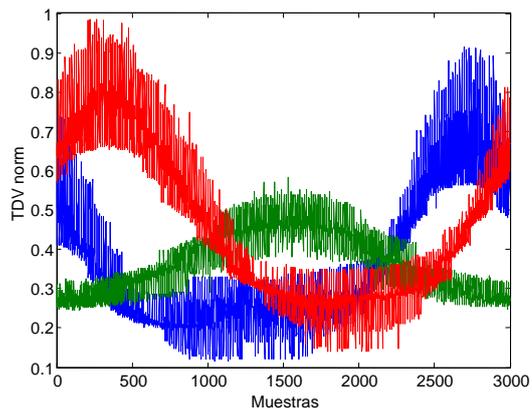


Figura 2.50: Sensores 3, 4 y 8

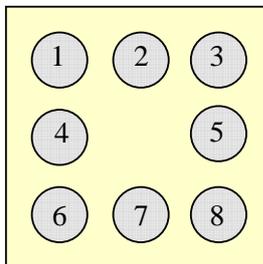


Figura 2.51: Numeración sensores receptores

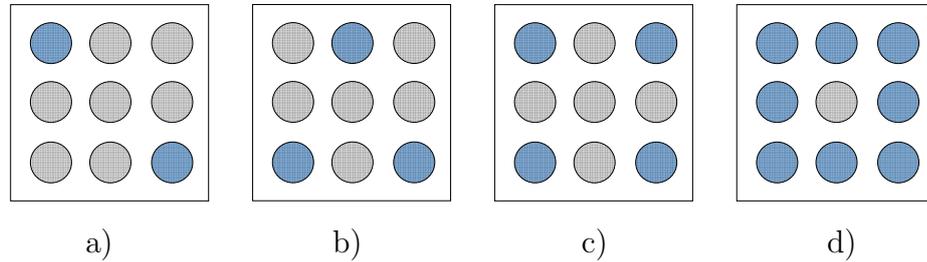


Figura 2.52: Configuraciones de a) dos, b) tres, c) cuatro y d) ocho sensores

Las figuras 2.47, 2.48, 2.49 y 2.50 muestran cuatro combinaciones posibles de tres sensores para una de las características de una de las caras de la pieza. La distribución de los sensores empleada puede verse en la figura 2.51.

La figura 2.52 y la tabla 2.6 muestran las combinaciones de sensores seleccionadas para cada una de las configuraciones evaluadas. Puede observarse en esta tabla que las configuraciones empleadas se resumen en cuatro distribuciones de sensores combinadas con una, dos y tres características. Para todas las configuraciones mostradas en la tabla 2.6 se han ido evaluando las estructuras de las redes neuronales incrementando de una en una el número de neuronas ocultas empleadas.

Configuración	Sensores	Nº de características	Neuronas ocultas
1	1,8	1	3-30
2	1,8	1,2	3-30
3	1,8	1,2,3	3-30
4	2,6,8	1	3-30
5	2,6,8	1,2	3-30
6	2,6,8	1,2,3	3-30
7	1,3,6,8	1	3-30
8	1,3,6,8	1,2	3-30
9	1,3,6,8	1,2,3	3-30
10	1,2,3,4,5,6,7,8	1	3-30
11	1,2,3,4,5,6,7,8	1,2	3-30
12	1,2,3,4,5,6,7,8	1,2,3	3-30

Tabla 2.6: Combinaciones de entradas y neuronas ocultas analizadas

Para el entrenamiento de las redes se ha empleado backpropagation con

el algoritmo de optimización de Levenberg-Marquardt [39, 53]. Este método resulta útil para mejorar la convergencia de la red cuando el número de pesos no es demasiado grande. En todos los casos se han separado los datos disponibles en dos conjuntos del mismo tamaño, empleando uno de ellos para el proceso de entrenamiento y el otro para el proceso de validación.

En primer lugar se ha realizado la configuración y el entrenamiento de la red de clasificación de caras estables. Para ello se ha empleado una red neuronal de dos capas que debe identificar la cara estable de la pieza. Como se ha mencionado anteriormente, la capa oculta de esta red está formada por neuronas no lineales con funciones de activación de tipo sigmoide.

La codificación de las cuatro caras estables es de tipo uno-de-cuatro según se muestra en la tabla 2.7, esto decir, las salidas están codificadas en binario .

Nº de cara	Salida			
	1	2	3	4
1	1	-1	-1	-1
2	-1	1	-1	-1
3	-1	-1	1	-1
4	-1	-1	-1	1

Tabla 2.7: Codificación de las caras

La red recibe como entradas la información de las características anteriormente indicadas de los sensores. La estructura de la red está formada por una capa de neuronas ocultas y una capa con cuatro neuronas de salida.

Se ha analizado en primer lugar el caso en que no existen perturbaciones ambientales. Se comienza analizando la configuración más simple de las mostradas en la tabla 2.6, como es la que emplea dos sensores y una característica. Se han utilizado para el entrenamiento ocho mil casos cubriendo el rango completo de posibles situaciones para cada una de las caras: diez muestras por posición, doscientas posiciones y cuatro caras. Para este caso puede verse en la figura 2.53 la evolución del error medio cuadrático *mse* obtenido durante el proceso de validación para un rango de tres a diez neuronas ocultas. Puede verse también en esta figura cómo con esta simple configuración de red es suficiente para conseguir la correcta clasificación con una baja tasa de error.

Se analiza ahora el caso en que las señales están afectadas por variaciones de los parámetros ambientales. Se muestran en la tabla 2.8 los resultados obtenidos. Puede observarse en esta tabla que no es necesario emplear redes muy complejas para obtener un alto porcentaje de éxito en la clasificación de las caras. En este caso la configuración de entradas formada por cuatro sensores y dos características por sensor permite alcanzar sólo un 0.25 % de errores de clasificación.

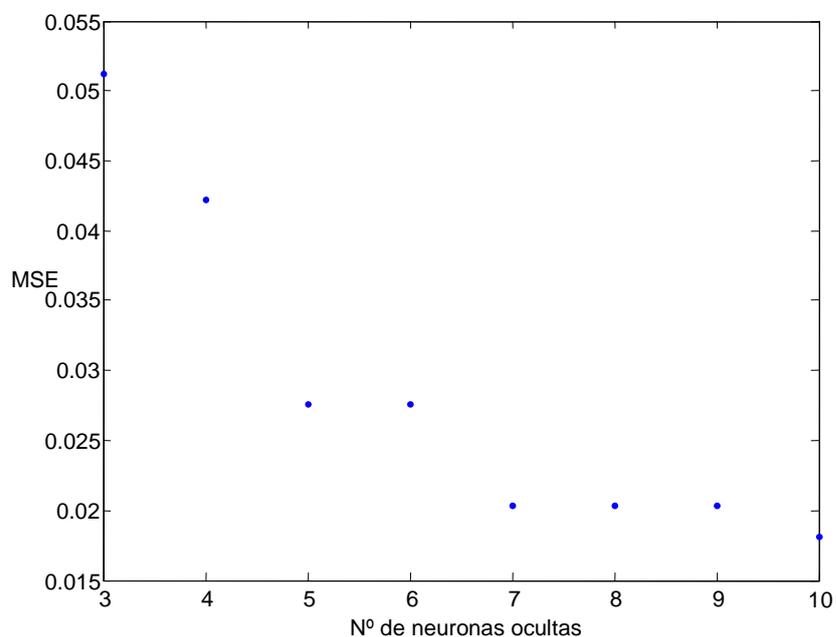


Figura 2.53: Ejemplo de evolución del mse para clasificación de cara

En segundo lugar se ha realizado el análisis para el caso de estimación de la posición del objeto. Para ello se han entrenado cuatro redes independientes para obtener el ángulo de rotación de cada una de las cuatro caras de la pieza. Las redes empleadas constan de dos capas donde la capa oculta está construida a base de neuronas no lineales capaces de aprender los comportamientos no lineales de los parámetros seleccionados, y la capa de salida está formada por neuronas lineales capaces de responder en el rango de valores de salida fijado para la precisión de 1.8 grados.

Se considerándose en primer lugar el caso de ausencia de perturbaciones ambientales. Para ilustrar los resultados obtenidos se muestra a continuación el estudio para una de las caras estables. Para cada configuración de red mostrada en la tabla 2.6 se han realizado diez entrenamientos independientes. El conjunto de datos empleados estuvo formado por dos mil combinaciones cubriendo todo el rango de posiciones, tomando diez muestras por cada una de las doscientas posiciones. En todos los caso y por propósitos de comparación de resultados se limitó a cien el número de epochs de entrenamiento.

Nº. Sensores	Características	Nº neuronas ocultas	Min. error en entrenamiento	Min. error validación	% Error clasificación
2	TOF	11	0.04810	0.05250	14.69
2	TOF-TOM	14	0.00859	0.01940	3.58
2	TOF-TOM-AM	16	0.00031	0.00590	0.94
3	TOF	9	0.01090	0.01720	3.69
3	TOF-TOM	16	0.00083	0.00651	1.04
3	TOF-TOM-AM	15	1.56e-11	0.00336	0.67
4	TOF	13	0.00695	0.01790	3.88
4	TOF-TOM	15	7.23e-11	0.00169	0.25
8	TOF	13	0.00021	0.00182	0.38

Tabla 2.8: Resultados para la clasificación de caras

En las figuras 2.54 y 2.55 se muestran de  $mse$  obtenidos para una de las caras del objeto cuando se varía el número de neuronas ocultas de tres a treinta. La figura 2.54 muestra para una de las caras estables el mínimo  $mse$  obtenido para el conjunto de datos de validación frente al número de neuronas ocultas empleando la configuración 4 de la tabla 2.6, donde se emplea la información de una sola característica de tres sensores. Puede verse en dicha figura que una estructura con más de diecisiete neuronas ocultas incrementa la carga computacional de la red pero no aporta mejoras en cuanto a las tasas de reconocimiento. Así mismo, en la figura 2.55 se muestra el mismo análisis pero para la configuración 12 de la tabla 2.6, que corresponde con el caso más complejo donde la información de entrada a la red proviene de los ocho sensores empleando las tres características de cada sensor. En este caso empleando más

de veinte neuronas ocultas no se consigue reducir más el  $mse$  sobre el conjunto de datos de validación. Esta pérdida de generalización puede ser debida a un sobreajuste a los datos de entrenamiento.

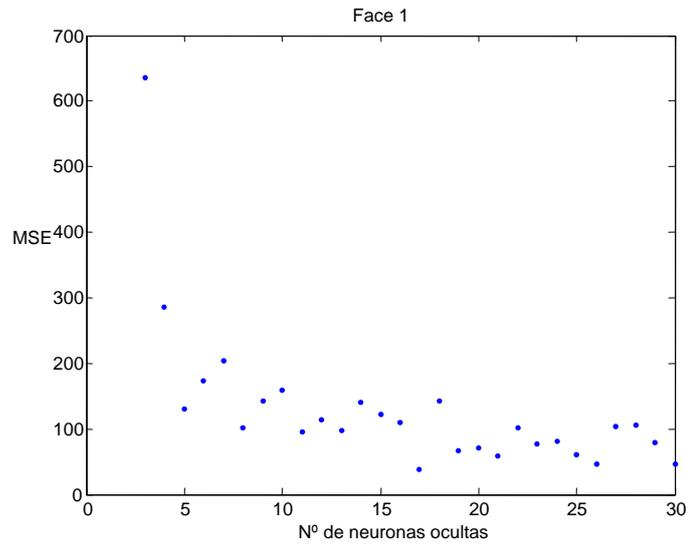


Figura 2.54: Evolución del  $mse$  para la configuración 4

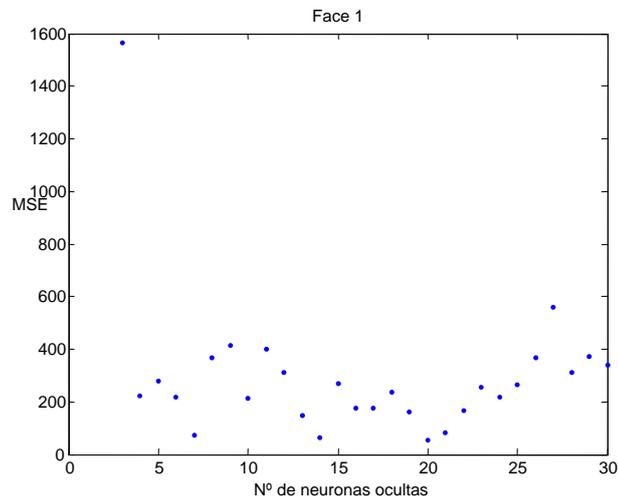


Figura 2.55: Evolución del  $mse$  para la configuración 12

Los resultados mostrados en la tabla 2.9 para las doce configuraciones ana-

lizadas permiten observar que la configuración número cinco, formada por la información de tres sensores y dos características de cada sensor, y con veintisiete neuronas ocultas, es suficientemente buena para resolver el problema y que configuraciones más complejas no mejoran los resultados. Esta tabla también muestra que la solución puede ser de dos tipos. Un primer tipo podría ser una red con pocas entradas y un gran número de neuronas ocultas como es el caso de la configuración número cinco. Y otro tipo sería emplear una red con muchas entradas y menos neuronas ocultas, como la configuración número ocho, donde se utiliza la información de cuatro sensores y dos características. Puede observarse también en esta tabla que emplear un número muy elevado de datos de entrada no permite obtener mejores resultados. Resumiendo los resultados de esta tabla puede concluirse que para esta aplicación, sobrecargar con más ocho entradas la red no aporta mejoras en los resultados.

Configuración	Neuronas ocultas	Min. MSE
1	25	359.4
2	20	141.8
3	27	34.4
4	17	38.5
5	27	11.5
6	30	31.2
7	26	40.5
8	22	18.9
9	22	30.3
10	25	18.9
11	17	52.9
12	20	56.0

Tabla 2.9: Resultados de entrenamiento sin perturbaciones

Por último se realizó el análisis de la estimación de la posición del objeto considerando las señales afectadas por perturbaciones ambientales. La tabla 2.10 muestra para una de las caras los mejores resultados obtenidos con las diferentes configuraciones de redes neuronales.

Por mantener un criterio comparativo se ha reducido el análisis al empleo de cien epochs, pudiéndose mejorar la respuesta de las redes ajustando su valor

de forma particular para cada configuración y siempre teniendo en cuenta que un sobreentrenamiento puede producir la pérdida de generalización provocando que aunque disminuya el error en el entrenamiento se produzca un incremento en el error de validación.

La tabla 2.10 muestra, para cada combinación de entradas, el número de neuronas ocultas necesarias así como el error medio cuadrático  $mse$  obtenido tanto en el proceso de entrenamiento como de validación, utilizados ambos para la selección de las redes más adecuadas.

En este caso, debido a la gran dispersión de los datos debido a las perturbaciones ambientales, el aprendizaje de las redes se ha realizado intentando reducir el error de entrenamiento sin perder la potencia de generalización de la red. Para este propósito, utilizando el conjunto de datos de validación, se han descartado aquellas redes que aún mostrando reducidos errores de entrenamiento presentaban altas tasas de error con los datos de validación. En dicha tabla se muestra el número máximo de neuronas ocultas que permiten que el error de validación no crezca o permanezca estable.

Nº. Sensores	Características	Nº neuronas ocultas	Min. error en entrenamiento	Min. error en validación
2	TOF	24	977.44	1206.88
2	TOF-TOM	30	398.31	488.00
2	TOF-TOM-AM	28	130.69	154.17
3	TOF	30	149.79	225.66
3	TOF-TOM	27	112.61	162.40
3	TOF-TOM-AM	22	84.49	74.20
4	TOF	27	103.35	196.30
4	TOF-TOM	28	87.09	159.47
4	TOF-TOM-AM	22	70.32	77.72
8	TOF	29	84.29	151.49
8	TOF-TOM	17	78.72	124.74
8	TOF-TOM-AM	26	13.01	74.15

Tabla 2.10: Resultados de entrenamiento con perturbaciones

En este caso puede observarse en la tabla que es clave el empleo de las tres características para obtener los mejores resultados. La mejor solución encontrada corresponde a la configuración de entradas formada por ocho sensores y tres características con veintiséis neuronas en la capa oculta. Esta configuración presentó un error de validación de 74.15 que se correspondía con una máxima desviación respecto de la posición correcta de diez posiciones, es decir, 18 grados. Esta configuración es claramente la mejor si se observan los valores de los errores de entrenamiento, pero si se mira a los errores con los datos de validación su respuesta es muy similar a las configuraciones de tres y cuatro sensores con tres características, siendo éstas de menor complejidad. Por tanto, para mejorar los resultados, es más importante incrementar el número de características empleadas que el número de sensores. Estos resultados difieren de los obtenidos para el caso sin perturbaciones donde empleando redes de menor complejidad se obtenían muy buenos resultados.

La precisión obtenida con este método en la posición real de la pieza no es muy elevada, pero permite obtener una respuesta de la posición del objeto en tiempos muy reducidos comparados con otros métodos tales como escaner de láser o cámaras de visión artificial y puede servir como primera aproximación y apoyo para la aplicación de éstos otros procedimientos más exactos.

## **2.12. Resumen y conclusiones del capítulo**

Se han presentado en este capítulo las redes neuronales como método de reconocimiento de patrones basado en la información proporcionada por los sensores de ultrasonidos.

Se ha realizado en primer lugar una introducción a las redes neuronales mostrando los elementos básicos que las forman, sus tipos de entrenamiento, las topologías y los tipos de redes más estandarizados.

A continuación se han propuesto una serie de casos de identificación de objetos y su posición empleando para su resolución las redes neuronales.

Paralelamente se han ido también empleando diferentes estructuras sensoricas adaptadas a cada tipo de aplicación industrial.

El primer caso analizado ha sido el reconocimiento de la orientación de piezas similares pero con diferentes grados de simetrías mediante una configuración simple formada únicamente por un par de sensores emisor y receptor. Para ello se propusieron tres soluciones basadas en redes de backpropagation, redes asociativas y redes radial basis.

El segundo caso analizado ha sido el reconocimiento de objetos empleando un array circular formado por un sensor emisor y veinticuatro sensores receptores situados en tres circunferencias centradas en el emisor. Se han analizado diferentes configuraciones de redes de tipo backpropagation con una y dos capas ocultas empleando como entrada la presión obtenida en los sensores.

El tercer caso corresponde al reconocimiento de piezas de fundición de revolución empleando un array lineal 8x2 para reconocer tipo de pieza y posición. Para ello se han empleado tres parámetros del eco, como son el tiempo de vuelo, el tiempo de amplitud máxima y la máxima amplitud y se ha propuesto para el reconocimiento de cada pieza una arquitectura formada por una red para cada sensor empleando redes backpropagations, asociativas y radial basis. En el caso del reconocimiento de la posición todas las redes utilizan información de todos los sensores.

Y el cuarto caso analizado ha sido el reconocimiento de la cara y orientación para una pieza de fundición empleando un array 3x3 de sensores de ultrasonidos. Se propone su resolución mediante la combinación de cinco redes independientes, una para la identificación de la cara y cuatro para la posición dentro de cada cara. Las redes empleadas estaban formadas por dos capas y contenían neuronas no lineales. Se ha realizado el análisis para situaciones en ausencia y presencia de perturbaciones ambientales.

Puede decirse que las redes neuronales se presentan como una buena herramienta para tareas de clasificación de patrones basados en la información proporcionada por los sensores de ultrasonidos. Permiten generar modelos de forma supervisada y exclusivamente basados en los datos de la experimentación, los cuales se le presentan para el entrenamiento. De la misma forma, puede seguir aprendiendo de nuevos datos experimentales que vayan completando a los iniciales. Son capaces de manejar las no linealidades que presentan los parámetros extraídos del eco y también son capaces de manejar la incertidumbre

que presentan dichos parámetros debido a las variaciones de los parámetros ambientales. Además presentan una alta capacidad de generalización, lo que permite resolver situaciones para las que no han sido entrenadas.

Dentro de las redes utilizadas en la experimentación, las redes de back-propagation son las que han presentado mayor versatilidad de uso y mejores resultados, sobre todo cuando el problema se va volviendo más complejo, aunque tienen como contrapartida que los tiempos de entrenamiento pueden llegar a ser muy elevados. Las redes asociativas y radial basis se han mostrado como una buena alternativa para los casos más simples ya que el tiempo de entrenamiento es mucho más reducido y su respuesta ha sido adecuada.

Como se ha visto no se pueden fijar unos criterios de diseño generales, ya que sus resultados dependen mucho de las características particulares de cada aplicación, pero en líneas generales se ha podido comprobar que aumentar en complejidad las redes no lleva siempre a una mejora en los resultados.

## Capítulo 3

# Mejora de la imagen ultrasónica mediante conjuntos difusos.

### 3.1. Introducción.

Obtener información tridimensional de objetos es de gran aplicación en el entorno industrial cuando se desea automatizar operaciones de captura y manipulación de piezas. En este aspecto los ultrasonidos brindan la posibilidad de realizar reconstrucciones de baja resolución a bajo coste, que pueden ser en algunos casos una alternativa a los costosos sistemas de visión 3D cuando no se necesita llegar a obtener un gran detalle del objeto.

En este capítulo se procede a mostrar la metodología propuesta para la mejora de las imágenes tridimensionales obtenidas a partir de sensores de ultrasonidos trabajando bajo la técnica pulso-eco empleando para ello técnicas basadas en lógica difusa, así como los resultados obtenidos sobre ensayos reales.

Se presenta en primer lugar una introducción a los conjuntos difusos mostrando las diferencias entre los conjuntos clásicos y los difusos. Se continúa con la presentación de la estructura de un sistema difuso y sus subsistemas fundamentales, describiendo para cada uno de ellos su función. Seguidamente se presentan los sistemas difusos de tipo Sugeno y los métodos de agrupamiento, o clustering, difuso. Y se continúa con las propuestas de mejora de imágenes tridimensionales aplicadas a las imágenes ultrasónicas.

## 3.2. Introducción a los conjuntos difusos.

La lógica difusa es una forma de representación del conocimiento adecuada para ideas que no pueden ser definidas con exactitud numérica pero que dentro de un contexto se entiende su valor. La lógica difusa es una lógica multivaluada que permite definir valores intermedios entre los convencionales, tales como si/no, verdadero/falso, blanco/negro, etc. Ideas como bastante caliente o un poco frío se pueden formular de forma matemática y ser procesadas por el computador. Esto permite que un computador pueda razonar de forma más humana.

En general, las aplicaciones de los conjuntos difusos es muy extensa. Se emplean en el modelado, control y supervisión de procesos industriales [30, 24, 63], en diagnóstico de fallos [22, 56], en tareas de planificación [83], en procesamiento de señal [57], etc.

Pueden encontrarse aplicaciones de conjuntos difusos en temas relacionados con reconstrucción de imágenes y ultrasonidos en trabajos sobre clasificación y reconstrucción de esquinas [25], sobre segmentación de imágenes 3D [20], sobre restauración de imágenes [62, 79, 70], sobre cálculo de volúmenes en imágenes ultrasónicas [13] y sobre detección de esquinas en imágenes 3D [78] entre otros.

### 3.2.1. Conjuntos lógicos clásicos.

La teoría de conjuntos clásica corresponde a conjuntos con límites rígidos, es decir, que un elemento solo tiene dos posibilidades, pertenecer al conjunto o no pertenecer. De esta forma, se puede establecer una función de pertenencia del siguiente modo:

$$\mu_A(x) = \begin{cases} 1 & \text{si y solo si } x \in A \\ 0 & \text{si y solo si } x \notin A \end{cases} \quad (3.1)$$

donde:

$x$  es un elemento del conjunto universal  $X$ .

$A$  es un conjunto clásico.

$\mu$  es la función de pertenencia de  $x$  a  $A$ .

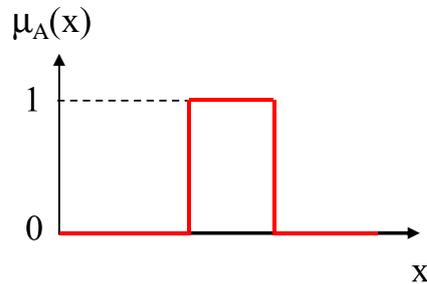


Figura 3.1: Función de pertenencia de una variable lógica

Esta función de pertenencia, representada en la figura 3.1, indica si el elemento  $x$  pertenece al conjunto  $A$  o no, y únicamente puede tomar dos valores (0 o 1), lo que puede ponerse como:

$$\mu_A : X \rightarrow \{0, 1\} \quad (3.2)$$

### 3.2.2. Conjuntos lógicos difusos.

Los conjuntos difusos también disponen de una función de pertenencia que proporciona información acerca de la pertenencia de un elemento  $x$  a un conjunto difuso  $A$ . Sin embargo, en esta ocasión la función de pertenencia puede tomar cualquier valor real dentro del intervalo  $[0, 1]$ , incluidos estos límites. Esto se puede expresar como:

$$\mu_A : X \rightarrow [0, 1] \quad (3.3)$$

De esta forma, a través de la función de pertenencia es posible asignar el grado de pertenencia de un elemento  $x$  a un conjunto  $A$ , lo cual representa una herramienta muy atractiva para describir las relaciones existentes en la realidad.

La figura 3.2 muestra, de forma gráfica, la función de pertenencia de una variable lógica difusa. Comparando las figuras 3.1 y 3.2 puede verse como los límites del conjunto clásico presentan un cambio brusco entre la pertenencia y a la no pertenencia. Por el contrario, en el conjunto difuso se establece un

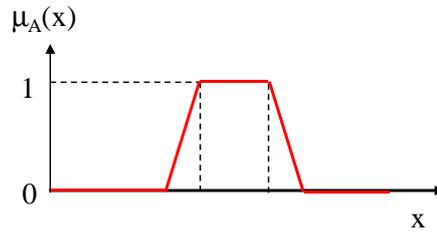


Figura 3.2: Función de pertenencia de una variable lógica difusa

cambio controlado por la denominada función de pertenencia, de forma que es posible ajustar el perfil de cambio deseado.

Es importante observar que, la aplicación de conjuntos difusos es una generalización de la teoría de conjuntos, que permite modelar la forma de cualquier conjunto en general.

En el caso de los conjuntos difusos existen infinitas posibilidades para modelar la forma que presenta la función de cambio entre la pertenencia y la no pertenencia y entre la no pertenencia y la pertenencia. Una relación de las formas más comunes de funciones de transferencia podría ser: Triangular, trapezoidal, Gaussiana, Campana, Sigmoidea, etc. Tener en cuenta, además, que no tienen porqué ser simétricas.

Una vez definido el conjunto difuso, se han de establecer los criterios para las relaciones de pertenencia, de igualdad, etc. y para las operaciones lógicas básicas entre conjuntos, tales como el complemento, la unión y la intersección que se describen a continuación.

Complemento de un Conjunto Difuso:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad \forall x \in X \quad (3.4)$$

Unión entre dos Conjuntos Difusos:

$$\mu_{A \cup B}(x) = \max [\mu_A(x), \mu_B(x)] \quad \forall x \in X \quad (3.5)$$

Intersección entre dos Conjuntos Difusos:

$$\mu_{A \cap B}(x) = \min [\mu_A(x), \mu_B(x)] \quad \forall x \in X \quad (3.6)$$

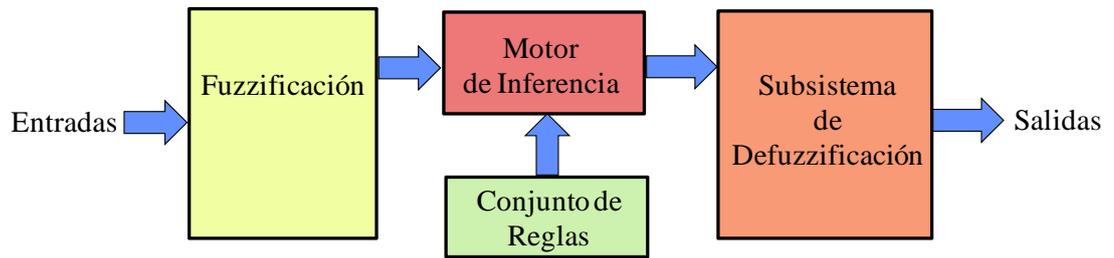


Figura 3.3: Estructura de un sistema difuso

Tanto la unión como la intersección presentan diferentes definiciones y en las expresiones anteriores se han mostrado las más comúnmente utilizadas.

### 3.2.3. Estructura del sistema difuso

Un sistema fuzzy realiza una asignación (mapeado) no lineal entre las entradas y salidas. Asumiendo que el sistema tiene entradas ( $u_i \in U_i$   $i = 1, 2, 3, \dots, n$ ) y salidas ( $y_i \in Y_i$   $i = 1, 2, 3, \dots, m$ ), la estructura básica del sistema de clasificación difuso es tal como la que muestra la figura 3.3. En ella se pueden ver los componentes principales del sistema de clasificación difuso, aunque su estructura es básicamente idéntica para un controlador difuso.

En esta figura se puede observar en primer lugar la llegada de las señales de entrada al sistema difuso. Como estas señales de entrada y salida toman valores pertenecientes a conjuntos clásicos o rígidos, es decir, no son números difusos si no reales, es necesario utilizar unas funciones de interface entre el sistema de inferencia difuso y el mundo exterior. Estos interfaces están formados por los subsistemas de fuzzificación, que realiza el proceso de borrosificación y el subsistema de defuzzificación, que realiza el proceso de deborrosificación. Además, se puede observar el sistema de inferencia y el conjunto de reglas sobre las que trabaja el sistema de inferencia. A continuación, y de forma muy breve, se presenta el conjunto de elementos que van a formar parte del sistema difuso.

Los conjuntos clásicos  $U_i$  y  $Y_i$  forman el universo de discurso de las entradas  $u_i$  y de las salidas  $y_i$ , respectivamente, y corresponden al conjunto de todos los posibles valores que puede tomar cada entrada y cada salida.

Para especificar las reglas que regirán el sistema, el experto utiliza una descripción lingüística. Por este motivo aparecen las variables lingüísticas, que se utilizan para describir las entradas y salidas del sistema experto de una forma más próxima al lenguaje humano. De esta forma, se denotará como  $\tilde{u}_i$  a la variable lingüística que describe la entrada  $u_i$ , como por ejemplo “Amplitud Máxima”, y como  $\tilde{y}_i$  a la variable lingüística que describe la salida  $y_i$  como por ejemplo “Pendiente de salida”.

De la misma forma en que las entradas  $u_i$  y las salidas  $y_i$  toman valores sobre los universos de discurso  $U_i$  y  $Y_i$ , las variables lingüísticas  $\tilde{u}_i$  y  $\tilde{y}_i$  toman valores lingüísticos, como por ejemplo “Bajo”. Se denotará como  $\tilde{A}_i^j$  al  $j$ -ésimo valor lingüístico de la variable  $\tilde{u}_i$ , y como  $\tilde{B}_i^j$  al  $j$ -ésimo valor lingüístico de la variable  $\tilde{y}_i$ . Si se asume que la variable lingüística  $\tilde{u}_i$  tiene  $N_i$  posibles valores y la  $\tilde{y}_i$  tiene  $M_i$  posibles valores, se puede definir el conjunto de todos los posibles valores de una variable lingüística  $i$  como  $\tilde{A}_i = \{ \tilde{A}_i^j : j = 1, 2, \dots, N_i \}$  y  $\tilde{B}_i = \{ \tilde{B}_i^p : p = 1, 2, \dots, M_i \}$

La asignación entre entradas y salidas se realiza mediante la utilización de un conjunto de reglas IF-THEN, en modus ponens, de la forma IF *premisa* THEN *consecuencia*.

Estas reglas actúan sobre la información lingüística, obteniéndose reglas tal como IF ( $\tilde{u}_1 = \tilde{A}_1^j$ ) THEN ( $\tilde{y}_q$  es  $\tilde{B}_q^p$ ).

Como ya se ha indicado anteriormente las funciones de pertenencia permiten ajustar el grado de pertenencia de cada valor del universo de discurso a un valor lingüístico. Estas funciones van a ser de vital importancia para los sistemas de fuzzificación y defuzzificación.

La lógica fuzzy es la herramienta matemática que permite trabajar con los conjuntos difusos formados y que van a ser utilizadas para realizar las operaciones lógicas indicadas por las reglas lingüísticas, estando entre las operaciones más habituales el complemento, la intersección u la unión de conjuntos difusos.

El subsistema de fuzzyficación permite asignar a cada una de las estradas al clasificador difuso el valor correspondiente al grado de pertenencia que presenta el valor recibido con ciertas variables lingüísticas definidas previamente. A partir de este subsistema las entradas ya no corresponden a valores reales si

no que pasan a formar parte de las variables lingüísticas con un índice de pertenencia a cada una de ellas fijado en función de la magnitud de la entrada y de las funciones de pertenencia definidas por el ingeniero de conocimiento.

El mecanismo de inferencia se encarga de dos tareas básicas. En primer lugar debe buscar cual es el conjunto de reglas relevantes para la situación actual. Esto lo hace observando los valores de las entradas para el instante actual. Por otro lado, la otra tarea del sistema de inferencia es la de extraer conclusiones mediante la aplicación de los valores de las entradas actuales a la base de conocimiento formada por el conjunto de reglas lingüísticas.

Por último el subsistema de defuzzificación realiza la operación inversa al sistema de fuzzificación, esto es, obtener una valor real a partir del conjunto difuso obtenido tras el proceso de inferencia. En la actualidad se vienen utilizando diferentes métodos de defuzzificación, estando entre los más utilizados los siguientes operadores:

- Centro de gravedad:

$$y_q^{crisp} = \frac{\sum_{i=1}^R b_i^q \int_{y_q} \mu_{\hat{B}_q^i}(y_q) \cdot d(y_q)}{\sum_{i=1}^R \int_{y_q} \mu_{\hat{B}_q^i}(y_q) \cdot d(y_q)} \quad (3.7)$$

Siendo:

$\hat{B}_q^i \Rightarrow$  Valor lingüístico  $i$  para la variable lingüística de salida  $q$ .

$\mu_{\hat{B}_q^i} \Rightarrow$  Función de pertenencia  $i$  para la variable lingüística de salida  $q$ .

$b_i^q \Rightarrow$  centro del área de la función de pertenencia  $\hat{B}_q^p$ .

$R \Rightarrow$  Número de reglas.

$y_q \Rightarrow$  Universo de discurso de la salida  $q$ .

$y_q^{crisp} \Rightarrow$  Valor real (crisp) de la salida  $q$ .

- Centro de promedio:

$$y_q^{crisp} = \frac{\sum_{i=1}^R b_i^q \cdot \sup_{y_q} \left( \mu_{\hat{B}_q^i}(y_q) \right)}{\sum_{i=1}^R \sup_{y_q} \left( \mu_{\hat{B}_q^i}(y_q) \right)} \quad (3.8)$$

donde sup indica “supremo” y se corresponde con el valor máximo de la función de pertenencia.

Si se establecen funciones de pertenencia cuyo valor máximo sea la unidad, lo cual es lo habitual, se puede calcular el valor defuzzificado muy fácilmente ya que se cumple:

$$\sup_{y_q} \left( \mu_{\hat{B}_q^i}(y_q) \right) = \mu_i(u_1, u_2, \dots, u_n) \quad (3.9)$$

Con lo cual, la defuzzificación queda como:

$$y_q^{crisp} = \frac{\sum_{i=1}^R b_i^q \cdot \mu_i(u_1, u_2, \dots, u_n)}{\sum_{i=1}^R \mu_i(u_1, u_2, \dots, u_n)} \quad (3.10)$$

### 3.2.4. Sistemas difusos de tipo Sugeno

Los sistemas expertos difusos que se han presentado anteriormente corresponden, principalmente, a los “sistemas difusos estándar” o “sistemas tipo Mamdani”. Sin embargo, existe una variación de estos en la que no se utiliza un término lingüístico (asociado con una función de pertenencia determinada) para la salida del sistema, si no que se utiliza una función. De esta forma, las reglas de este tipo de sistemas son de la forma:

IF ( $\tilde{u}_1 = \tilde{A}_1^j$ ) THEN ( $y_q = g(\cdot)$ )

donde:

$\tilde{u}_1$  es la variable lingüística asociada a la entrada 1.

$\tilde{A}_1^j$  es el valor lingüístico de la entrada 1 en el instante  $j$ .

$y_q$  es el valor de la salida  $q$ .

$g_q(\bullet)$  es la función de salida  $q$ .

$\bullet$  es el argumento de la función  $g$ .

La forma de la función  $g$  puede ser cualquiera, y depende de la aplicación a la que se aplique. Ejemplos de tales funciones pueden ser las siguientes:

$$g_q = a_{q,0} + a_{q,0} \cdot (u_1)^2 + \dots + a_{q,n} \cdot (u_n)^2 \quad (3.11)$$

o

$$g_q = e^{[a_{q,1} \cdot \text{sen}(u_1) + \dots + a_{q,n} \cdot \text{sen}(u_n)]} \quad (3.12)$$

Sin embargo, una de las funciones más sencillas y, por lo tanto, que permiten un cálculo más rápido es aquella en la que la función toma un valor constante:

$$g_q = a_q \quad (3.13)$$

### 3.2.5. Algoritmo de agrupamiento basado en lógica borrosa: Fuzzy c-means.

Es posible automatizar el diseño del sistema difuso a partir de datos de entrada/salida. El objetivo es entonces diseñar un sistema que caracterice el comportamiento implícito en los datos de entrada/salida utilizados como muestra.

Uno de los métodos para definir el sistema de inferencia es un método basado en agrupamientos.

A partir de todos los datos de entrada, cada uno de  $n$ -dimensiones, se forman agrupamientos. En los centros de los grupos se ubican entonces los centros de las funciones de pertenencia de las entradas. Sus parámetros, como por ejemplo, la dispersión en funciones de pertenencia de tipo gaussiano, son función del número y la distribución de los datos que forman cada grupo. A continuación, se formularán reglas sólo para las combinaciones de funciones de pertenencia de entradas que formen grupos, es decir, se genera una base de reglas con una partición dispersa de los espacios de entrada. En estos casos, los consecuentes de las reglas del sistema de inferencia difuso son de tipo Sugeno, por lo que sus parámetros lineales se suelen sintonizar con métodos de mínimos cuadrados. No obstante, las técnicas de agrupamiento difuso resultan de interés no solo para construir sistemas de inferencia, sino para agrupar datos utilizando la lógica difusa. Uno de los métodos de agrupamiento o clusterizado difuso más popular es el clusterizado fuzzy c-means.

El método de clusterizado fuzzy c-means es un algoritmo de agrupamiento de datos en el cual cada dato puntual pertenece a un grupo o cluster con un grado determinado especificado por un grado de pertenencia. Bezdek introdujo originalmente esta técnica en 1973 [14].

Este método, mostrado en [32, 80], particiona un conjunto de  $n$  vectores  $x_j$ ,

donde  $j=1, \dots, n$  en  $c$  grupos difusos y encuentra un centro de grupo o cluster en cada grupo, tal que se minimice una función de coste basada en una función de distancia. Al ser grupos difusos un punto dado puede pertenecer a varios grupos con un grado de pertenencia especificado por un valor entre 0 y 1. Estos valores son recogidos en una matriz de pertenencia  $U$ . Sin embargo, la imposición de normalización estipula que la suma de los grados de pertenencia para un conjunto de datos debe ser siempre igual a la unidad:

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n \quad (3.14)$$

La función de coste o función objetivo para fuzzy c-means es:

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_j^n u_{ij}^m d_{ij}^2 \quad (3.15)$$

donde:

$u_{ij}$ : valor entre 0 y 1

$c_i$ : centro del cluster del  $i$ -ésimo grupo fuzzy

$d_{ij} = \|c_i - x_j\|$ : distancia euclídea entre el  $i$ -ésimo cluster y el  $j$ -ésimo dato.

$m$ : coeficiente de ponderación  $m \in [1, \infty)$

Las condiciones necesarias para que la función de coste 3.15 alcance su mínimo son:

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (3.16)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left( \frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}} \quad (3.17)$$

Mediante un proceso iterativo, el método fuzzy c-means determina los centros de los clusters  $c_i$  y la matriz de pertenencia  $U$  siguiendo los siguientes pasos:

1. Inicializa la matriz de pertenencia  $U$  con valores aleatorios entre 0 y 1 tal que las restricciones de la ecuación 3.14 se satisfagan.

2. Calcula  $c$  centros de los clusters
3. Calcula el valor de la función de coste 3.15. Para si alcanza o está por debajo de un cierto valor de tolerancia o si su mejora respecto a la iteración previa está por debajo de un cierto umbral.
4. Calcula una nueva matriz de pertenencia  $U$  mediante 3.17. Vuelve al paso 2.

### 3.3. Propuestas y resultados en la mejora de imágenes ultrasónicas.

#### 3.3.1. Introducción

En este trabajo se ha combinado el uso de sensores de ultrasonidos con el uso de las técnicas fuzzy para la mejora de la imagen tridimensional. A partir de la información de los sensores de ultrasonidos se han obtenido las imágenes tridimensionales ultrasónicas iniciales de piezas pertenecientes a una cadena de producción, y mediante el uso de técnicas fuzzy se ha mejorado y realizado dichas imágenes ultrasónicas. Esta técnica se ha aplicado al reconocimiento de piezas de fundición durante su transporte sobre una cinta transportadora empleando un array estático de sensores ultrasónicos.

Como en los trabajos anteriores, el motivo de usar una técnica de detección basada en sensores de ultrasonidos es debido a las ventajas que estos presentan frente a otros métodos. Con el procesado de señal adecuado, estos sensores dan información acerca de distancias, posición, orientación y características del objeto, con una rápida respuesta de tiempo. Y si se hace un barrido del objeto nos permitirá realizar una reconstrucción tridimensional de baja resolución del objeto empleando un hardware simple, ya que los sensores de ultrasonidos son robustos y su tamaño y peso reducidos, con lo cual no son difíciles de situar en el espacio de trabajo. Son además especialmente indicados para aquellas aplicaciones en las que se desea una respuesta rápida y de bajo coste, ya que su precio es muy reducido comparado con el de un sistema de visión artifi-

cial. Permiten además recuperar una imagen tridimensional del objeto frente a métodos como las cámaras de visión artificial que solo ofrecen una visión en dos dimensiones. Otro motivo para la utilización de este tipo de sensores pueden ser las condiciones medioambientales que se den, ya que los sensores de ultrasonidos se pueden utilizar para trabajos en lugares mal iluminados o en los que haya presencia de humos y donde por tanto la visión artificial no sería una solución adecuada. También hay que decir que a pesar de las ventajas que poseen, existe la desventaja de que este tipo de señales posee un cierto nivel de ruido intrínseco que hace que la información obtenida tenga un cierto grado de incertidumbre y por ese motivo el uso de técnicas fuzzy parece ser adecuado para la reconstrucción de la imagen ultrasónica. Aunque la información que se puede obtener de un eco ultrasónico es muy elevada [48, 46] en este caso, de todos los posibles parámetros obtenibles del eco ultrasónico recibido, solamente se van a tener en cuenta un número muy limitado de ellos para la reconstrucción.

El sistema desarrollado utiliza la información obtenida de un array de sensores de ultrasonidos en una distribución 2x8 formando ocho parejas de emisor y receptor tal como se muestra en las figuras 3.4 y 3.5. Estos sensores trabajan bajo la técnica de pulso-eco, donde el emisor es excitado por un pulso que genera en dicho transductor una señal ultrasónica que viaja a través del aire, colisiona con el objeto y parte de ella es reflejada formando el eco. Este array se sitúa en posición transversal al movimiento de la pieza para realizar un barrido de ella. La forma de la superficie del array donde se alojan los sensores no es plana sino que está formada por dos zonas de diferente pendiente formando una cuña, como puede verse en la figura 3.5. Esta forma de cuña es para favorecer la eliminación de rebotes sucesivos entre el objeto y el array. Los sensores utilizados son Murata 40B8 R/S (ver tabla 1.1), los cuales trabajan a una frecuencia de 40 kHz y poseen un ángulo de radiación de  $100^\circ$ , lo cual permite ajustar la zona insonificada por cada sensor en el barrido ajustando la distancia vertical del sensor al objeto. Este parámetro es muy importante ya que marca la mayor resolución alcanzable. Si se desea mayor resolución es necesario utilizar sensores que trabajen a mayor frecuencia. En este caso el array ha sido situado a una distancia 7 cm por encima de la pieza más alta.

Esto se traduce en una zona enfocada por cada emisor de aproximadamente un radio de 10 cm. De esta forma utilizando únicamente la medida de distancias a la zona enfocada, se puede detectar la altura de la pieza en cada una de las posiciones. La adquisición de la señal del eco captada por los receptores se realiza de forma secuencial a lo largo de todos los sensores para evitar recoger ecos provenientes de otros sensores adyacentes. Una vez adquirido el eco, éste es filtrado digitalmente mediante el filtro Butterworth 1.15 para eliminar la señal portadora a 40 kHz y obtener la envolvente del eco. La forma de extraer la información sobre la geometría de la pieza del eco ultrasónico es mediante la obtención de una serie de características de la envolvente del eco recibido (ver tabla 1.3).

El barrido de la pieza se realiza gracias al movimiento de la pieza durante su transporte por ejemplo sobre una cinta transportadora. De esta forma se puede obtener información tridimensional de la pieza, ya que al estar el array situado en dirección transversal al movimiento de la pieza, se realiza un barrido en dos dimensiones del objeto, y las distancias obtenidas a través de los sensores de ultrasonidos permiten calcular la tercera dimensión de cada posición. La velocidad de movimiento del objeto y el periodo de muestreo en el sistema de adquisición de datos fija la resolución en la dirección del movimiento. En la dirección transversal dicha resolución viene fijada por el número de pares de sensores empleado.

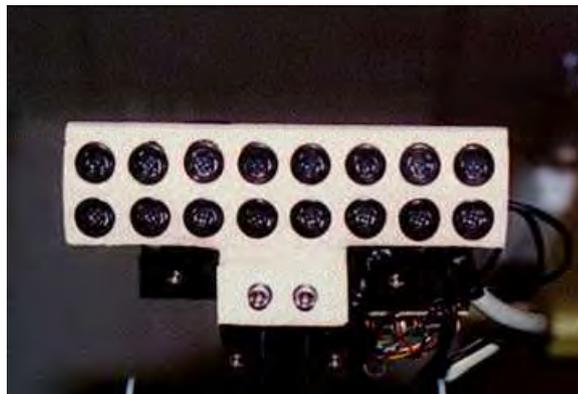


Figura 3.4: Vista inferior del array lineal de sensores

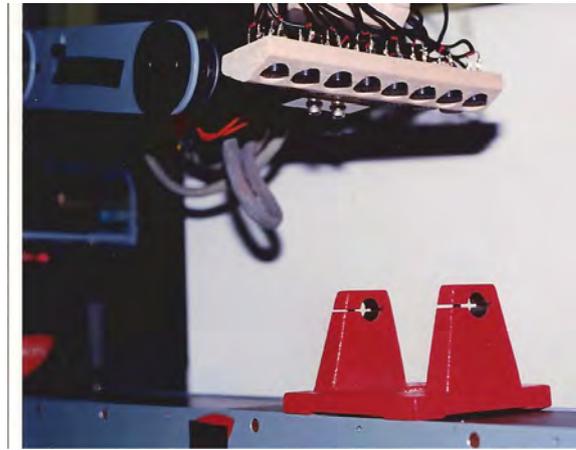


Figura 3.5: Vista lateral del array lineal de sensores

### 3.3.2. Suavizado y realzado fuzzy a partir de la imagen 3D basada en el tiempo de amplitud máxima.

Se pretende desarrollar un sistema de mejora de la reconstrucción 3D de un objeto obtenido a partir de un barrido de la pieza mediante un array lineal de sensores de ultrasonidos empleando para ellos un sistema fuzzy [74].

De las características obtenidas para la reconstrucción de la imagen en este caso se ha considerado exclusivamente el tiempo de amplitud máxima por contener información fiable y con menos variaciones, de la distancia entre la pieza y el sensor. Como el barrido de la pieza se está realizando en dos dimensiones, añadiendo a estas coordenadas la información obtenida del sensor, se puede hacer una reconstrucción tridimensional aproximada de la forma del objeto.

Esta característica es utilizada después para la toma de decisiones del sistema fuzzy desarrollado para realizar un realce de la imagen ultrasónica obtenida. Este tiempo, eliminando el correspondiente al transitorio del eco, corresponderá a dos veces la distancia recorrida entre la zona enfocada de la pieza y el sensor correspondiente dentro del array. Teniendo como referencia la distancia que existe a la superficie de apoyo de la pieza, es fácil obtener la altura de la misma para el punto considerado. Para obtener la información de toda la pieza es necesario hacer un barrido sobre ella con dicho array y en este caso se ha

realizado aprovechando el movimiento de la cinta transportadora. Para ello se ha colocado un array longitudinal, de longitud tal que abarca el ancho total de las piezas, colocado transversalmente a la dirección de movimiento de la cinta. Ajustando la velocidad de la cinta y la frecuencia de toma de ecos se obtiene la resolución de puntos con que generar la forma tridimensional del objeto. En la figura 3.6 puede verse una de las piezas ensayadas y en la figura 3.7 se indica de forma esquematizada la forma de la pieza. Esta pieza pertenece a una cadena de fabricación de piezas de fundición y se desea hacer una recuperación de la imagen mediante el barrido del array de sensores para su posterior clasificación dentro del sistema.



Figura 3.6: Pieza ensayada

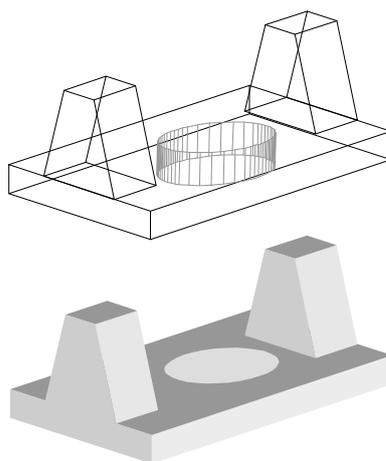


Figura 3.7: Esquema de la pieza

El sistema fuzzy recibe la información de la forma del objeto según lo indicado anteriormente, es decir, por medio de las alturas de los diferentes puntos en cada posición dentro de la zona de barrido del sensor. Y basándose en esta información el sistema fuzzy decide las modificaciones necesarias a producir en la imagen obtenida para realizar un realzado de la imagen, y así una mejor visualización de la pieza. El motor de inferencia del sistema establece la nueva forma de la imagen conociendo el comportamiento de las señales ultrasónicas al incidir sobre diferentes formas y superficies, y propone los cambios a realizar en los datos obtenidos, para que la imagen final tenga mayor parecido con la realidad. El realce ha sido realizado en dos fases consecutivas. El primero corresponde a un suavizado de la imagen para eliminar los ruidos provenientes de la señal de ultrasonidos. Y la segunda fase consiste en el realzado en sí mismo, donde se mejora la forma real de la superficie consiguiendo una figura más nítida. Para cada una de las fases se han definido los siguientes pasos: el conjunto de entradas fuzzificadas y sus funciones de pertenencia, el conjunto de reglas y el método de defuzzificación utilizado.

A continuación se indican las dos fases en que consiste el sistema.

### **Suavizado:**

Para realizar el suavizado se ha creado un filtro fuzzy de segundo orden, mediante la utilización en serie de dos filtros fuzzy. Para ello se han utilizado como entradas al sistema fuzzy las pendientes existentes entre cada dos puntos. Las funciones de pertenencia de la entrada fuzzificada de este sistema se representa en la figura 3.8. Se han considerado cinco rangos de valores para dividir todo el espacio de las entradas en rangos fuzzy. El conjunto de reglas empleado ha sido sintonizado para suavizar las pendientes cuando la señal corresponde a ruido y mantener las pendientes actuales cuando la señal no corresponde a ruido. En este caso el proceso de inferencia se ha realizado mediante un modelo de tipo Sugeno de orden cero utilizando como método de defuzzificación la media ponderada. El método Sugeno es bueno para este tipo de aplicaciones porque se puede actuar de forma similar a un sistema interpolativo con las ventajas que ofrece el trabajar con lógica fuzzy.

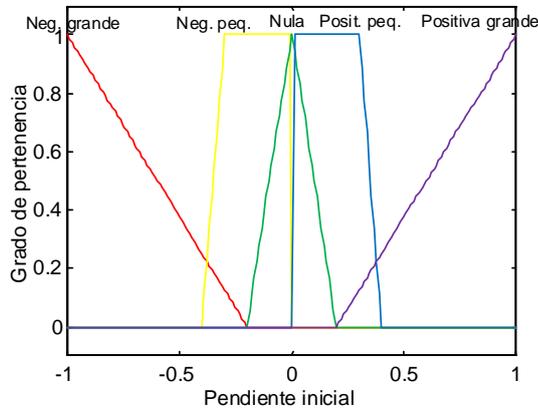


Figura 3.8: Entradas fuzzy para suavizado

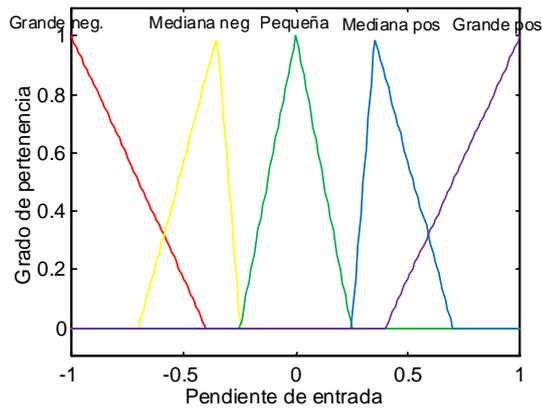


Figura 3.9: Entradas fuzzy para realce

**Realzado:**

El proceso de realzado se ha implementado mediante un sistema fuzzy de tipo Mamdani. Mediante este sistema se pretende acentuar la forma tridimensional obtenida de la pieza y que ha sido suavizada en el paso anterior para la eliminación de ruidos. En este caso las entradas al sistema vuelven a ser las pendientes entre los diferentes puntos pero ahora se pretende que el resultado sea el opuesto al suavizado, es decir, que acentúe las pendientes existentes para realzar la imagen final. El conjunto fuzzificado de las pendientes de entrada

utilizadas como entradas al sistema fuzzy se representa en la figura 3.9. En este caso se puede ver que se han considerado cinco posibles rangos de los valores de entrada. Para las salidas el correspondiente conjunto de valores fuzzy se representa en la figura 3.10. Aquí se puede ver que las salidas están formadas por tres rangos de valores. El método para obtener el valor defuzzificado de salida que ha sido utilizado en este caso ha sido el del centroide, que convierte el conjunto fuzzy de salida en el valor numérico del centro del área formada por dicho conjunto.

El conjunto de reglas empleado está enfocado a la acentuación de las pendientes existentes, ya que las imágenes ultrasónicas reconstruidas suelen suavizar las pendientes reales de los objetos. Es decir, donde existe gran pendiente, la incrementa aún más, y donde la pendiente no es elevada la disminuye.

El sistema fuzzy descrito ha sido aplicado a la reconstrucción de la imagen de la pieza mostrada en la figura 3.6. En la figura 3.11 puede verse la imagen reconstruida sólo con la información obtenida por los sensores donde puede observarse la existencia del ruido que siempre acompaña a la señales ultrasónicas y dificulta su reconocimiento.

El paso siguiente ha sido el suavizado de esta imagen, ver figura 3.12, para eliminar dicho ruido y obtener una imagen más clara.

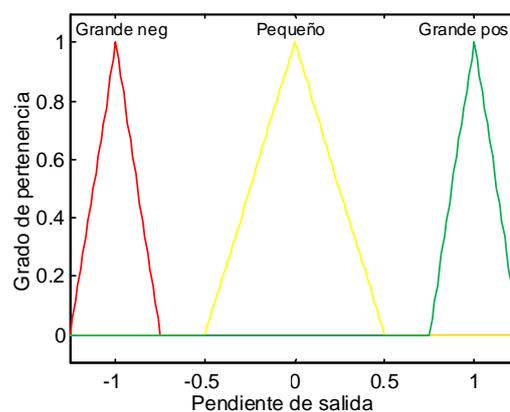


Figura 3.10: Salidas fuzzy para realce

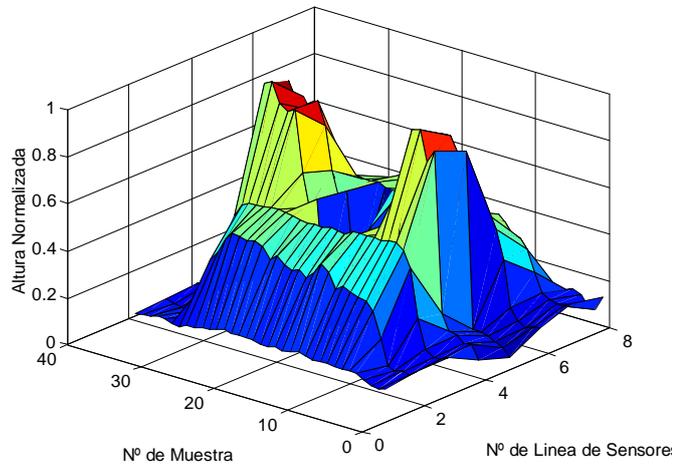


Figura 3.11: Reconstrucción inicial

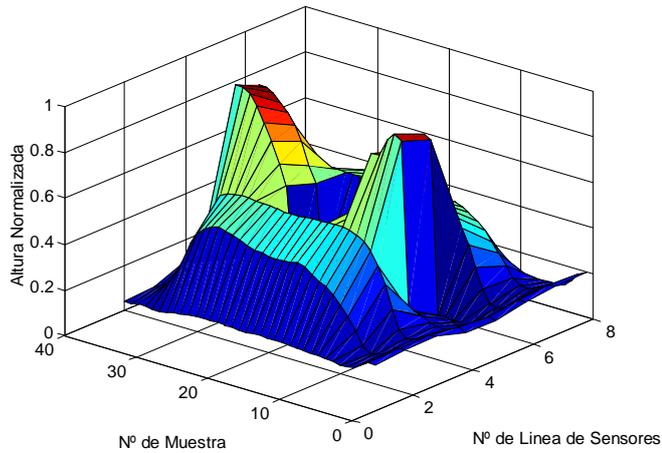


Figura 3.12: Aplicación del suavizado

Al eliminar dicho ruido la imagen obtenida pierde nitidez, por lo que es necesario aplicar el siguiente paso para realzar de nuevo las formas de la pieza obteniéndose la imagen de la figura 3.13.

En este caso se ha utilizado un array de sensores formado únicamente por ocho pares de emisores y receptores. Con este número de sensores para el tamaño de pieza considerado la resolución que se consigue no es muy alta y

se ve cómo aplicando el sistema fuzzy de realce se consigue una considerable mejora de la imagen a pesar de la baja resolución.

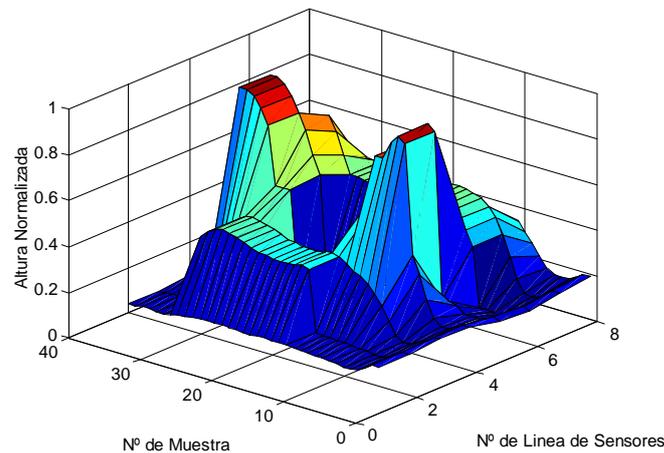


Figura 3.13: Aplicación del realce

### 3.3.3. Suavizado y realzado fuzzy a partir de la imagen 3D basada en el tiempo de vuelo y de amplitud máxima.

Se presenta a continuación otro ejemplo de mejora de imágenes tridimensionales basado en la misma estructura que el método indicado en el apartado 3.3.2. Se pretende también en este caso reconstruir y mejorar la imagen obtenida mediante el array lineal situado sobre piezas en movimiento [45]. En la figura 3.14 puede observarse la forma y disposición respecto al array de la pieza utilizada en este caso.

En esta aplicación, de la información proveniente de la envolvente del eco, se ha utilizado el tiempo de comienzo y el tiempo de máxima amplitud para obtener la distancia real del objeto al array. Igualmente el barrido de la pieza se ha realizado aprovechando el movimiento de la pieza sobre una cinta transportadora. De esta forma, empleando un array 2x8 estático se puede obtener una imagen tridimensional del objeto, ya que los ocho pares de sensores ultrasónicos cubren el ancho de la pieza. La altura es calculada en cada posición

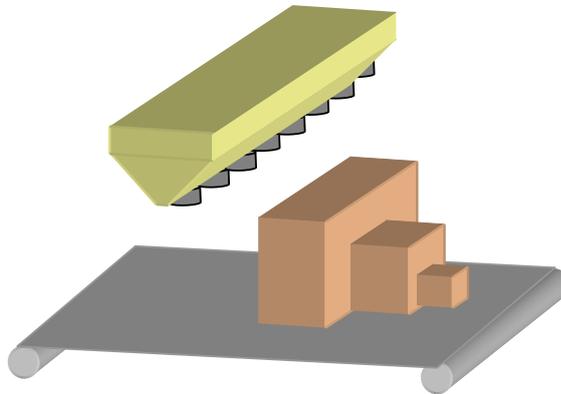


Figura 3.14: Disposición del array y la pieza

mediante la diferencia de distancias medidas desde el array a la base de apoyo del objeto y al objeto en cuestión. La velocidad de movimiento de la cinta transportadora y la frecuencia de muestreo del sistema de adquisición de datos empleado fija la resolución en la dirección del movimiento. Y el número de pares de sensores de que está formado array y la separación entre ellos fija la resolución en la dirección transversal al movimiento.

El proceso consta de dos etapas, una primera etapa de reconstrucción tridimensional del objeto basada en la combinación de la información extraída de los ecos ultrasónicos y una segunda etapa de mejora de la calidad de la reconstrucción. A continuación se presentan cada una de dichas etapas.

En primer lugar se ha construido un sistema fuzzy con la información obtenida de las envolventes de los ecos para reconstruir la imagen tridimensional del objeto utilizando el tiempo de comienzo y el tiempo de máxima amplitud del eco en cada posición.

Cuando las piezas tiene formas con cambios bruscos de pendiente, como por ejemplo piezas formadas por caras planas como la empleada en este caso, si se utiliza únicamente la información de las distancias calculadas en base al tiempo de comienzo del eco la reconstrucción obtenida presenta una forma suavizada en sus bordes, como puede observarse en la figura 3.15, lo cual no permite apreciar claramente la forma real del objeto.

Para su mejora se ha empleado un sistema fuzzy basado en reglas para

añadir la información del tiempo de máxima amplitud y obtener la segunda aproximación de la forma del objeto que se muestra en la figura 3.16. En esta figura se puede observar una reconstrucción mucho menos suavizada, pero todavía con un alto nivel de ruido.

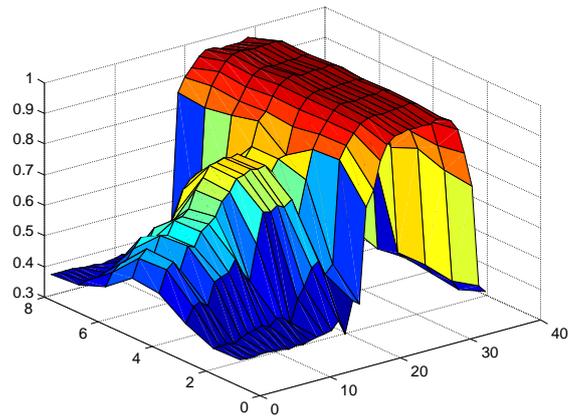


Figura 3.15: Reconstrucción inicial

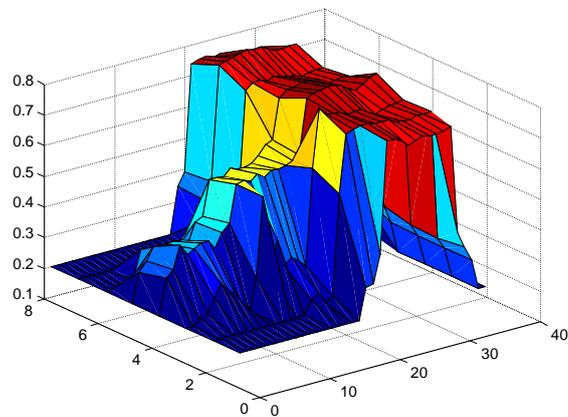


Figura 3.16: Segunda aproximación

A continuación se muestran los pasos seguidos para obtener dicha reconstrucción. En primer lugar se han normalizado los datos de las entradas al sistema fuzzy entre 0 y 1 para que el proceso pueda ser empleado sea cual sea

el tamaño de la pieza. Puede verse en la figura 3.17 las funciones de pertenencia del espacio de la variable de entrada. Puede observarse que dicho espacio ha sido uniformemente dividido en conjuntos fuzzy para cubrir el rango completo de la variable. El número de funciones de pertenencia utilizadas dependerá de la precisión a alcanzar.

El conjunto de reglas del sistema de inferencia empleado para la reconstrucción se muestra en la tabla 3.1, donde se establece la importancia de las dos entradas. En este caso se ha dado mayor peso a la segunda entrada, correspondiente al tiempo de máxima amplitud, que a la primera entrada, correspondiente al tiempo de vuelo.

Los conjuntos fuzzy para la salida, que se muestran en la figura 3.18, son similares en cuanto a distribución, a los conjuntos de entrada.

Una vez que la imagen ha sido reconstruida el siguiente paso es la mejora de dicha imagen para obtener una respuesta más real. En la reconstrucción inicial puede observarse que la resolución obtenida es muy baja. Esto es debido a que en la dirección normal al movimiento del array el número de puntos está limitado al número de pares de sensores de que esté formado dicho array.

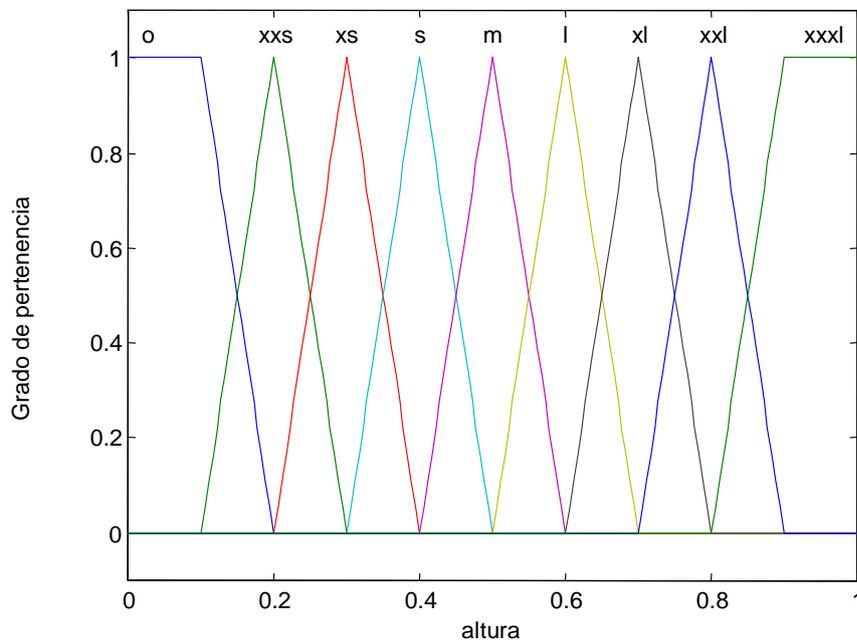


Figura 3.17: Funciones de pertenencia para las entradas

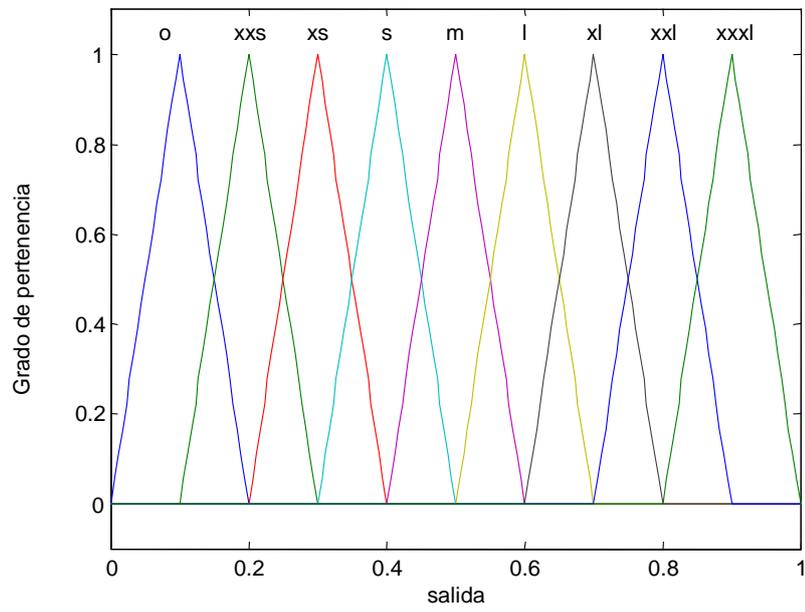


Figura 3.18: Funciones de pertenencia para la salida

$h_b \backslash h_m$	o	xxs	xs	s	m	l	xl	xxl	xxxl
o	o	xxs	xxs	xs	s	s	l	xl	xl
xxs	o	xxs	xs	xs	s	m	m	l	xl
xs	xxs	xxs	xs	s	s	m	l	l	xl
s	xxs	xs	xs	s	m	m	l	xl	xl
m	xxs	xs	s	s	m	l	l	xl	xxl
l	xs	xs	s	m	m	l	xl	xl	xxl
xl	xs	s	s	m	l	l	xl	xxl	xxl
xxl	xs	s	m	m	l	xl	xl	xxl	xxxl
xxxl	s	s	m	l	l	xl	xxl	xxl	xxxl

Tabla 3.1: Conjunto de reglas para reconstrucción

En este caso el array presenta ocho líneas de sensores. Por tanto, se realiza en primer lugar un proceso de interpolación fuzzy para incrementar la resolución de la imagen. De esta forma, para cada coordenada, basándose en los valores anterior y posterior de cada punto, se calcula un nuevo punto intermedio. Se ha empleado un interpolador de segundo orden, de tal forma que a partir de las ocho líneas iniciales de sensores se generan un total de treinta y dos puntos. De esta forma para la imagen utilizada se ha igualado la resolución en la dirección de los dos ejes cartesianos.

Las funciones de pertenencia utilizadas han sido nuevamente las mostradas en las figuras 3.17 y 3.18, y el conjunto de reglas empleado puede verse en la tabla 3.2. El resultado final de la interpolación de la pieza puede verse en la figura 3.19.

$h_b \backslash h_m$	o	xxs	xs	s	m	l	xl	xxl	xxxl
o	o	xxs	xxs	xs	xs	s	s	m	m
xxs	xxs	xxs	xs	xs	s	s	m	m	l
xs	xxs	xs	xs	s	s	m	m	l	l
s	xs	xs	s	s	m	m	l	l	xl
m	xs	s	s	m	m	l	l	xl	xl
l	s	s	m	m	l	l	xl	xl	xxl
xl	s	m	m	l	l	xl	xl	xxl	xxl
xxl	m	m	l	l	xl	xl	xxl	xxl	xxxl
xxxl	m	l	l	xl	xl	xxl	xxl	xxxl	xxxl

Tabla 3.2: Conjunto de reglas para la interpolación

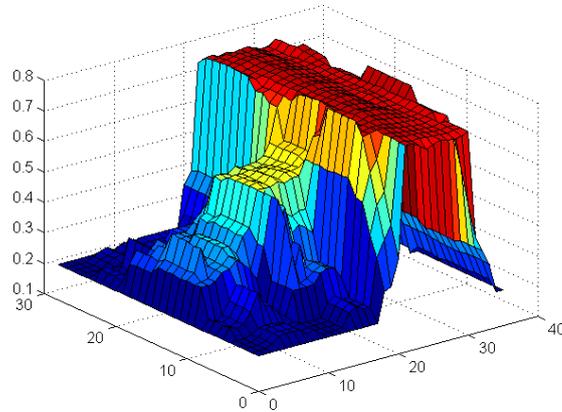


Figura 3.19: Pieza después de la interpolación

El último paso propuesto para la mejora es la reducción del ruido de la imagen para obtener una superficie más homogénea. En este caso para cada coordenada de la imagen se ha tenido en cuenta la información de sus ocho vecinos circundantes como se muestra en la figura 3.20.

Para realizar el proceso de reducción del ruido en primer lugar se calcula, para cada punto, la desviación en altura  $\Delta h_i$  respecto a sus ocho vecinos:

$$\Delta h_i = h_i - h_{pto} \quad (3.18)$$

donde:

$h_i$  es la altura del vecino  $i$

$h_{pto}$  es la altura del punto en análisis

Se va incrementando la variable *incremento positivo* (I+) para las desviaciones  $\Delta h_i$  positivas y la variable *incremento negativo* (I-) para las desviaciones  $\Delta h_i$  negativas.

En segundo lugar se definen las funciones de pertenencia para las variables de entrada *incremento positivo* (I+) e *incremento negativo* (I-) y para la variable de salida según se muestra en la figura 3.21 y se aplica la tabla de reglas 3.3 que lleva a modificar la altura de cada punto con la idea de obtener una superficie más homogénea.

1	2	3
4		5
6	7	8

Figura 3.20: Los ocho vecinos de cada punto de la imagen

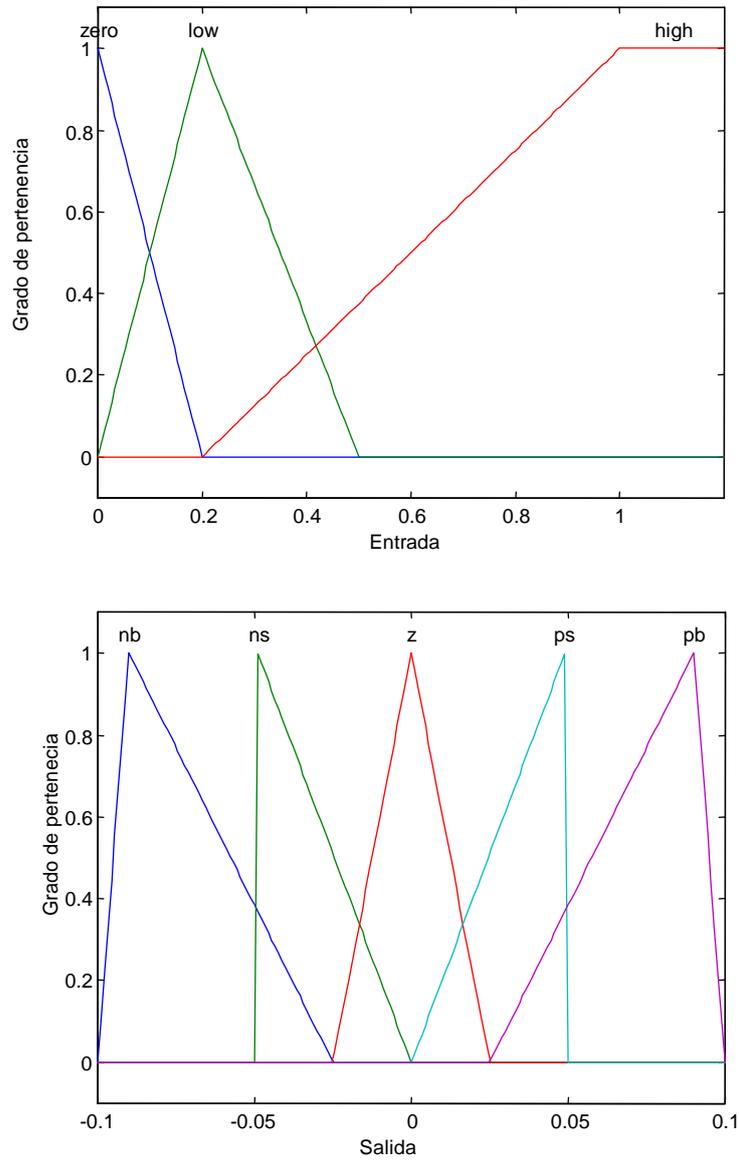


Figura 3.21: Funciones de pertenencia para la reducción del ruido

I+\I-	zero	low	high
zero	z	ns	nb
low	ps	z	ns
high	pb	ps	z

Tabla 3.3: Conjunto de reglas para la reducción del ruido

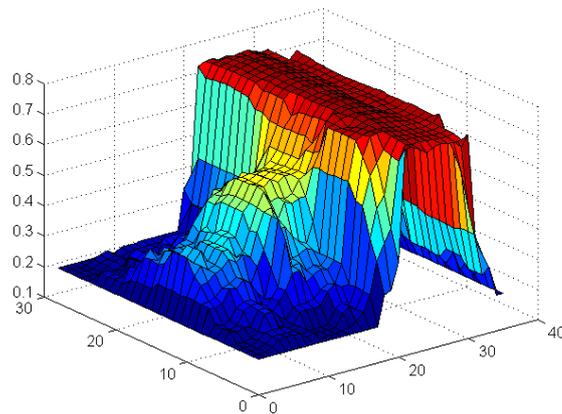


Figura 3.22: Reducción del ruido de la pieza

Cuando la reducción del ruido se aplica sobre los puntos del borde de la pieza, provoca nuevamente un suavizado de las aristas de la pieza. Para evitar ese efecto puede incluirse una nueva etapa de realce de bordes, empleando únicamente los vecinos que corresponden a la dirección del borde. En este caso el conjunto de reglas llevará a incrementar la pendiente cuando esta ya es grande, y a disminuirla aún más cuando es pequeña. Puede verse su resultado sobre la pieza analizada en la imagen 3.23.

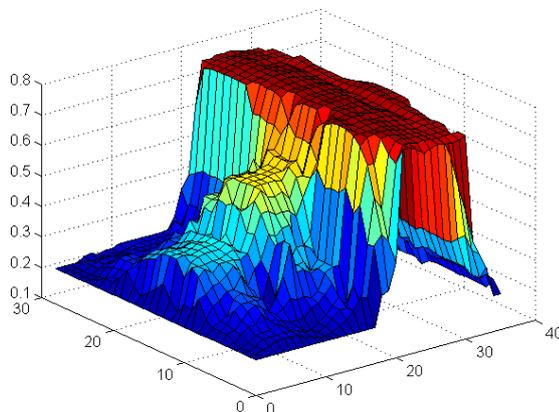


Figura 3.23: Reconstrucción final

#### 3.3.4. Suavizado y realzado de la imagen 3D mediante la técnica de agrupamiento fuzzy c-means.

Para el mismo objeto del apartado anterior mostrado en la figura se emplea ahora un algoritmo de agrupamiento para extraer características de la imagen y mejorar la reconstrucción tridimensional de la misma.

Se pretende también en este caso reconstruir y mejorar la imagen obtenida mediante el array lineal situado sobre piezas en movimiento [26]. En la figura 3.14 puede observarse la forma y disposición respecto al array de la pieza utilizada en este caso.

En esta aplicación se parte de la imagen obtenida después de haber empleado el sistema fuzzy basado en reglas del apartado anterior para añadir la información del tiempo de máxima amplitud y obtener la segunda aproximación de la forma del objeto que se muestra en la figura 3.24.

Para poder aplicar el método de agrupamiento fuzzy c-means en primer lugar es necesario ordenar los datos de partida, escalarlos y determinar el número de grupos para el agrupamiento.

Las coordenadas  $x$ ,  $y$  y  $z$  representan cada dato obtenido del objeto. En este caso se tienen en el eje  $x$  representados los 8 sensores, en el eje  $y$  los 36

puntos de toma de datos considerados durante el desplazamiento de la pieza, lo que da un total de 288 posiciones en el plano  $xy$ . Añadiendo la información de la altura se tiene una matriz de datos de dimensiones  $288 \times 3$ .

La técnica de agrupamiento particionará este conjunto de datos en varios grupos de tal forma que la similitud dentro del grupo sea mayor que entre grupos. Para poder realizar ésto se requiere emplear medidas de similitud que van evaluando los datos dos a dos y que son sensibles a los rangos en que varían las señales de entrada, por lo que dichos datos han de ser escalados en primer lugar. Los datos adecuadamente escalados y proyectados sobre los planos ortogonales se muestran en la figura 3.25.

Después del escalado de los datos y antes de aplicar las técnicas de agrupamiento o clustering es necesario eliminar aquellos datos que representan el suelo sobre el que está apoyado la pieza, puesto que estos datos no ofrecen información sobre la forma de la pieza, sino que podrían confundir y ralentizar el clustering. Se muestra en la figura 3.26 los datos una vez eliminados aquellos que corresponden al suelo.

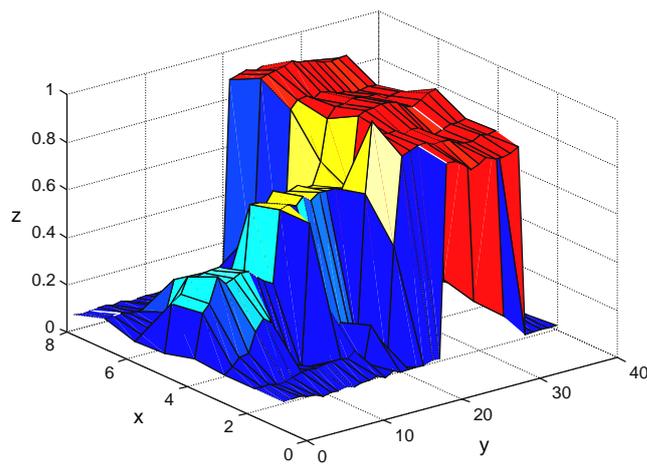


Figura 3.24: Imagen de partida

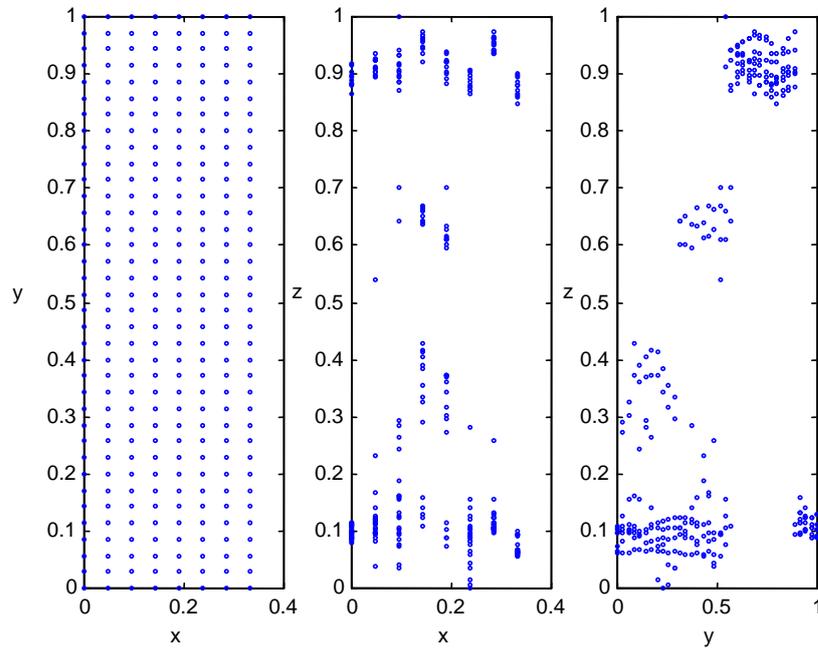


Figura 3.25: Proyecciones de los datos escalados

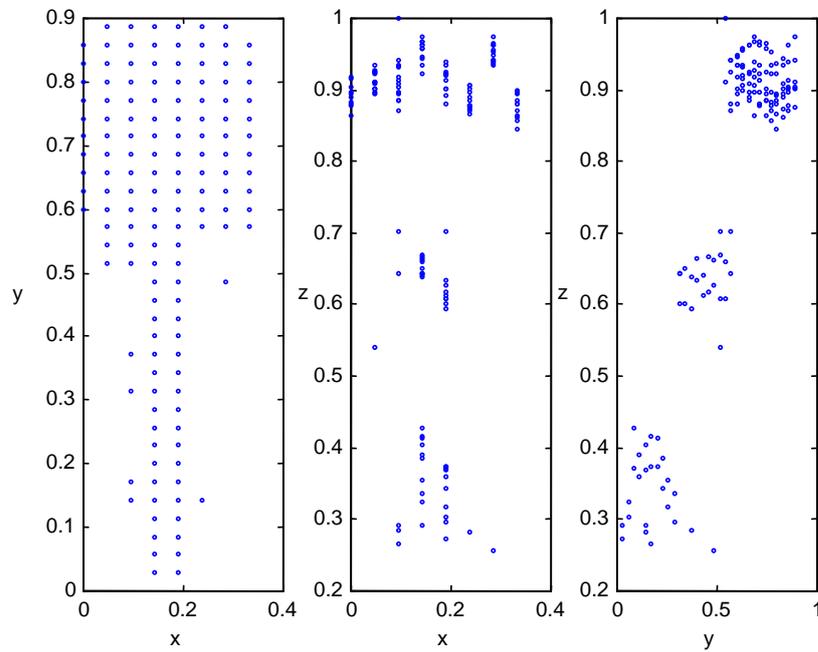


Figura 3.26: Proyecciones de los datos escalados sin puntos del suelo

Previamente a la aplicación del algoritmo de agrupamiento es necesario determinar el número de clases que se desean encontrar. Esta tarea se realizará aplicando el algoritmo de la distancia encadenada que, considerando los datos como vectores, se resume en los siguientes pasos:

1. Seleccionar aleatoriamente un vector entre todos los datos y colocarlo como el primer elemento de una lista.
2. De los restantes datos, seleccionar el elemento más próximo al previamente añadido. Este se convierte en el nuevo vector. Repetir el paso 2 hasta que todos los vectores de datos estén en la lista.
3. Calcular las distancias euclídeas entre elementos consecutivos en la lista.
4. Representar gráficamente las distancias y definir un umbral de tal forma que las distancias que lo superen indiquen la presencia de un nuevo grupo.

La precisión del algoritmo depende del umbral seleccionado, la distancia entre los datos y el vector inicial seleccionado. En la figura 3.27 puede verse la representación gráfica de las distancias, donde puede observarse por los cambios de distancias que hay tres grupos claramente identificados.

Una vez definidos el número de grupos a formar, el algoritmo de agrupamiento fuzzy c-means agrupará los datos en esas clases y determinará un centro representativo para cada una de ellas. Dicho algoritmo ha requerido once iteraciones para realizar el agrupamiento y ha agrupado correctamente en el 97 % de los datos. Al ser una técnica de agrupamiento fuzzy, la pertenencia de los puntos a un determinado grupo no es estrictamente 0 o 1, sino que puede ser cualquier valor entre 0 y 1 lo cual puede interpretarse como la probabilidad de cada punto de pertenecer al grupo.

Después de aplicar el método de agrupamiento y tomando el máximo grado de pertenencia de cada punto, estos son añadidos a los diferentes grupos, representados cada uno de ellos por los tres centros encontrados. Los resultados pueden verse en la figura 3.28.

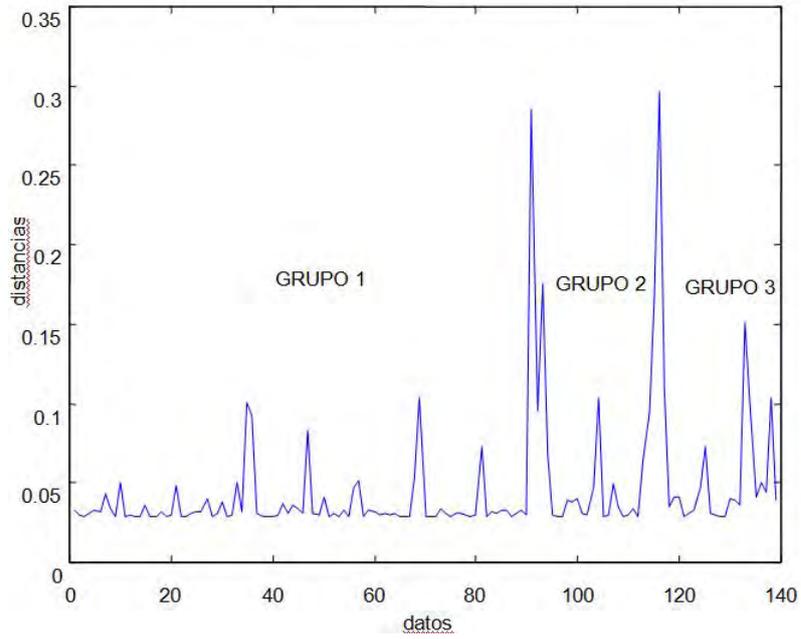


Figura 3.27: Distancias entre pares de datos más próximos

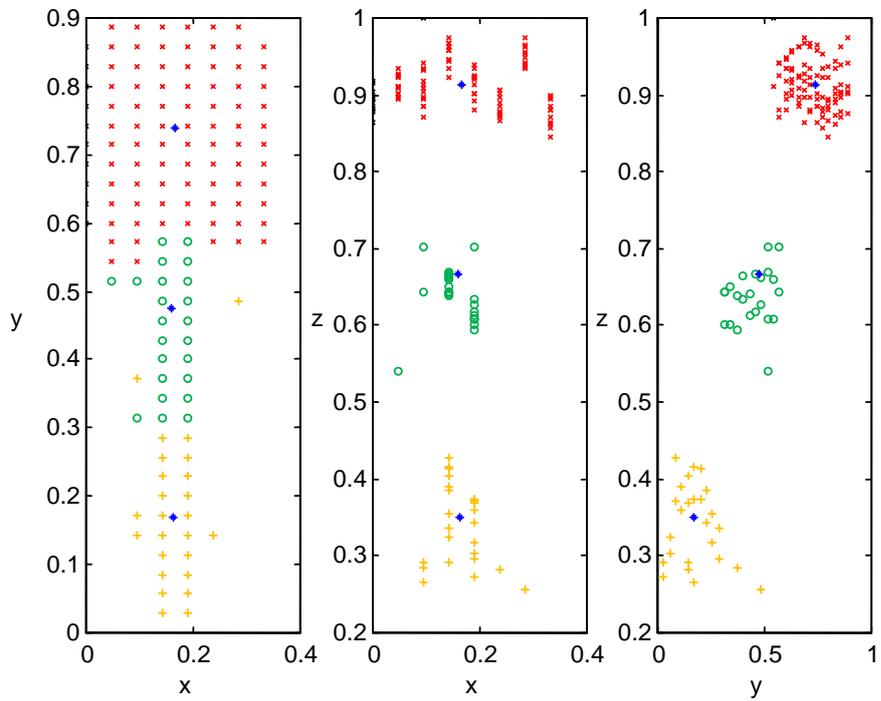


Figura 3.28: Agrupamientos obtenidos y sus centros

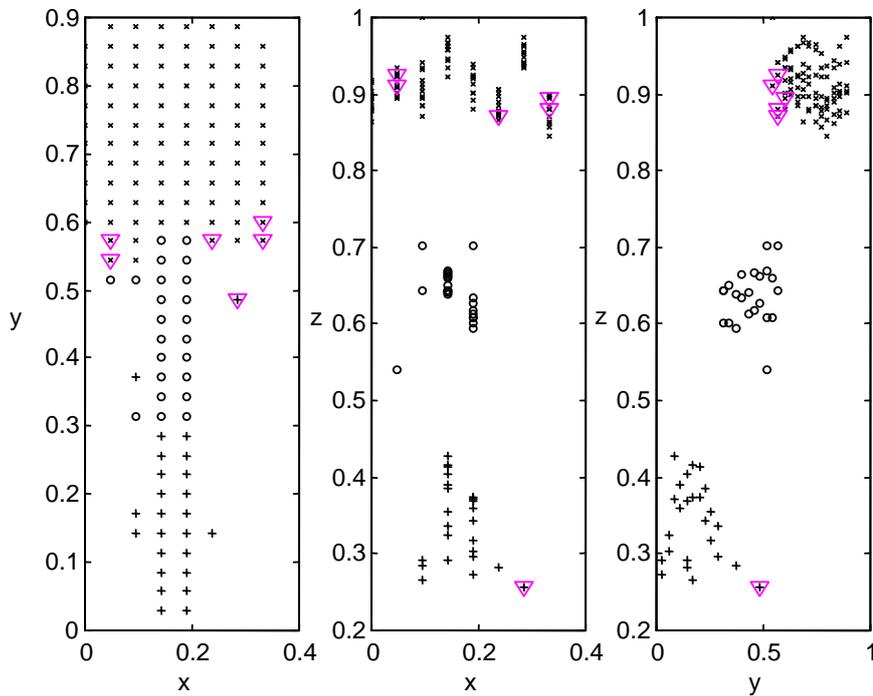


Figura 3.29: Puntos que no pertenecen claramente a ningún grupo

En la figura 3.29 pueden verse marcados con  $\nabla$  los puntos cuyo máximo valor de pertenencia a un grupo está por debajo de 0.65. Estos puntos no se pueden considerar pertenecientes a ningún grupo donde los demás puntos pertenecen con valores en el entorno de 0.9.

Ahora tomando la posición de los centros encontrados por el algoritmo de agrupamiento como el punto más representativo del grupo, su coordenada  $z$  se establece como altura del grupo libre de ruido. Así dicho valor se adopta como coordenada  $z$  para todos los puntos del grupo, con lo que permite simultáneamente reducir el ruido de la imagen y realizar una mejora de la reconstrucción. Para que la reconstrucción quede completa se recuperan los puntos del suelo también empleando para ellos su valor medio. La figura 3.30 muestra las proyecciones de las posiciones finales de todos los datos, incluidos los del suelo. Y en la figura 3.31 se muestra la imagen 3D reconstruida.

El estudio muestra la efectividad de las técnicas de agrupamiento fuzzy aplicadas al reconocimiento de patrones, que ha sido utilizado para la reducción

de ruido y la mejora en la reconstrucción tridimensional obtenida a partir de sensores de ultrasonidos.

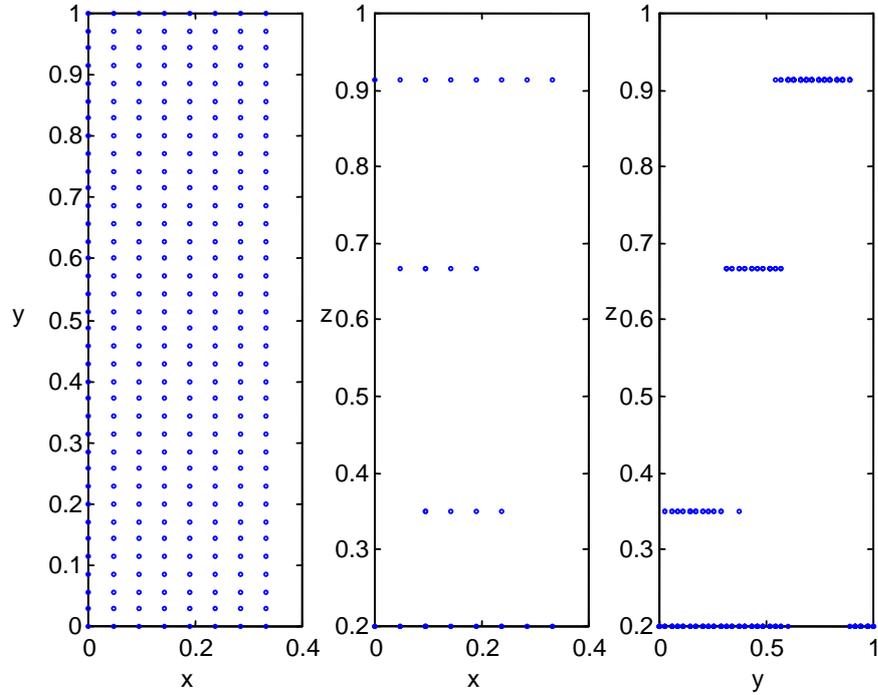


Figura 3.30: Proyecciones de las posiciones finales de los puntos

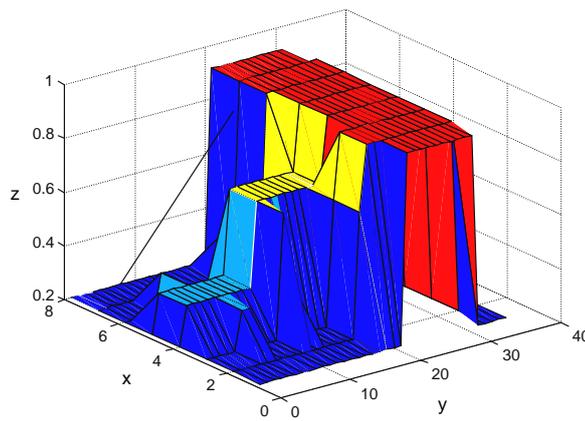


Figura 3.31: Imagen final reconstruida

## **3.4. Resumen y conclusiones del capítulo**

Se ha presentado en este capítulo los sistemas difusos como método de mejora de la imagen tridimensional reconstruida a a partir de la información proveniente de sensores de ultrasonidos.

En primer lugar se ha realizado una introducción a los sistemas difusos, indicando las diferencias entre los conjuntos clásicos y los conjuntos difusos, la estructura de un sistema difuso, los sistemas difusos de tipo Sugeno y la técnica de clusterizado fuzzy c-means.

A continuación se han propuesto una serie de métodos de mejora de la reconstrucción de imágenes tridimensionales basadas en ultrasonidos.

En el primer caso se ha propuesto la mejora de la reconstrucción de la imagen mediante un método de suavizado y realzado de la imagen empleando conjuntos difusos y la información del tiempo de amplitud máxima.

En el segundo caso se ha propuesto la mejora de la imagen realizando la reconstrucción mediante un sistema difuso basado en el tiempo de vuelo y amplitud máxima.

Y en el tercer caso se propone la mejora de la reconstrucción de la imagen mediante el empleo de técnicas de agrupamiento difuso.

Como conclusión puede verse que es posible emplear las técnicas fuzzy para eliminar el ruido y realzar las imágenes tridimensionales ultrasónicas. Los resultados obtenidos han sido adecuados para el tipo de piezas que se han utilizado. Pero cabe decir que estos métodos de suavizado y realzado están muy influenciados por la forma de la pieza. Los casos planteados han sido para la mejora de la reconstrucción de piezas que presentan superficies planas ortogonales y no sería extrapolable a cualquier tipo de pieza.

Por tanto se muestra que el proceso de mejora de las reconstrucciones es demasiado dependiente del caso y sería necesario establecer un conjunto de algoritmos más generalizado.

## Capítulo 4

# Caracterización de la respuesta temporal de los sensores

### 4.1. Introducción

Se plantea en este capítulo obtener un modelo de las respuestas transitorias que se producen en la transmisión de las ondas ultrasónicas cuando los sensores de ultrasonidos son excitados por señales de tipo pulso, y así conocer la forma de los ecos en mayor profundidad. La tecnología de fabricación empleada, el método de integración de los componentes y el encapsulado empleado, afecta a la forma final que la señal ultrasónica va a presentar. Es interesante por tanto poder obtener un modelo real de la señal para los sensores utilizados en vez de quedarse con la aproximación general de la respuesta para el pistón plano. Obtener un modelo más real permitirá posteriormente realizar análisis más completos de los ecos recibidos.

En este capítulo se realiza la caracterización del sensor de ultrasonidos que se va a utilizar en los posteriores desarrollos experimentales. Así, este análisis va a permitir ajustar mejor los modelos de propagación y reflexión que se van a plantear en el siguiente capítulo, para hacerlos coincidir con los sensores que se emplean realmente en la experimentación.

Se pretende analizar la respuesta temporal que presentan los transductores de ultrasonidos piezoeléctricos del fabricante SensComp (Grupo Polaroid) que

van a ser los empleados en la experimentación, con referencias del fabricante 40LT16 (emisor) y 40LR16 (receptor). Las características generales que ofrece el fabricante para estos transductores pueden verse en la tabla 1.2.

## 4.2. Obtención del patrón de radiación.

Se considera el transductor de ultrasonidos como un pistón circular plano de radio  $a$  que vibra con movimiento armónico simple con una velocidad uniforme  $U_0 e^{j\omega t}$  normal a la superficie. Según [33] la presión a lo largo del eje normal a la superficie del pistón para distancias  $r$  tales que se cumpla la relación  $\frac{r}{a} \gg ka$ , donde  $k$  es el número de onda, viene dada por 4.1. Es decir, en puntos del campo muy lejanos comparando tanto con el radio  $a$  del pistón como con la longitud de onda  $\lambda$ , tiene la forma:

$$P(r) = \frac{1}{2} \rho_0 c U_0 \frac{a}{r} ka \quad (4.1)$$

Es decir, a partir de una distancia mayor que  $r_1$  la presión presenta un comportamiento decreciente y con tendencia asintótica del tipo  $1/r$ . La distancia  $r_1$  marca la frontera entre el complicado campo cercano y el más simple campo lejano. La distancia  $r_1$  corresponde al primer máximo local de la presión axial, para lo cual se cumple que:

$$\frac{r_1}{a} = \frac{a}{\lambda} - \frac{1}{4} \frac{\lambda}{a} \quad (4.2)$$

Esta distancia  $r_1$  sólo tiene significado si la relación  $\frac{a}{\lambda}$  es lo suficientemente grande para que  $r_1$  sea positivo. Para analizar la presión fuera del eje normal al pistón, en cualquier punto de coordenadas  $(r, \vartheta)$  dentro del campo lejano ( $r \gg a$ ) se empleará la expresión:

$$p(r, \theta, t) = j \frac{\rho_0 c}{2} U_0 \frac{a}{r} ka e^{j(\omega t - kr)} \left[ \frac{2J_1(ka \sin \theta)}{ka \sin \theta} \right] \quad (4.3)$$

Por tanto el factor direccional vendrá dado por:

$$H(\theta) = \frac{2J_1(ka \sin \theta)}{ka \sin \theta} \quad (4.4)$$



Figura 4.1: Micrófono Brüel Kjær Type 4939

Este factor direccional variará con la frecuencia del sensor, la forma de la pantalla vibrante y el encapsulado. Ya se mostró en la figura 1.12 la representación el patrón de radiación típico dado por el fabricante para los transductores que van a ser analizados, donde puede observarse la forma y los lóbulos secundarios existentes.

Se ha realizado un ensayo en el laboratorio para obtener el patrón de radiación real de los transductores empleados en la experimentación. Para ello se ha empleado un micrófono del fabricante Brüel Kjær omnidireccional modelo Free-Field 1/4" Microphone Type 4939, ver figura 4.1, que trabaja dentro del rango de frecuencias del sensor de ultrasonidos analizado. Los resultados obtenidos pueden verse en la figura 4.2 a). Esta figura muestra la presión sonora recibida en el micrófono (expresada en voltios) para un barrido de posiciones angulares que van desde  $-90^{\circ}$  a  $+90^{\circ}$  respecto del eje del micrófono, considerando distancias de 15, 20, 25 y 30 cm (azul:15cm, rojo:20cm, cian:25cm, verde: 30cm). Estos patrones dan información de la forma del lóbulo de radiación real de los sensores así como de la atenuación que se produce debido al medio de transmisión en que se propagan las ondas. Pueden verse dichos patrones normalizados en la figura 4.2 b), así como la atenuación de la señal con el ángulo de incidencia (en dB) en la figura 4.3 a). La figura 4.3 b) muestra su representación en coordenadas polares como suele mostrarse en la hoja de características del fabricante.

Para simplificar el análisis se propone aproximar el perfil del haz mediante una función gaussiana obteniéndose así la amplitud del eco como función del ángulo de incidencia  $\theta$  del haz ultrasónico sobre la superficie del objeto:

$$A(\theta) = A_0 e^{-\frac{\theta^2}{2\sigma^2}} \quad (4.5)$$

donde  $A_0$  es la amplitud en el eje del sensor y  $\sigma$  es la medida del ancho del haz. Esta aproximación sólo es razonable para la zona central del lóbulo principal donde se producen ecos de tamaño detectable.

Empleando esta expresión se ajusta ahora de forma experimental el factor direccional y el patrón de emisión para los sensores SensComp 40LT16/40LR16 empleados en la experimentación:

$$H(\theta) = e^{-0,00085\theta^2} \quad (4.6)$$

En cuanto al factor de atenuación con la distancia para el campo lejano se comprueba experimentalmente que depende inversamente de la distancia  $r$  que separa el emisor del punto receptor. La expresión anterior se puede completar con dicho término quedando:

$$A(r, \theta) = \frac{K_1}{r} e^{-0,00085\theta^2} \quad (4.7)$$

donde  $K_1$  es una constante proporcional a la amplitud máxima de la señal de excitación.

En la figura 4.4a) se han representado conjuntamente los datos experimentales sin normalizar para las diferentes distancias analizadas (azul:15cm, rojo:20cm, cian:25cm, verde: 30cm) junto con la representación del factor direccional calculado mediante la aproximación por una campara de Gauss simple, en color negro, siguiendo la expresión 4.7. Puede comprobándose la similitud de los datos experimentales con los obtenidos de la expresión 4.7 una vez que se ha ajustado la constante  $K_1$  para la amplitud de la señal utilizada.

En la figura 4.4b) se han representado conjuntamente los datos experimentales anteriores normalizados junto con la representación del factor direccional teórico  $H(\theta)$ , en color magenta, calculado mediante la expresión 4.4, y una aproximación mediante una campara de Gauss simple, en color negro, según la expresión 4.6. Puede verse cómo los datos teóricos se aproximan muy bien a los experimentales para el rango de los  $-50^{\circ}$  a los  $50^{\circ}$ . También puede verse que para ese rango la aproximación mediante la campara de Gauss es también una buena solución, evitando la complejidad de cálculo de las funciones de Bessel de primera clase.

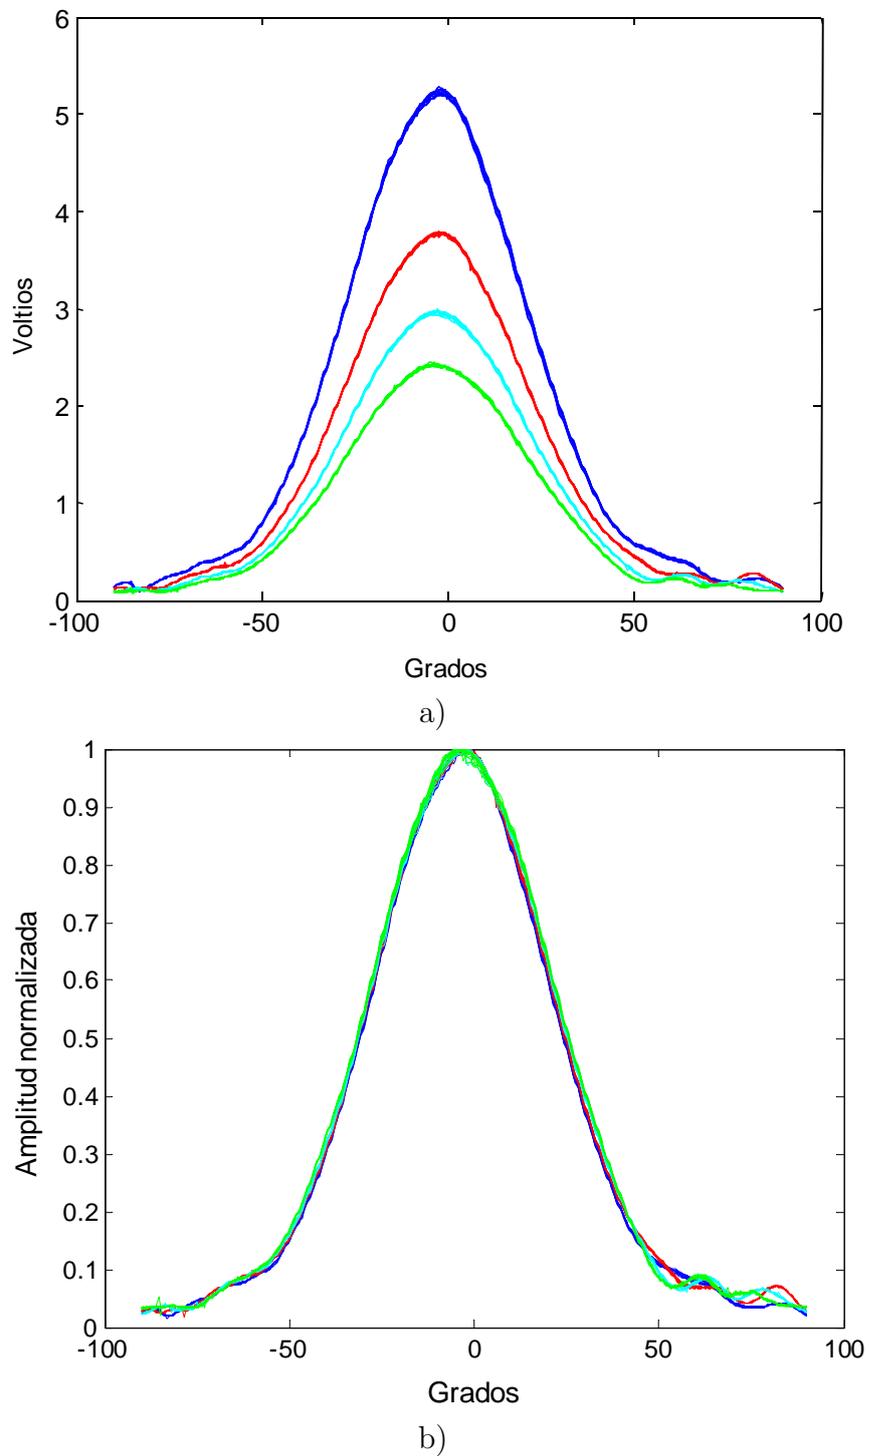
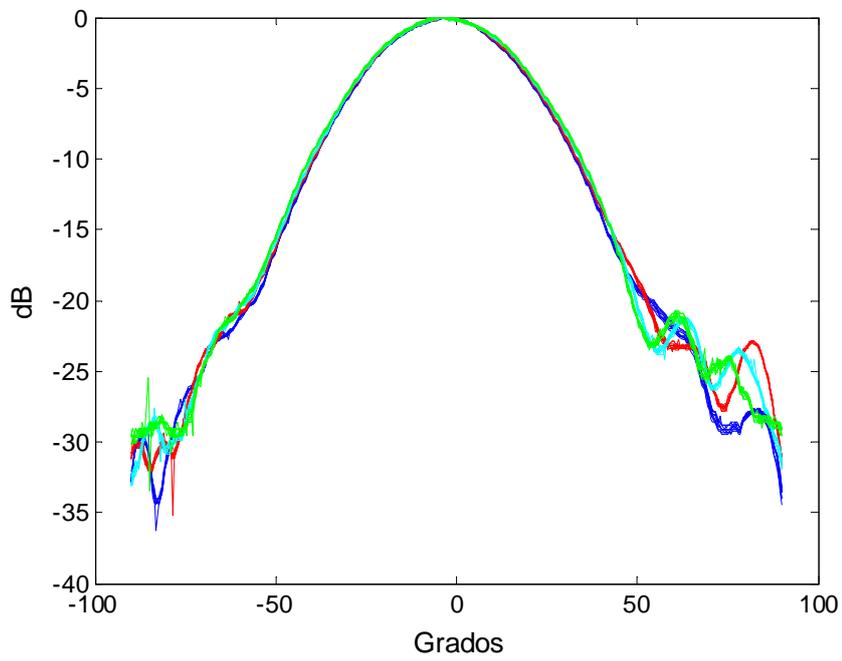
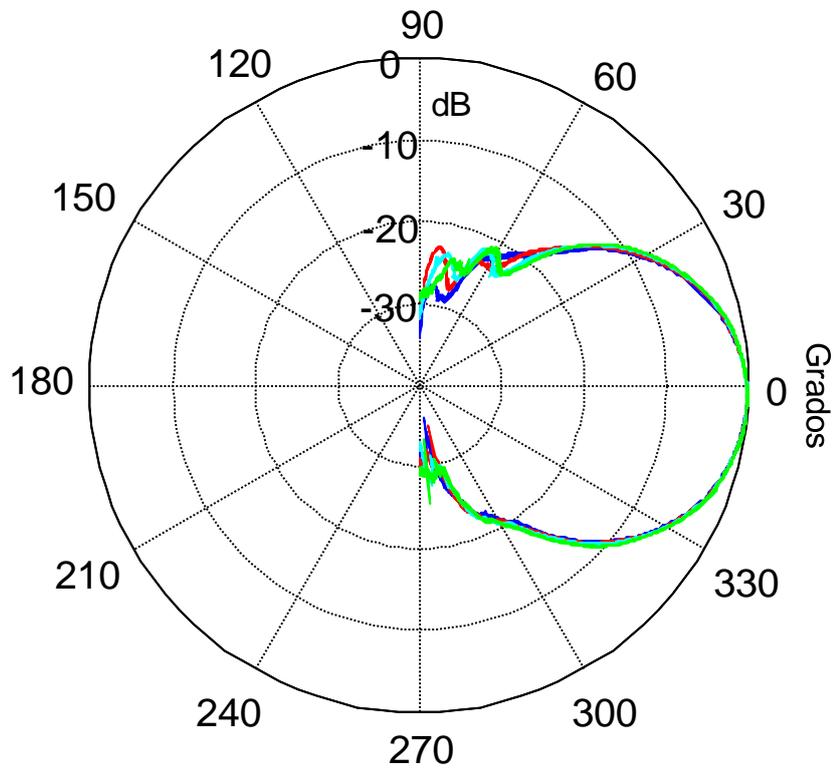


Figura 4.2: Patrón de radiación de los sensores SensComp 40LT16/40LR16 obtenido para distancias a la fuente de 15, 20, 25, 30cm a) directo, b)normalizado.



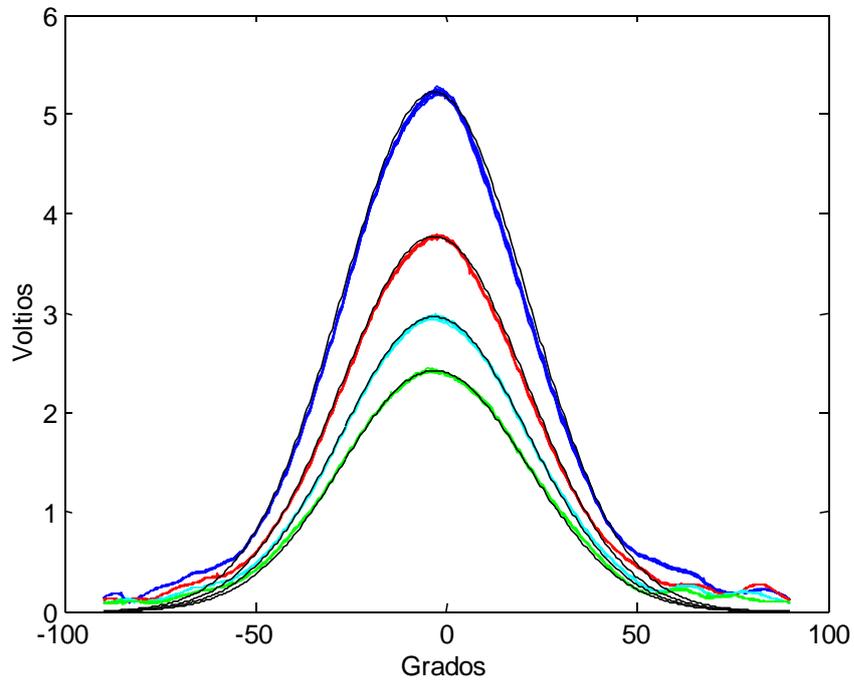
a)



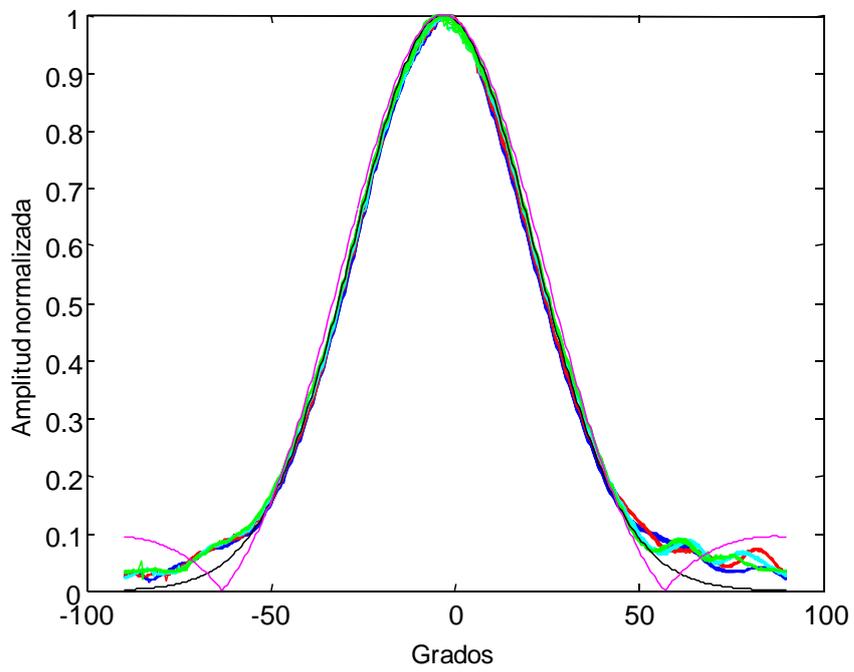
b)

Figura 4.3: Patrón de radiación en dB a) en coordenadas cartesianas, b) en coordenadas polares.

---



a)



b)

Figura 4.4: Patrón de radiación experimental frente a teórico a) directo para las distancias de 15, 20, 25 y 30 cm, b) normalizado

### 4.3. Relación entre número de ciclos de la señal de excitación y del eco obtenido.

A continuación se pretende analizar cómo responden los transductores de ultrasonidos empleados en la experimentación ante señales de entrada de diferente duración para encontrar un modelo de respuesta temporal tanto del eco generado y transmitido a través del aire por el sensor emisor como del eco recibido en el sensor receptor.

Para ello se ha experimentado con un par de sensores en configuración emisor-receptor empleando diferentes señales de excitación en forma de pulso, ya que éste va a ser el método de excitación de los sensores en la técnica pulso-eco.

Las señales de excitación utilizadas han sido pulsos formados por una serie de ciclos de una señal sinusoidal a la frecuencia de excitación del sensor empleado, en este caso a 40KHz. Se realizó un barrido experimental de la respuesta del sensor para pulsos que van desde una duración de un ciclo hasta cien ciclos.

En principio se pensó realizar la captura de la señal ultrasónica emitida por el sensor mediante el micrófono del fabricante Brüel & Kjær modelo Free-Field 1/4" Microphone Type 4939 anteriormente empleado. De esta forma se logra modelar únicamente la dinámica de funcionamiento del sensor emisor.

Pero debido a que la aplicación directa del estudio del transitorio del eco emitido y recibido por un sensor de ultrasonidos es para su empleo en la simulación de las señales recibidas en un entorno de navegación autónoma se ha modificado el procedimiento para que resulte más útil en esta aplicación.

De esta forma se va a intentar que las condiciones de simulación sean lo más parecidas posibles a las empleadas en la experimentación real, por lo que se ha tenido en cuenta las siguientes consideraciones:

En primer lugar en la experimentación se emplea como emisor el sensor SensComp 40LT16 y como receptor el sensor 40LR16, siendo por tanto, aunque de la misma gama y fabricante, diferentes sensores con posibles diferencias en sus respuestas dinámicas.

En segundo lugar, si se plantea obtener únicamente el modelo para el sensor emisor mediante la toma de datos con el micrófono, se debería también obtener el modelo del sensor receptor de forma independiente. Para el modelo del receptor también sería necesario generar un pulso ideal de la señal ultrasónica que viajara por el aire y fuera capturado por dicho sensor receptor. Con los equipos de experimentación de que se disponen esto no es posible, ya que la generación de la señal ultrasónica se realiza mediante los sensores de ultrasonidos de tipo emisor, por lo que dicha señal estará afectada ya por la dinámica de dicho emisor siendo imposible generar un pulso ultrasónico ideal.

En tercer lugar los sensores van a utilizarse en la experimentación siempre mediante la técnica pulso-eco, emparejando un emisor a un receptor, por lo que parece ser más conveniente obtener el modelo dinámico conjunto de los sensores ante este tipo de entradas para facilitar la tarea de simulación.

Por tanto ante la problemática de analizar por separado la dinámica del emisor y receptor, y puesto que su uso siempre va a ir emparejado en las aplicaciones reales, se ha optado por modelar el comportamiento del par emisor-receptor conjuntamente. En estas condiciones se han realizado los ensayos en primer lugar enfrentando emisor y receptor, y en segundo lugar considerando el rebote sobre una pared lisa.

Se ha realizado una batería de ensayos cubriendo una amplia variedad de situaciones. Se genera una señal de excitación de tipo pulso, similar a la que se va a emplear en su funcionamiento normal y se analiza la respuesta para pulsos de duración variable, que van desde un pulso de un ciclo hasta pulsos de cien ciclos, asegurándose así, llegar hasta la situación de excitación continua del sensor.

También se ha considerado utilizar pulsos de diferente amplitud para cada uno de los casos anteriores para comprobar la linealidad del sensor y situar los sensores a diferentes distancias y con diferentes inclinaciones para tener en cuenta también el efecto de la atenuación de la señal con la distancia y el efecto del lóbulo de radiación del sensor utilizado.

Las situaciones planteadas para el análisis experimental y sus respuestas se puede ver en las figuras 4.5 y 4.6 donde se ha representado la relación que existe entre el número de ciclos de la señal de excitación y el ciclo en el que

se produce el máximo del eco en la recepción. La figura 4.5a) muestra el caso de emisor y receptor enfrentados en línea con una separación de 40 cm entre ellos. La figura 4.5b) muestra el caso de rebote directo sobre una pared lisa estando emisor y el receptor totalmente enfrentados a la pared y separados 3 cm entre sí. La figura 4.6a) muestra el caso de rebote sobre una pared con 10 grados de inclinación respecto al par emisor-receptor. Y la figura 4.6b) muestra el caso de rebote sobre una pared con 20 grados de inclinación respecto al par emisor-receptor.

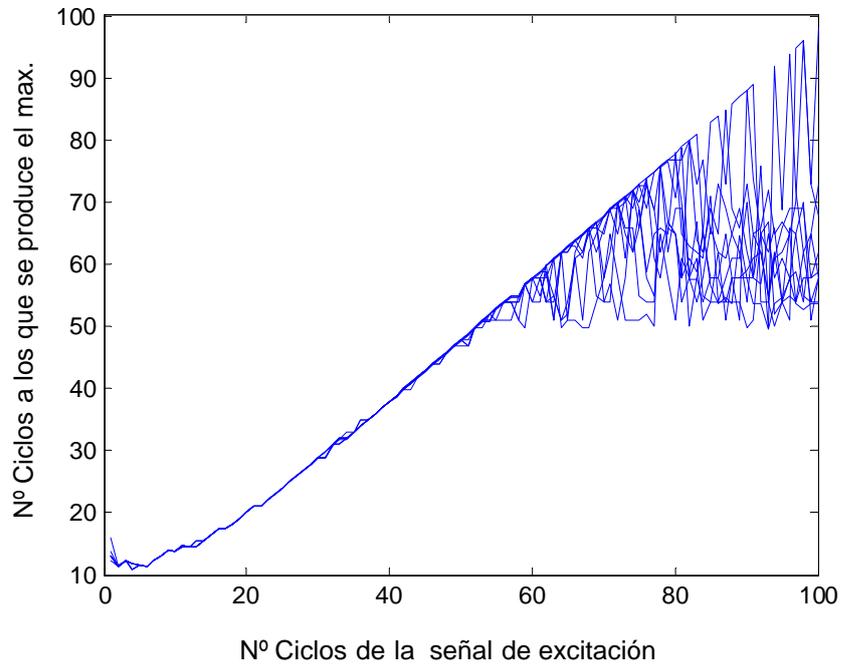
Se observa que con pulsos de menor duración de 5 ciclos la potencia de la señal transmitida es muy reducida generándose ecos muy débiles de difícil análisis.

Puede verse en las figuras 4.5 y 4.6 que existe una relación prácticamente lineal entre el número de ciclos de la señal de excitación y el número de ciclo en el que se produce el máximo en el eco siempre que no se superen los sesenta ciclos de duración de la señal de excitación. Esto ocurre en los cuatro casos analizados, es decir, tanto en la recepción directa del eco, como en el rebote sobre superficies con diferente inclinación. Esto ocurre porque para pulsos de la señal de entrada entre 6 y 50 ciclos el sensor de ultrasonidos trabaja sin llegar a la saturación, de tal forma que cuando termina el pulso de excitación en sensor no ha alcanzado el valor máximo de presión que puede generar y vuelve a disminuir hasta llegar a cero.

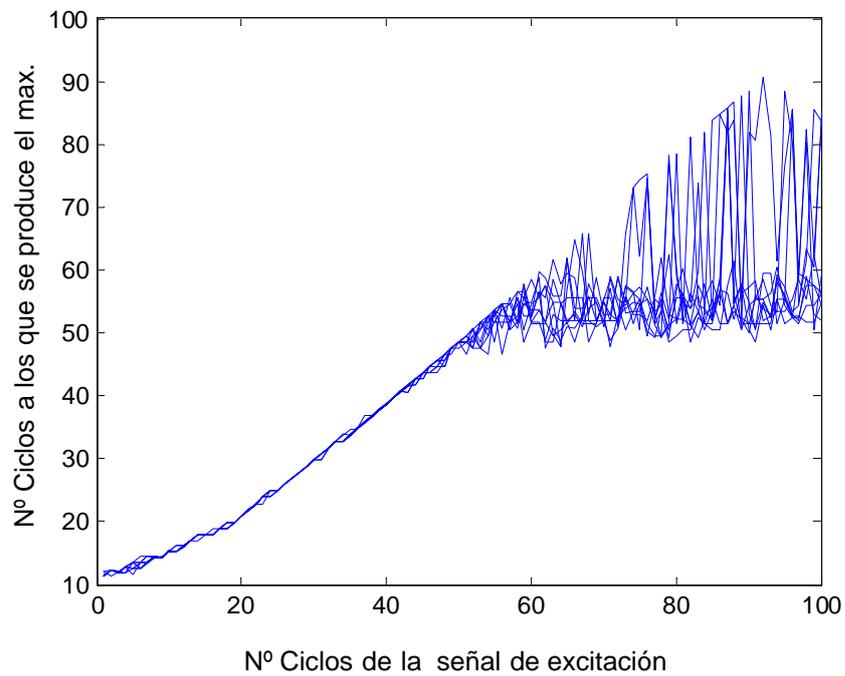
A partir de 50 ciclos se pierde esta relación porque para ese número de ciclos el sensor sí ha llegado a la saturación, la onda ultrasónica ya no puede crecer más en amplitud y por tanto la señal de respuesta se estabiliza a ese valor máximo. Es decir, la respuesta se ha convertido en una señal sinusoidal estacionaria. La dispersión de valores de ciclos a los que se produce el máximo que puede observarse en la curva a partir de los 50 ciclos de señal de excitación es debido a que la amplitud una vez que se ha saturado el sensor no exactamente constante sino que presenta algunas variaciones debido a las perturbaciones. Esto hace que el máximo en cada experimento coincida en un punto distinto.

Toda esta información va a ser de gran interés a la hora de modelar el transitorio del eco puesto que va a ser uno de los parámetros de dicho modelo y marcará la duración real del transitorio del eco.

4.3. Relación entre número de ciclos de la señal de excitación y del eco obtenido.

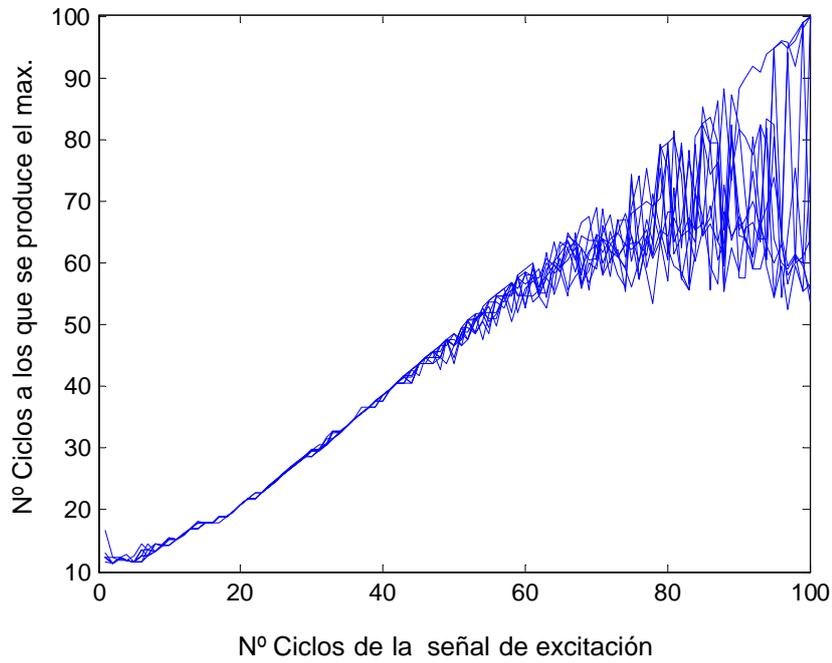


a)

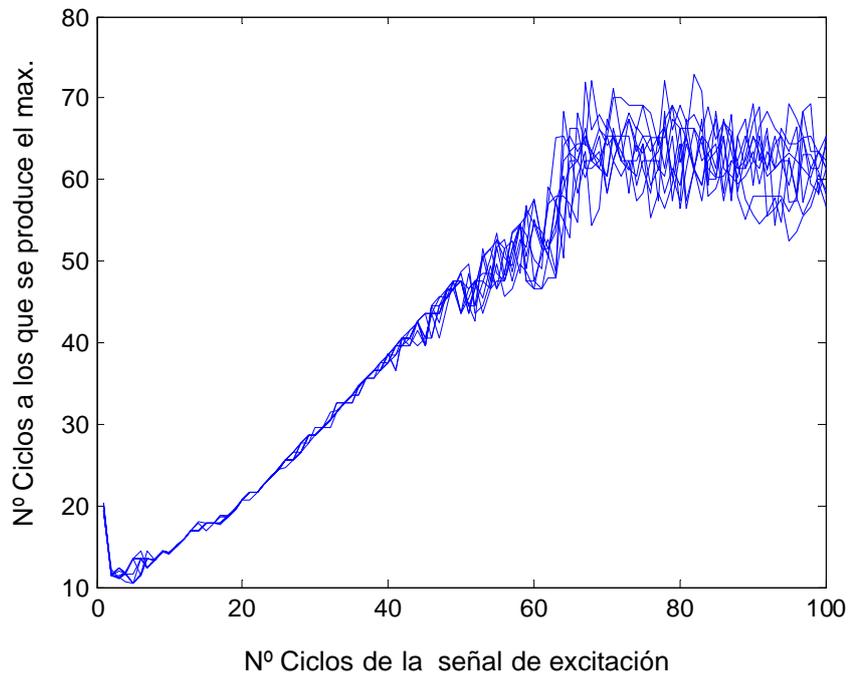


b)

Figura 4.5: Ciclos de señal de excitación frente a ciclos a los que se produce el máximo a) en el eco en recepción directa, b) en rebote sobre pared plana con 0° de inclinación.



a)



b)

Figura 4.6: Ciclos de señal de excitación frente a ciclos a los que se produce el máximo en el eco en rebote sobre pared plana con a)  $10^\circ$  de inclinación, b)  $20^\circ$  de inclinación.

## 4.4. Aproximación de la envolvente para pulsos de excitación de corta duración.

Se pretende modelar la forma del transitorio de la envolvente de un eco simple obtenido mediante la técnica pulso-eco. Para ello se van a utilizar los datos reales obtenidos de la experimentación con un par de sensores en configuración emisor-receptor ante señales de excitación de seis a catorce ciclos de duración. Se considera este rango para el número de ciclos en primer lugar porque permite generar pulsos en el sensor emisor que no le hacen llegar a la saturación de presión acústica, y en segundo lugar porque permite que el transitorio del eco sea de corta duración y ayude a que no se solapen, o se solapen en menor medida, los ecos que pudieran aparecer cercanos entre sí.

En primer lugar se va a realizar el filtrado de dichos ecos mediante el filtro 1.15 para quedarse exclusivamente con la envolvente, que es la que contiene la información de dicha respuesta transitoria de interés. Con las muestras de dichas envolventes se va a realizar el ajuste de un modelo paramétrico.

En las figuras 4.7 a 4.11 puede verse en color azul la forma que presentan los ecos correspondientes a señales de excitación que van de seis a catorce ciclos. Con los datos obtenidos de los ensayos realizados se ha podido observar un comportamiento de los sensores similar a un sistema lineal de segundo orden, por lo que se ha ajustado su respuesta en base a la respuesta de un sistema de segundo orden ante una entrada pulso, considerando que la envolvente de la señal de excitación es un pulso formado por una señal escalón de subida seguida por una señal escalón de bajada.

Se han realizado ensayos con diferentes amplitudes de la señal de excitación. En todas las situaciones los resultados han sido muy similares, no observándose variaciones sustanciales en el transitorio por lo que se puede afirmar que el comportamiento es lineal. Llegándose a que, para pulsos de excitación de corta duración, hasta 14 ciclos, se obtiene una buena aproximación mediante un sistema de segundo orden con un polo real doble con una constante de tiempo  $\tau = 160\mu s$ .

A continuación se muestra la expresión que permite aproximar la respuesta

temporal de este sistema ante entradas de excitación formadas por un pulso de  $n$  ciclos de señal sinusoidal.

Para  $0 \leq t \leq n \cdot 25\mu s$ :

$$y(t) = K \left( 1 - \frac{1}{\tau} t e^{-\frac{t}{\tau}} - e^{-\frac{t}{\tau}} \right) \quad (4.8)$$

para  $n \cdot 25\mu s < t < \infty$ :

$$y(t) = K A \cdot \left( 1 - \frac{1}{\tau} t e^{-\frac{t}{\tau}} - e^{-\frac{t}{\tau}} - \left( 1 - \frac{1}{\tau} (t - 25 \cdot 10^{-6} \cdot n) e^{-\frac{t-25 \cdot 10^{-6} \cdot n}{\tau}} - e^{-\frac{t-25 \cdot 10^{-6} \cdot n}{\tau}} \right) \right) \quad (4.9)$$

donde  $K$  engloba las ganancias debidas al propio sensor y los amplificadores empleados en la recepción de la señal y  $A$  es la amplitud del pulso de excitación.

Puede verse en las figuras 4.7 a 4.11 representado en verde la envolvente obtenida a partir de este modelo aproximado sobre la respuesta real, en azul, de los sensores para una señal de excitación de 5 voltios de amplitud (10Vpp).

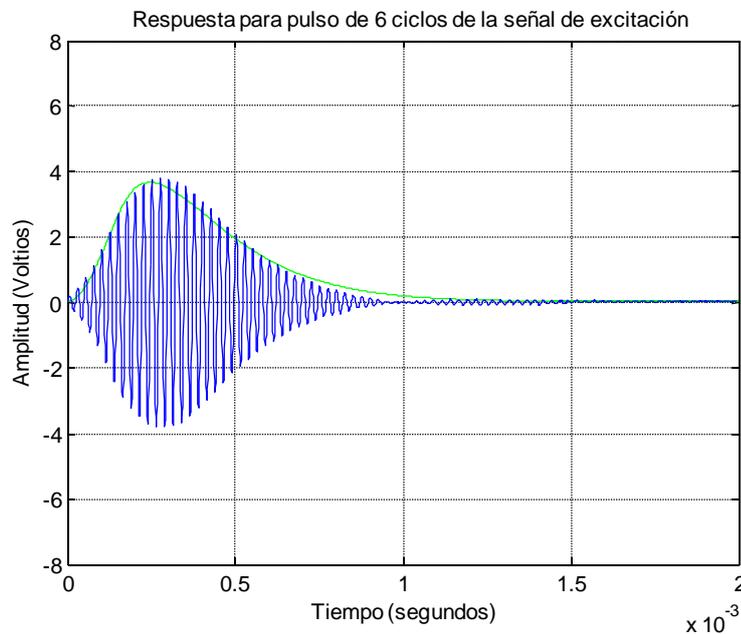


Figura 4.7: Transitorio para pulso de 6 ciclos de la señal de excitación

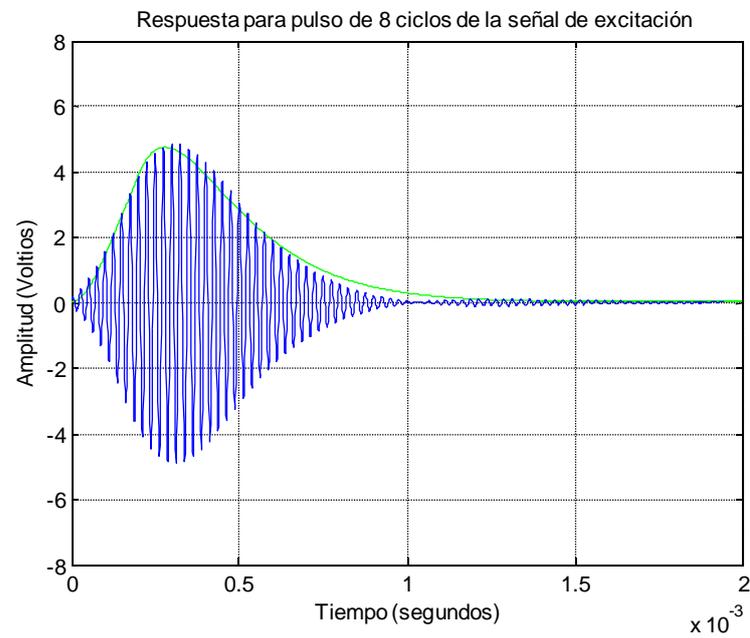


Figura 4.8: Transitorio para pulso de 8 ciclos de la señal de excitación

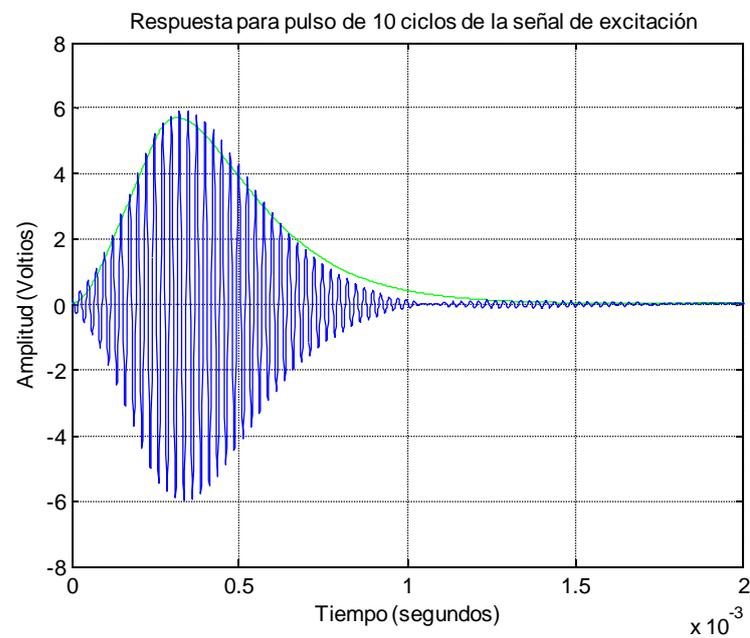


Figura 4.9: Transitorio para pulso de 10 ciclos de la señal de excitación

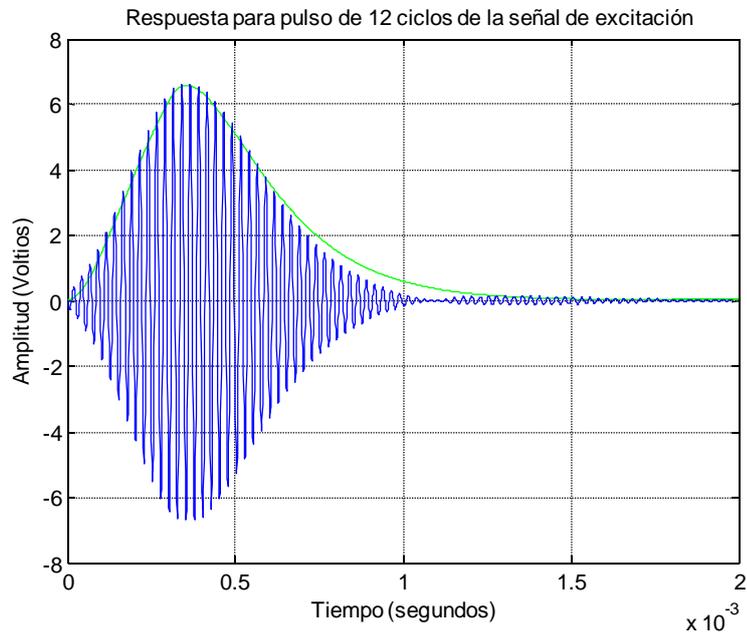


Figura 4.10: Transitorio para pulso de 12 ciclos de la señal de excitación

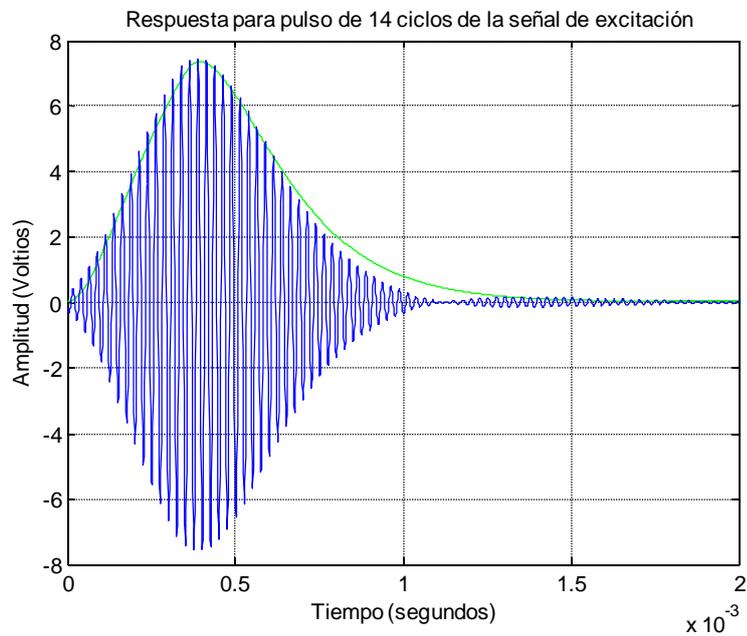


Figura 4.11: Transitorio para pulso de 14 ciclos de la señal de excitación

Las señales provenientes de pulsos de corta duración tienen también la ventaja añadida de que la duración de los ecos generados también es más corta, lo que permite que se solapen en menor medida los distintos subecos que conforman el eco total cuando se suman simultáneamente varios rebotes procedentes de la reflexión sobre superficies que se encuentran a distintas distancias pero todos ellos dentro del campo de visión de un mismo sensor receptor.

Esto ocurre frecuentemente cuando el lóbulo del sensor es muy amplio como es el caso de los sensores de baja frecuencia utilizados para la experimentación. También puede verse esta circunstancia como una ventaja ya que con un único sensor se puede ver una zona más amplia.

Se comprueba a continuación la respuesta del modelo propuesto ante diferentes amplitudes de la señal de excitación. Puede verse los resultados en las figuras 4.12 a 4.15. Se comprueba también que utilizar señales de excitación de muy pequeña amplitud hace que la señal ultrasónica generada tenga muy poca potencia y se atenúe mucho con la distancia llegando a ser imperceptible en el sensor receptor al confundirse con el nivel de ruido.

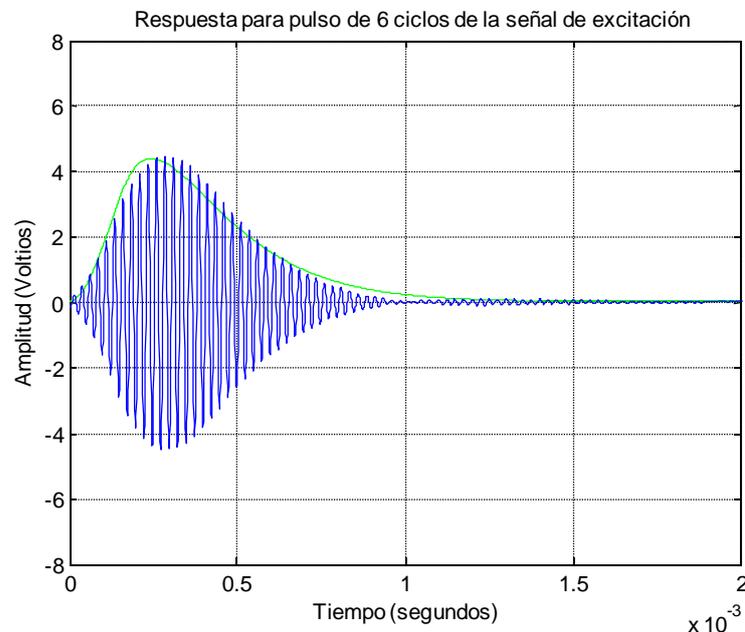


Figura 4.12: Transitorio para señal de excitación de 6 ciclos y 6 voltios

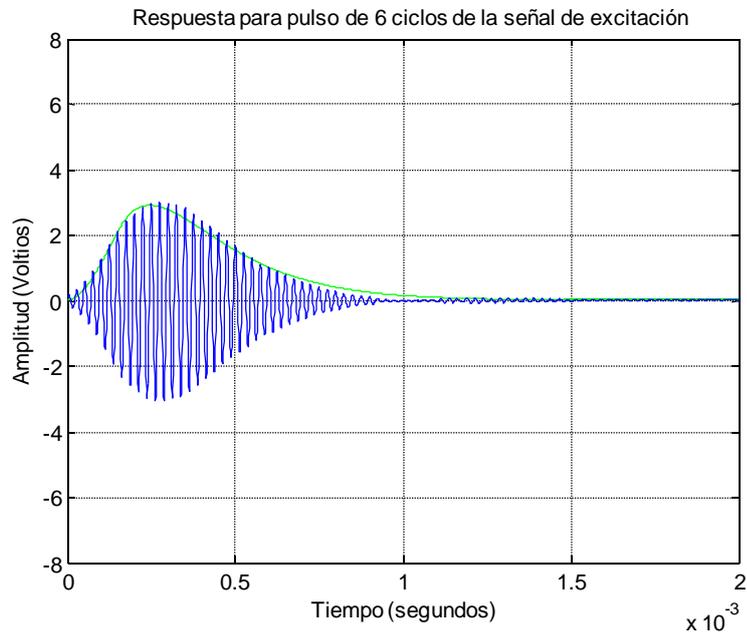


Figura 4.13: Transitorio para señal de excitación de 6 ciclos y 4 voltios

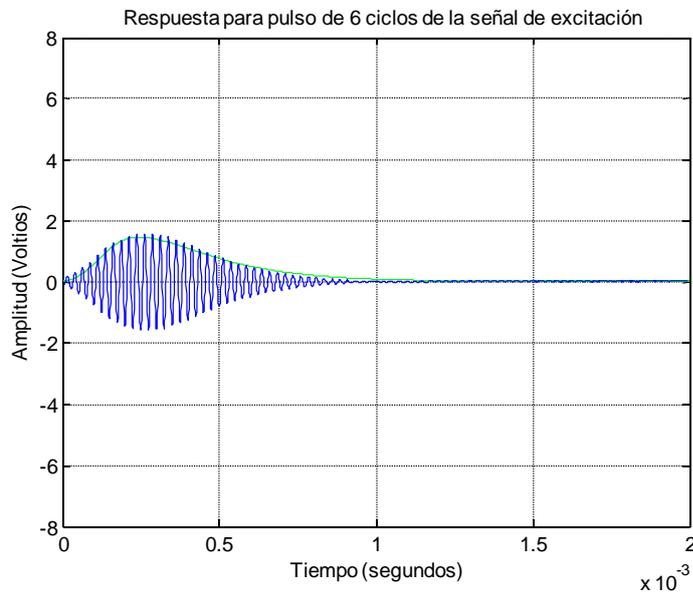


Figura 4.14: Transitorio para señal de excitación de 6 ciclos y 2 voltios

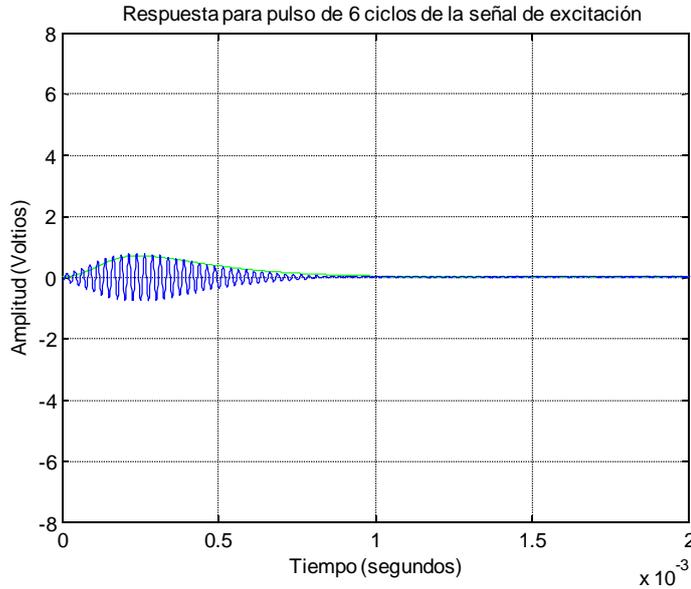


Figura 4.15: Transitorio para señal de excitación de 6 ciclos y 1 voltio

## 4.5. Aproximación de la envolvente para pulsos de excitación de larga duración.

Se pretende ahora hacer extensivo el modelo a los ecos generados con señales de excitación de larga duración que llevan a que se alcance el régimen permanente en la señal recibida en el sensor receptor.

En este caso se obtiene igualmente una buena aproximación de la respuesta temporal mediante el sistema de segundo orden con un polo real doble empleado en las ecuaciones 4.8 y 4.9 pero utilizando una constante de tiempo  $\tau = 135\mu s$ .

A continuación se muestra en las figuras 4.16 a 4.21 la respuesta de dicha aproximación sobre la respuesta real de los sensores empleados para un pulso de excitación de 5 voltios (10 Vpp) para diferente número de ciclos.

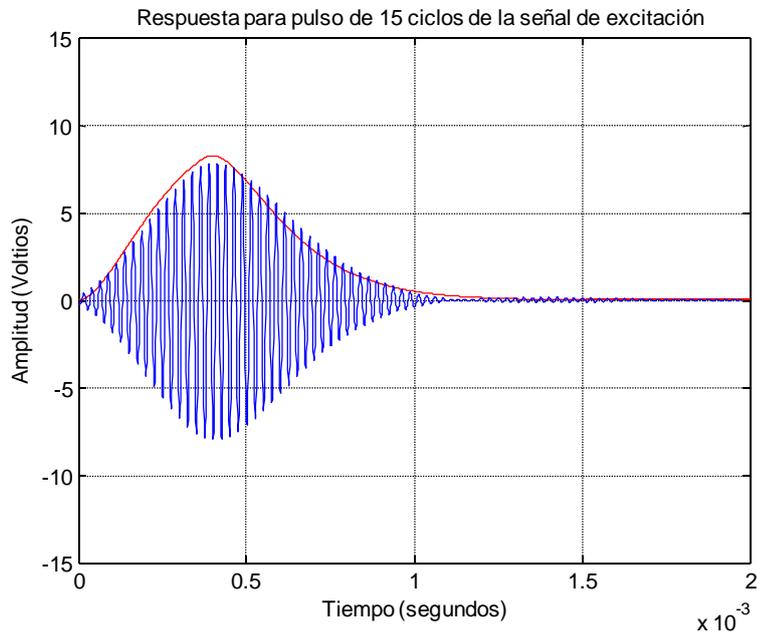


Figura 4.16: Aproximación para pulso de 15 ciclos de señal de excitación

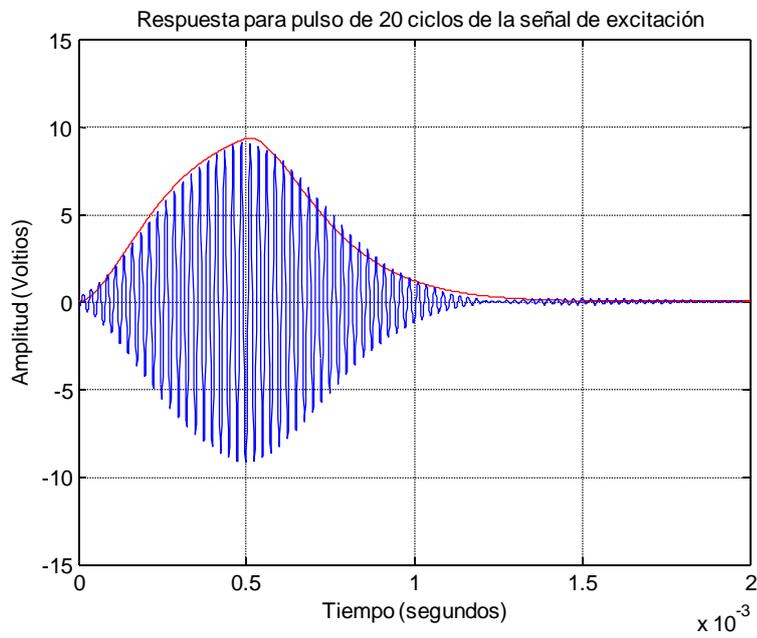


Figura 4.17: Aproximación para pulso de 20 ciclos de señal de excitación

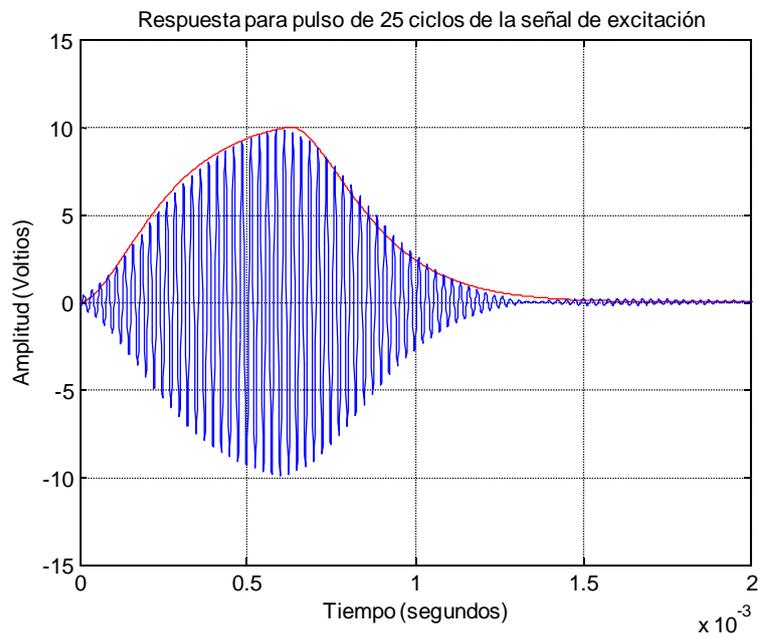


Figura 4.18: Aproximación para pulso de 25 ciclos de señal de excitación

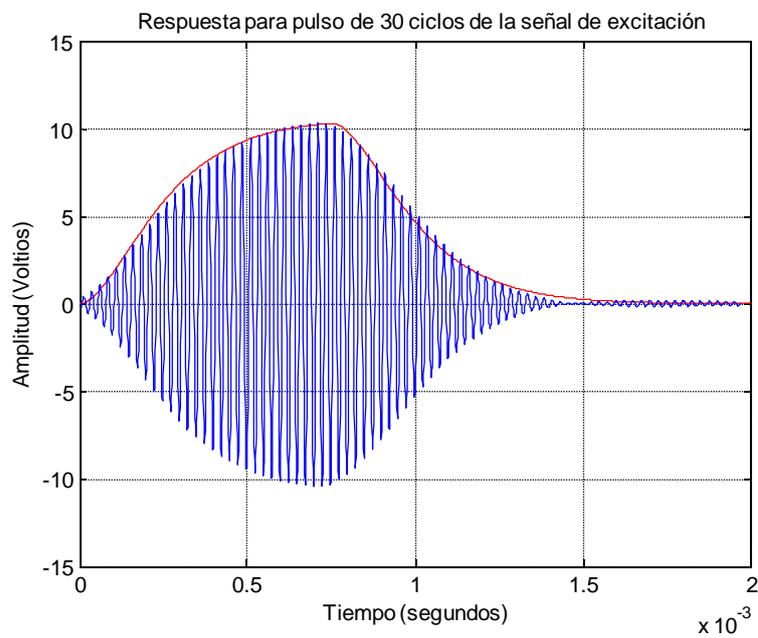


Figura 4.19: Aproximación para pulso de 30 ciclos de señal de excitación

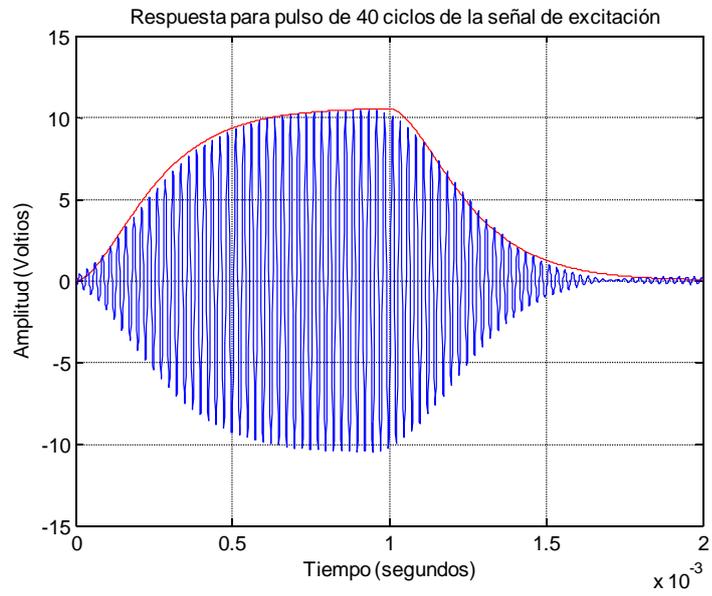


Figura 4.20: Aproximación para pulso de 40 ciclos de señal de excitación

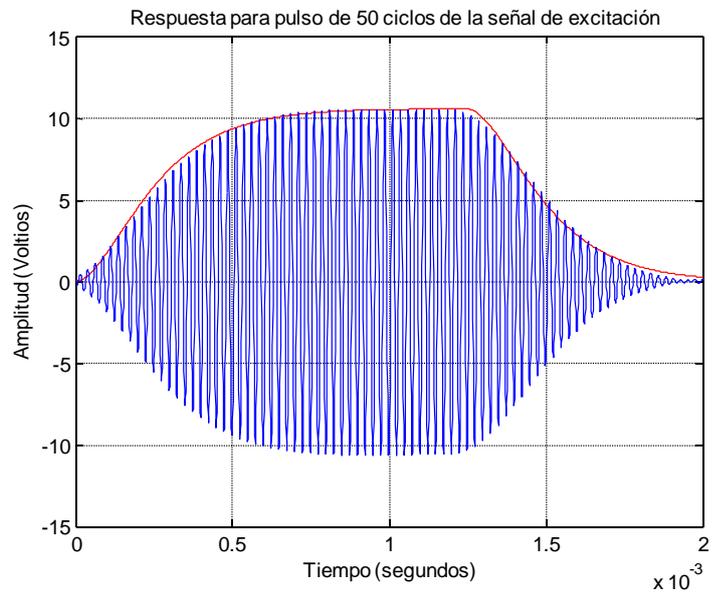


Figura 4.21: Aproximación para pulso de 50 ciclos de señal de excitación

## 4.6. Resumen y conclusiones

Como resumen del análisis se puede concluir que el comportamiento del sensor es lineal dentro del rango de amplitudes de las señales de excitación establecidas por el fabricante, obteniéndose una respuesta idéntica para pulsos de excitación de la misma duración pero de diferente amplitud, y siendo este comportamiento, desde el punto de vista de la envolvente del eco, muy similar a un sistema de segundo orden sobreamortiguado.

Sin embargo se ha comprobado que su comportamiento en relación con el número de ciclos de la señal de excitación no es lineal. Se ha propuesto un modelo linealizado que funciona para pulsos de corta duración, hasta un máximo de 14 ciclos. Y otro modelo, también linealizado, que responde correctamente para pulsos desde 15 a 50 ciclos. A partir de 50 ciclos de la señal de excitación puede observarse que la señal ha alcanzado ya el régimen estacionario.

Se ha comprobado experimentalmente dicho modelo contrastando sus resultados con los obtenidos para una amplia variedad de casos reales.

Como este modelo se pretende emplear en la navegación autónoma de un robot móvil es interesante ajustar el número de ciclos de señal para que no se solapen los posibles subecos que puedan formar la señal recibida, por ejemplo de esquinas, considerando que el robot mantendrá distancias de separación respecto a las paredes de al menos cuarenta centímetros.

También, conociendo de esta forma la evolución temporal de las señales de ultrasonidos trabajando bajo la técnica pulso-eco, y su implementación matemática nos permitirá definir mejor los tiempos de vuelo en señales complejas formadas por la suma de varios ecos. Es decir, mediante esta aproximación se podrá calcular el comienzo de cada uno de los subecos de que puede estar formado un eco proveniente del rebote sobre varias superficies simultáneamente y así abordar análisis más complejos que simplemente calcular el tiempo de vuelo del eco global recibido.



# Capítulo 5

## Modelo de transmisión de las ondas ultrasónicas.

### 5.1. Introducción.

En este capítulo se pretende analizar la naturaleza de la transmisión de ondas ultrasónicas en el aire, así como su comportamiento ante la presencia de paredes lisas y esquinas. El propósito de este análisis es presentar un modelo de transmisión de las ondas de ultrasonidos que nos permita conocer el comportamiento de los ecos ante la presencia de superficies planas y esquinas y así poder mejorar la información que, del entorno de navegación en que se mueve, puede disponer un robot móvil.

Por tanto, a partir de éste análisis, se va a programar un modelo de simulación de dicha respuesta adaptado a las situaciones y dimensiones reales que puede encontrarse un robot cuando navega por entornos interiores estructurados. Este modelo va a permitir tener un mejor conocimiento de la información que contiene un eco ultrasónico y de esta forma poder plantear un procedimiento para la extracción de dicha información.

Se plantean seguidamente una batería de experimentos para comprobar la validez de dicho modelo ante una amplia variedad de situaciones reales.

## 5.2. La ecuación de onda unidimensional.

Un aspecto importante a la hora de analizar los ecos ultrasónicos recibidos del objeto que se desea identificar es tener un modelo de propagación en el aire de dichas ondas. El modelo de transmisión de las señales ultrasónicas es la solución de la ecuación de onda linealizada para la propagación del sonido en fluidos, que viene dada por:

$$\nabla^2 p = \frac{1}{c^2} \frac{\delta^2 p}{\delta t^2} \quad (5.1)$$

donde:

$p$ : presión acústica

$c$ : es la velocidad de propagación del sonido en el aire

$t$ : tiempo.

Se va a tratar en primer lugar el caso más sencillo de transmisión de una onda en una sola dimensión, como pudiera ser el caso de una cuerda vibrante ideal.

En este caso la ecuación de onda unidimensional sería:

$$\frac{\partial^2 y}{\partial x^2} = \frac{1}{c^2} \frac{\partial^2 y}{\partial t^2} \quad (5.2)$$

Siendo la solución a la ecuación de onda de la forma mostrada en la expresión 5.3 donde se combina el comportamiento espacial y temporal de una onda armónica que viaja en la dirección  $x$ :

$$y(x, t) = A \cdot e^{j(\omega t - kx)} \quad (5.3)$$

donde

$\omega$ : velocidad angular

$k$ : número de onda

tal que

$$k = \frac{\omega}{c} \quad (5.4)$$

Debido a que la forma de onda se mueve una longitud de onda  $\lambda$  en un

periodo  $T$ , estas dos variables están relacionadas por:

$$c = \frac{\lambda}{T} \quad (5.5)$$

### 5.3. La ecuación de onda bidimensional.

Se considera ahora la vibración de un sistema en dos dimensiones como es una membrana o el diafragma de un micrófono. En este caso se requieren dos coordenadas espaciales con lo que la ecuación de onda para membranas rectangulares sería:

$$\frac{\partial^2 y}{\partial x^2} + \frac{\partial^2 y}{\partial z^2} = \frac{1}{c^2} \frac{\partial^2 y}{\partial t^2} \quad (5.6)$$

Para membranas circulares son preferibles las coordenadas polares  $(r, \theta)$  con lo que la ecuación de onda para las vibraciones transversales de una membrana circular quedaría:

$$\frac{\partial^2 y}{\partial r^2} + \frac{1}{r} \frac{\partial y}{\partial r} + \frac{1}{r^2} \frac{\partial^2 y}{\partial \theta^2} = \frac{1}{c^2} \frac{\partial^2 y}{\partial t^2} \quad (5.7)$$

donde:

$$x = r \cdot \cos\theta$$

$$z = r \cdot \sen\theta$$

### 5.4. Reflexión en la superficie de un sólido.

Se analizan aquí los fenómenos de reflexión de las ondas ultrasónicas que viajan por el aire y encuentran con un medio sólido.

Para el caso de una onda plana que incide en la dirección normal a la superficie de un sólido, dirección del eje  $x$ , la presión de la onda incidente  $p_i$ , reflejada  $p_r$  y transmitida  $p_t$  se puede representar por:

$$p_i = P_i e^{j(\omega t - k_1 x)} \quad (5.8)$$

$$p_r = P_r e^{j(\omega t + k_1 x)} \quad (5.9)$$

$$p_t = P_t e^{j(\omega t - k_2 x)} \quad (5.10)$$

donde:

$$k_1 = \frac{\omega}{c_1} \quad (5.11)$$

$$k_2 = \frac{\omega}{c_2} \quad (5.12)$$

siendo

$P_i, P_r, P_t$ : amplitudes máximas de presión incidente, reflejada y transmitida.

$c_1$ : velocidad de transmisión del sonido en el aire

$c_2$ : velocidad de transmisión del sonido en el sólido

Para el caso de una onda plana que incide oblicuamente en la superficie de un sólido no existe ningún método simple para analizar la reflexión. Debido a las diferencias en la porosidad y estructura interna de los diferentes sólidos, la naturaleza de las ondas transmitidas varía. Si se considera el tipo de refracción que ocurre para ondas planas que entran en un segundo medio, entonces existirán tres ondas: incidente, reflejada y transmitida. Si la incidencia de la onda es oblicua, con un ángulo de incidencia  $\theta_i$  la onda reflejada tendrá un ángulo  $\theta_r$  y la onda transmitida tendrá un ángulo  $\theta_t$ . Para esta situación, particularizando para las ondas incidente, reflejada y transmitida, la forma compleja de la solución armónica para la presión acústica de una onda plana que viaja en cierta dirección arbitraria en un plano será:

$$p_i = P_i e^{j(\omega t - k_1 x \cos \theta_i - k_1 y \sin \theta_i)} \quad (5.13)$$

$$p_r = P_r e^{j(\omega t + k_1 x \cos \theta_r - k_1 y \sin \theta_r)} \quad (5.14)$$

$$p_t = P_t e^{j(\omega t - k_2 x \cos \theta_t - k_2 y \sin \theta_t)} \quad (5.15)$$

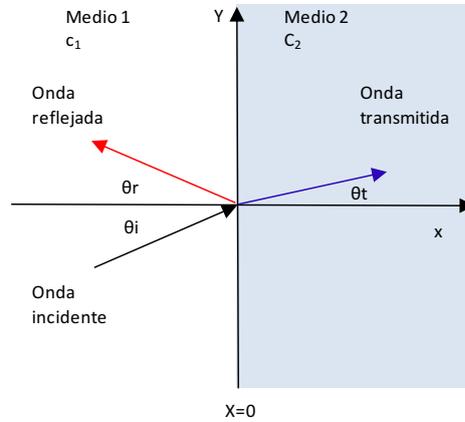


Figura 5.1: Ondas incidente, reflejada y transmitida.

Aplicando la condición de continuidad de presión en la frontera se tiene:

$$P_i e^{-jk_1 y \text{sen} \theta_i} + P_r e^{-jk_1 y \text{sen} \theta_r} = P_t e^{-jk_2 y \text{sen} \theta_t} \quad (5.16)$$

Esta expresión debe ser cierta para todo  $y$ , luego:

$$\text{sen} \theta_i = \text{sen} \theta_r \quad (5.17)$$

por lo que el ángulo de incidencia es igual al ángulo de reflexión.

Y cumpliendo la ley de Snell:

$$\frac{\text{sen} \theta_i}{c_1} = \frac{\text{sen} \theta_t}{c_2} \quad (5.18)$$

donde:

$c_1$ : velocidad de la onda en el medio 1

$c_2$ : velocidad de la onda en el medio 2

Se emplea como solución de la ecuación de onda para una fuente puntual (onda esférica monofrecuencial) la siguiente expresión:

$$p(t, r) = \frac{A}{r} e^{j(\omega t - kr)} \quad (5.19)$$

donde  $A/r$  es la amplitud de presión de la onda que decrece inversamente con la distancia a la fuente.

Se muestra en la figura 5.2 la representación de una fuente puntual ultrasónica emitiendo de forma continua a 40 kHz en un hemisferio. Considerando la presión en el campo según 4.3 y el factor de direccionalidad indicado en 4.4 calculado mediante las funciones de Bessel se representa en la figura 5.3 el patrón de direccionalidad y en la figura 5.4 el efecto que dicha direccionalidad tiene sobre las ondas ultrasónicas.

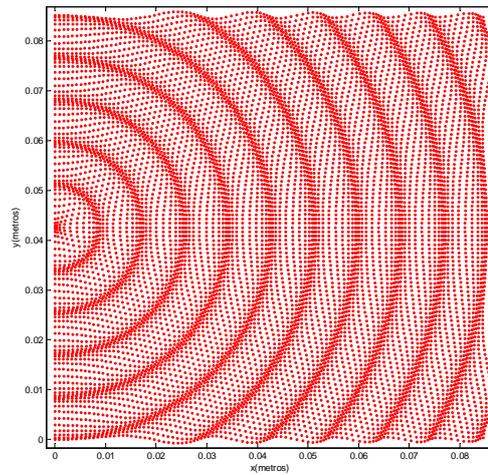


Figura 5.2: Emisión de fuente puntual ultrasónica de 40 kHz en un hemisferio

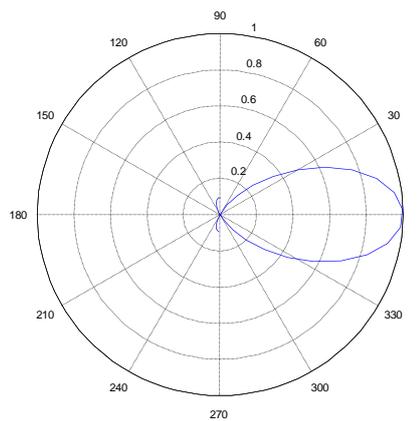


Figura 5.3: Patrón de radiación calculado mediante las funciones de Bessel

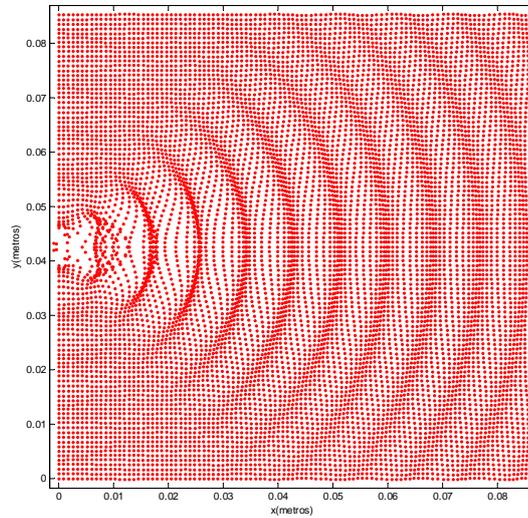


Figura 5.4: Aplicación del patrón de direccionalidad de Bessel a la emisión a 40 KHz

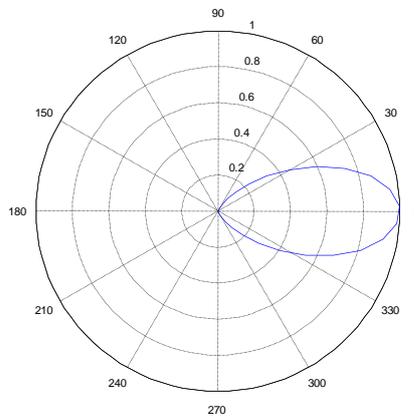


Figura 5.5: Patrón de radiación empleando la campana de Gauss

Se considera a continuación también la aproximación del patrón de radiación obtenida mediante la campana de Gauss según la expresión 4.7 que puede verse representado en la figura 5.5.

En la figura 5.6 se muestra la misma fuente puntual afectada ahora por la direccionalidad del sensor calculada a partir de la función de Gauss. La forma del patrón de radiación en el campo lejano prácticamente la misma pero la complejidad matemática de la función es mucho menor.

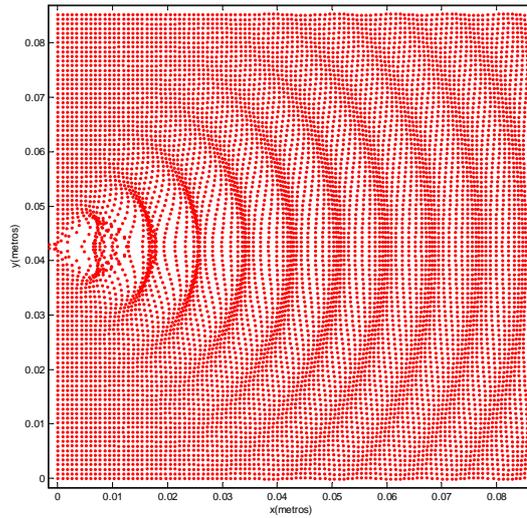


Figura 5.6: Aplicación del patrón de direccionalidad de Gauss a la emisión a 40 KHz

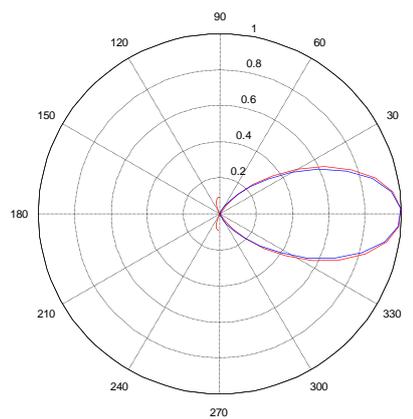


Figura 5.7: Comparativa de ambos patrones de radiación

Puede verse en la gráfica 5.7 la superposición de ambos patrones (Bessel en rojo y Gauss en azul) donde se comprueba las leves diferencias que existen entre ellos, siendo matemáticamente mucho más compleja su obtención mediante las funciones de Bessel.

## 5.5. Reflexión de las ondas ultrasónicas sobre un plano.

Se analiza el viaje de un tren de ondas ultrasónicas generadas desde un sensor emisor que se mueven espacial y temporalmente por el aire hasta alcanzar una pared sobre la que rebotan y viajan en sentido inverso hasta alcanzar el sensor receptor. El tren de ondas está formado por  $n$  ciclos de una señal de periodo  $T$ .

Empleando como solución de la ecuación de onda la indicada en la ecuación 5.19 se tiene que, para cada instante de tiempo, el inicio del tren de ondas ultrasónicas estará a una distancia  $r_i$  del foco emisor igual a la distancia recorrida por la onda en ese tiempo:

$$r_i = \frac{\omega t}{k} \quad (5.20)$$

Y el final del tren de ondas ultrasónicas estará a una distancia  $r_f$  del foco emisor que vendrá dado por:

$$r_f = \frac{\omega(t + n \cdot T)}{k} \quad (5.21)$$

Para cada punto  $p$  del espacio, definido mediante el vector  $\vec{p}$  que le une al origen de coordenadas, la distancia al foco emisor viene dada en coordenadas polares por el valor absoluto y el ángulo del vector  $\vec{r\hat{e}}$ :

$$\vec{r\hat{e}} = \vec{p} - \vec{foco} \quad (5.22)$$

Cada punto  $\vec{r\hat{e}}$  del espacio que cumpla que:

$$r_i < \text{abs}(\vec{r\hat{e}}) < r_f \quad (5.23)$$

vibrará siguiendo la expresión 5.13.

Se plantea a continuación el procedimiento bidimensional a seguir para el cálculo de la onda reflejada. La señal recibida tras una reflexión sobre un plano puede considerarse como si hubiese una fuente imagen simétrica al plano de reflexión emitiendo simultáneamente con la fuente original. Se calculará para ello la fuente imagen del emisor.

- Ecuación de la recta que define el cambio de medio. Dicha recta pasa por los puntos  $r_1p_1(x_1, y_1)$  y  $r_1p_2(x_2, y_2)$ :

$$r_1 : (y_2 - y_1)x + (x_2 - x_1)y + x_1(y_1 - y_2) + y_1(x_1 - x_2) = 0 \quad (5.24)$$

$$r_1 : A_1x + B_1y + C_1 = 0 \quad (5.25)$$

- Ecuación de la recta que pasa por el emisor ( $foco_x, foco_y$ ) y es perpendicular a la recta  $r_1$ :

$$r_{f1} : B_1x - A_1y + A_1foco_y - B_1foco_x = 0 \quad (5.26)$$

$$r_{f1} : A_fx + B_fy + C_f = 0 \quad (5.27)$$

- Punto de intersección  $pto\_intersecc_1 = (x_i, y_i)$  entre las rectas  $r_1$  y  $r_{f1}$ :

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} A_1 & B_1 \\ A_f & B_f \end{bmatrix}^{-1} \begin{bmatrix} -C_1 \\ -C_f \end{bmatrix} \quad (5.28)$$

- Fuente imagen del foco: Para ello definimos los vectores  $f\vec{o}co(foco_x, foco_y)$  y  $pto\_intersecc_1 = (x_i, y_i)$

$$f\vec{o}co1s = f\vec{o}co + 2 \left( pto\_intersecc_1 - f\vec{o}co \right) \quad (5.29)$$

- Ángulo del patrón de radiación en la fuente imagen del foco (suponiendo que el emisor emite con el patrón de radiación centrado a 0 grados): Siendo  $\theta_1$  el ángulo existente entre el eje central del patrón de radiación del emisor y la recta normal al plano de reflexión  $r_{f1}$ :

$$\theta_{foco_{1s}} = \pi + 2\theta_1 \quad (5.30)$$

- Vector y ángulo correspondiente a la señal reflejada:

$$r\vec{r}_1 = receptor - \vec{foco} \quad (5.31)$$

- Angulo de salida de la señal reflejada respecto al eje central del patrón de radiación:

$$angulo\_respecto\_foco_{1s} = angulo(r\vec{r}_1) - (\pi + 2\theta_1) \quad (5.32)$$

- Señal recibida por el receptor aplicando la expresión 5.19:

$$repcion_1 = -E \cdot a \cdot D_{r1} \cdot A_{r1} \cdot \frac{1}{abs(r\vec{r}_1)} \cdot sen(\omega t - k \cdot r\vec{r}_1) \quad (5.33)$$

donde:

$E$  es la constante que agrupa las diferentes ganancias empleadas,

$D_{r1}$  es la función que modela el patrón de radiación según la ecuación 4.7

$A_{r1}$  es la función que modela el transitorio del eco según las expresiones 4.8 y 4.9.

Puede verse en la figura 5.8 la representación de la fuente imagen del foco emisor, el patrón de radiación del sensor emisor y del sensor receptor con su ángulo respecto de la pared y el patrón del sensor emisor visto desde la fuente imagen.

En la figura 5.9 se incluye también la representación del punto de contacto con la pared y los rayos de incidencia y reflexión, en color rosa, así como sus ángulos respecto al eje del patrón de radiación.

En estas condiciones para una señal de emisión formada por un pulso de 10 ciclos de una señal sinusoidal se obtiene la señal de recepción mostrada en la figura 5.10.

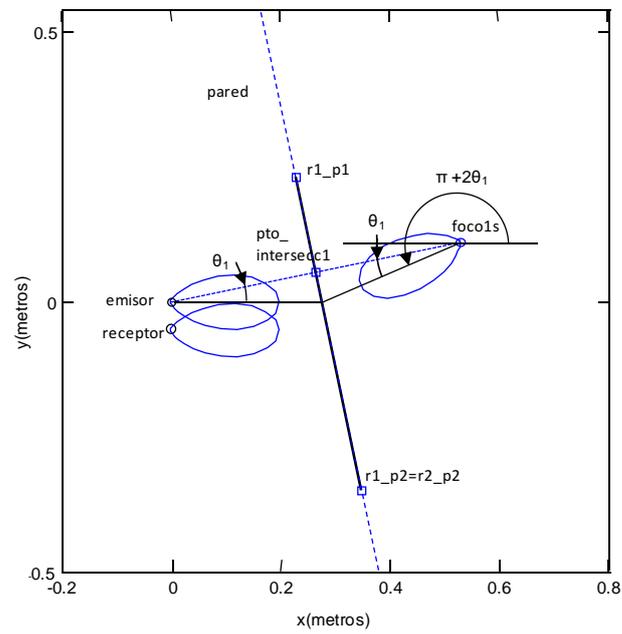


Figura 5.8: Fuente imagen para el cálculo de la reflexión sobre una superficie plana

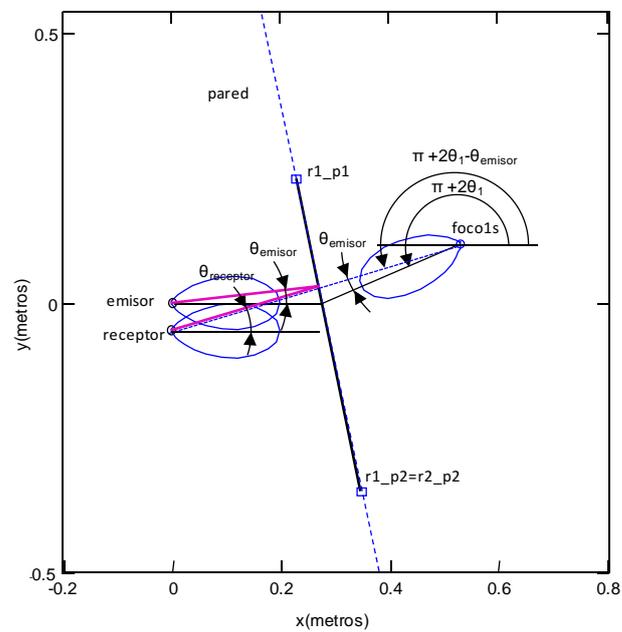


Figura 5.9: Rayos de incidencia y reflexión sobre una superficie plana

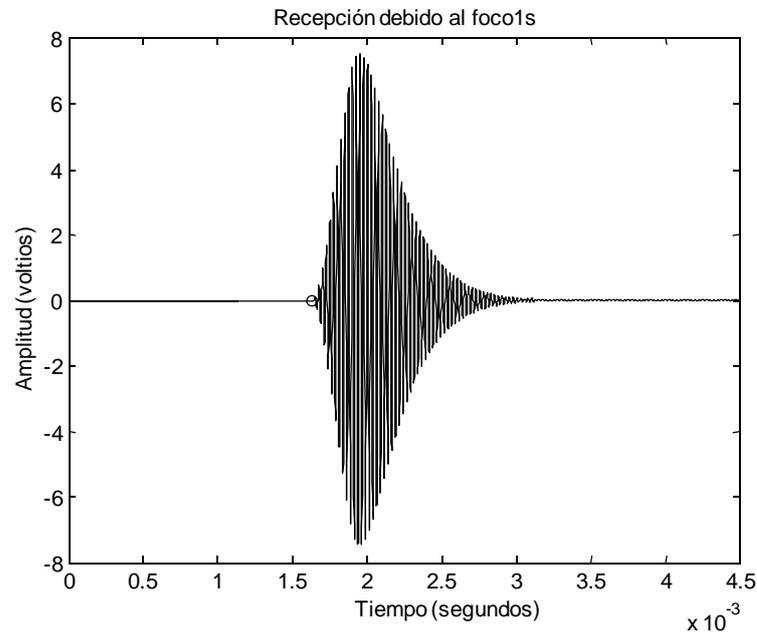


Figura 5.10: Señal de recepción en rebote sobre pared plana

## 5.6. Reflexión de las ondas ultrasónicas sobre una esquina cóncava

En este apartado se amplía el estudio realizado en el apartado anterior, para la reflexión sobre una única pared plana, al caso de la reflexión obtenido en el entorno cercano de la zona de confluencia de dos paredes planas, que denominaremos a partir de ahora como esquina cóncava.

Se muestra en primer lugar el análisis detallado de todas las señales que van a aparecer en dicha situación. Se representa dicho análisis sobre el ejemplo de una esquina cóncava mostrado, por su vista en planta, en la figura 5.11 donde el Medio 1 es el aire y el Medio 2 es la pared.

Para cada uno de los focos se representa una aproximación del patrón de radiación de los sensores empleados. Para los ensayos realizados se ha considerado como patrón de radiación el obtenido experimentalmente en 4.7:

$$D_e(r_e, \theta_e) = \frac{0,69}{r_e} e^{-0,00085 \cdot \theta_e^2} \quad (5.34)$$

donde  $(r_e, \theta_e)$  son las coordenadas polares del punto.

Se analiza a continuación por separado cada una de las señales implicadas en la formación del eco recibido de una esquina cóncava.

Considerando que el emisor es excitado por un pulso de señal senoidal, el eco recibido por el sensor receptor cuando éstos está enfocando hacia una esquina cóncava puede llegar a estar formado por hasta cinco subecos dependiendo de la geometría de la esquina. Estos cinco subecos serán los generados por:

- Reflexión directa sobre la pared 1.
- Reflexión directa sobre la pared 2.
- Reflexión directa sobre el punto de confluencia de las dos paredes.
- Doble reflexión resultante de rebotar primero la señal en la pared 1 y luego en la pared 2.
- Doble reflexión resultante de rebotar primero en la pared 2 y luego en la pared 1.

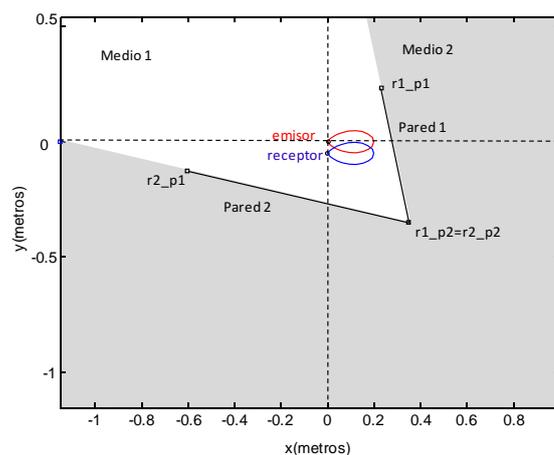


Figura 5.11: Reflexión sobre esquina cóncava

Antes de comenzar con la descripción, se indica en primer lugar la nomenclatura que se va a emplear en el análisis.

- emisor: punto donde se encuentra situado el sensor emisor
- receptor: punto donde se encuentra situado el sensor receptor
- pared1 y pared 2: las dos rectas que desde la vista en planta definen la esquina cóncava sobre la que rebota el tren de ultrasonidos
- r1\_p1 y r1\_p2: dos puntos que definen la pared 1
- r2\_p1 y r2\_p2: dos puntos que definen la pared 2
- foco1s: fuente simétrica del foco respecto a la pared1 utilizado para calcular el rebote directo sobre la pared1
- pto1: punto de contacto en el rebote sobre la pared1
- foco2s: fuente simétrica del foco respecto a la pared2 utilizado para calcular el rebote directo sobre la pared2
- pto2: punto de contacto en el rebote sobre la pared2
- foco3s: fuente simétrica del foco respecto a la confluencia de las dos paredes para calcular el rebote directo sobre la unión
- foco1ss: fuente simétrica del foco1s respecto de la pared2 utilizado para calcular el segundo rebote que primero se refleja en la pared1 y después en la pared2.
- pto1s y pto1ss: puntos de contacto en el rebote doble primero sobre pared1 y después sobre pared2
- foco2ss: fuente simétrica del foco2s respecto de la pared1 utilizado para calcular el segundo rebote que primero se refleja en la pared2 y después en la pared1.
- pto2s y pto2ss: puntos de contacto en el rebote doble primero sobre pared2 y después sobre pared1

Mediante su representación en las figura 5.12 a 5.16 se va a ir mostrando el proceso de obtención de cada uno de las reflexiones que aparecen en una esquina siguiendo el mismo procedimiento que el mostrado en el rebote sobre pared plana mostrado en la figura 5.8 y 5.9. Las figuras que se muestran a continuación incluyen la representación de la fuente imagen del emisor que corresponda en cada caso así como sus patrones de radiación, el punto de contacto de la señal en la pared y la trayectoria del subeco considerado.

En la figura 5.12 se muestra la recepción respecto a la pared 1. En la figura 5.13 se muestra la recepción respecto a la pared 2. En la figura 5.14 se muestra la recepción respecto a la confluencia de las dos paredes. En la figura 5.15 se muestra la recepción respecto al rebote primero en pared1 y después en pared 2. En la figura se muestra la recepción debida al rebote sobre la pared 2 seguido del rebote sobre la pared 1. Y por último se muestra en la figura 5.17 las cinco señales de forma conjunta.

Para una señal de emisión formada por un diez ciclos de señal senoidal a 40 kHz se ha calculado, mediante el modelo de propagación propuesto, la señal recibida en el sensor receptor proveniente de las cinco fuentes consideradas. En dichas señales se ha incluido también los tiempos de vuelo de cada una de las señales que conforman la respuesta.

- **tdv11**: tiempo en recorrer la distancia: distancia emisor a pto1 + distancia pto1 a receptor. Representado en negro.
- **tdv12**: tiempo en recorrer la distancia: distancia emisor a pto2 + distancia pto2 a receptor. Representado en verde.
- **tdv13**: tiempo en recorrer la distancia: distancia emisor a r1\_p2 + distancia r1\_p2 a receptor. Representado en rojo.
- **tdv14**: tiempo en recorrer la distancia: distancia emisor a pto1s + distancia pto1s a pto1ss + distancia pto1ss a receptor. Representado en cian.
- **tdv15**: tiempo en recorrer la distancia emisor a pto2s + distancia pto2s a pto2ss + distancia pto2ss a receptor. Representado en amarillo.

5.6. Reflexión de las ondas ultrasónicas sobre una esquina cóncava

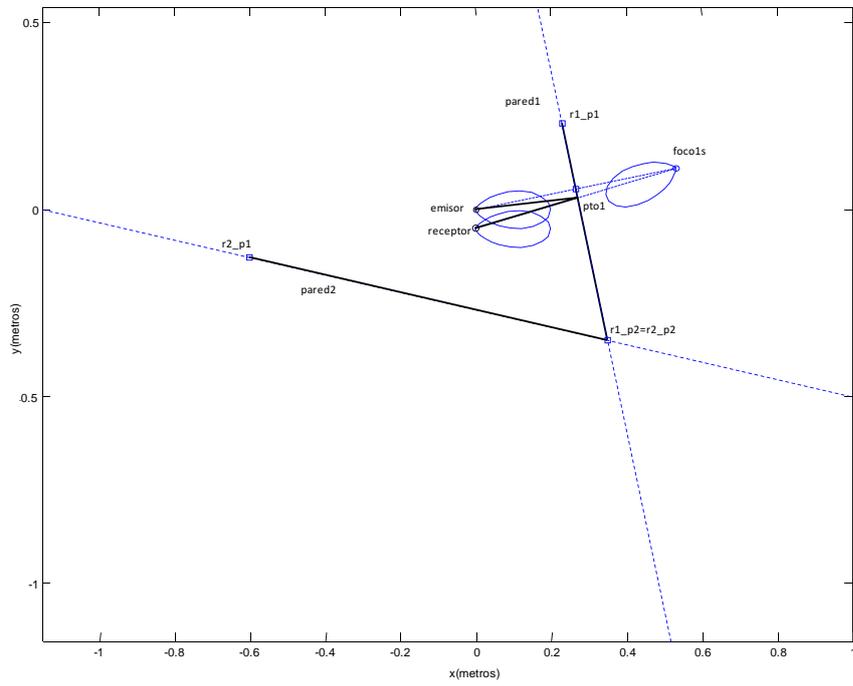


Figura 5.12: Reflexión directa sobre la pared 1

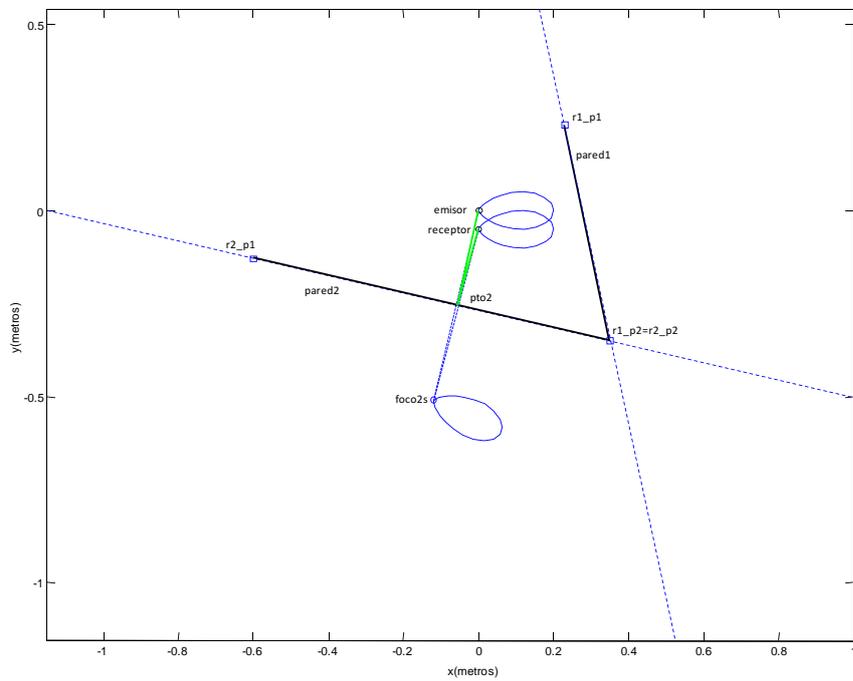


Figura 5.13: Reflexión directa sobre la pared 2

5. Modelo de transmisión de las ondas ultrasónicas.

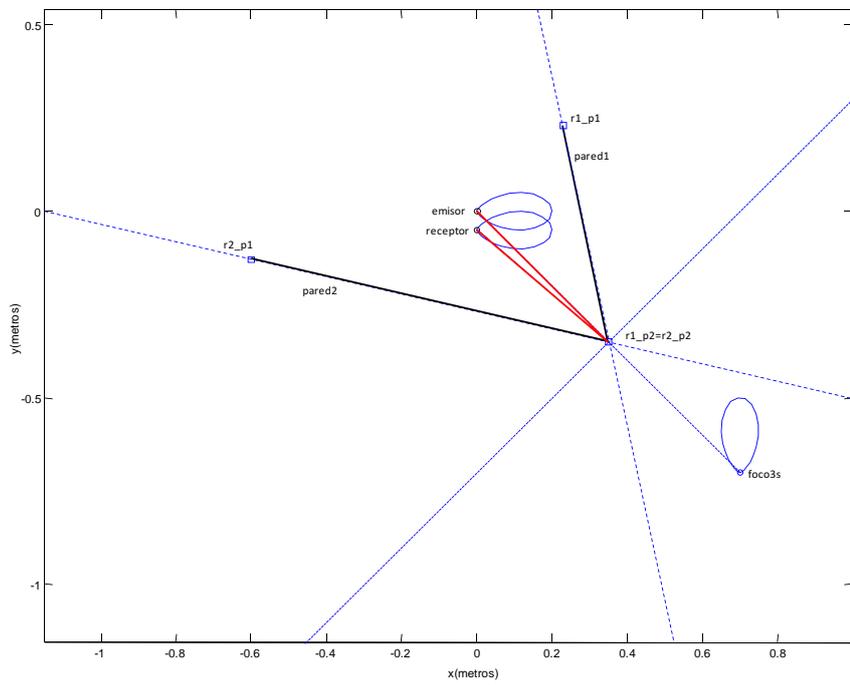


Figura 5.14: Reflexión directa de la confluencia de las dos paredes

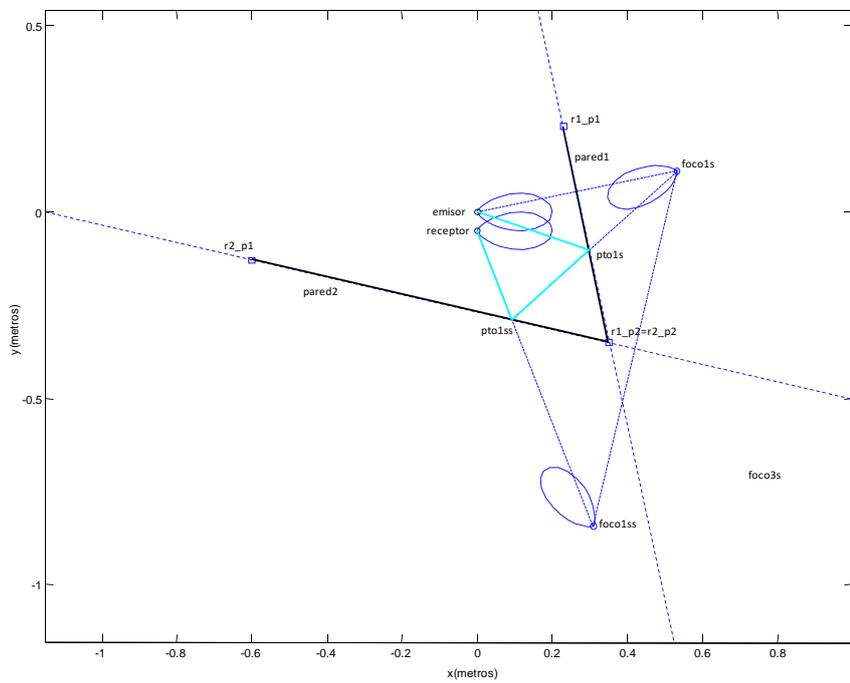


Figura 5.15: Reflexión primero sobre pared 1 y después sobre pared 2

5.6. Reflexión de las ondas ultrasónicas sobre una esquina cóncava

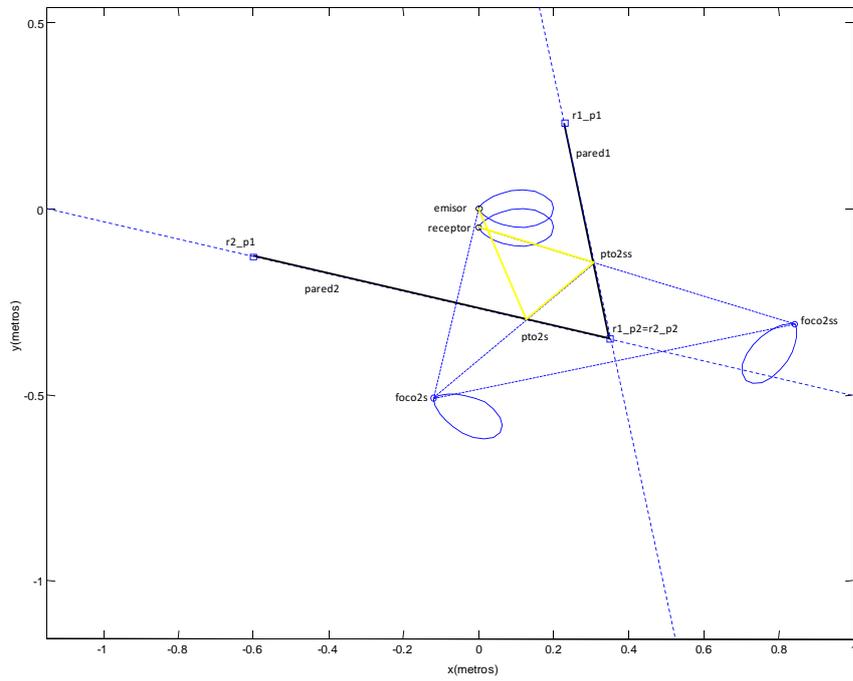


Figura 5.16: Reflexión primero sobre la pared 2 y después sobre la pared 1

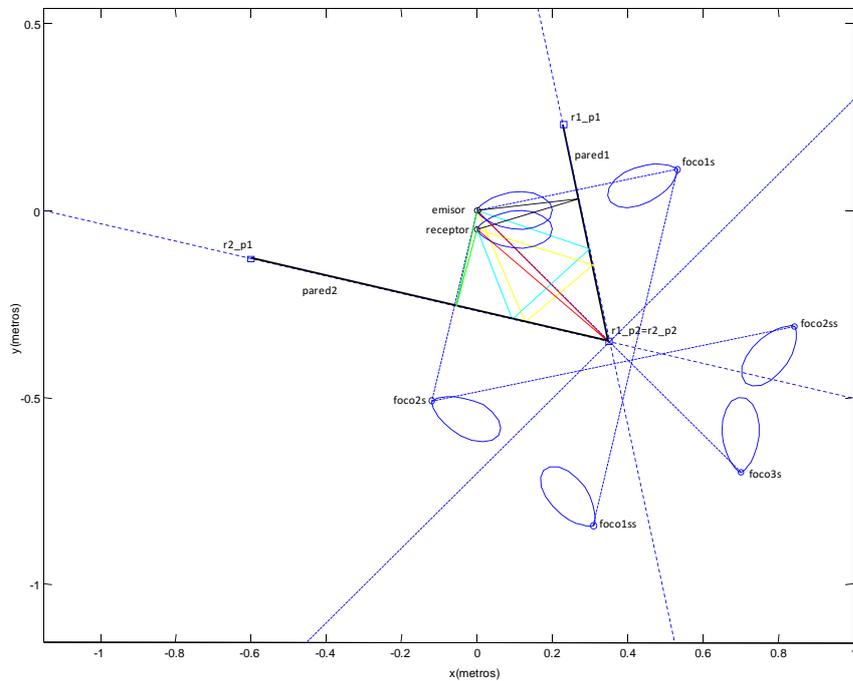


Figura 5.17: Representación conjunta de las cinco señales

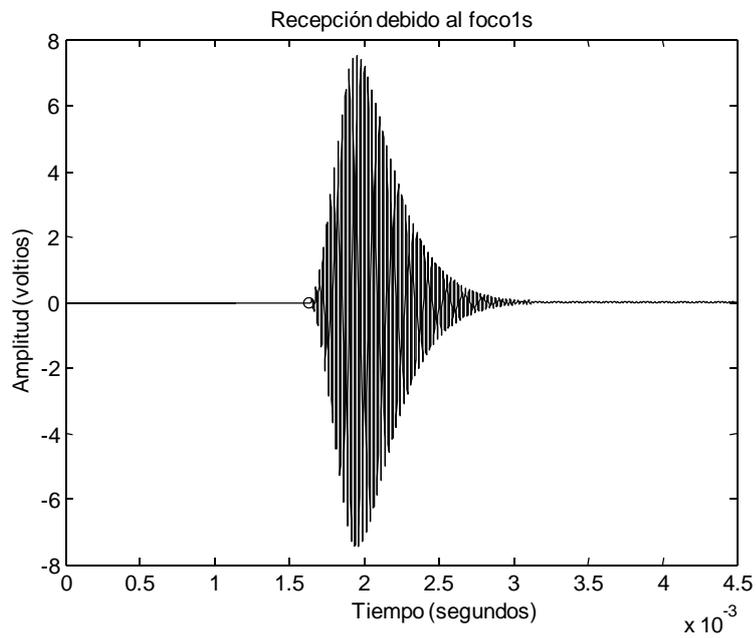


Figura 5.18: Reflexión debida al foco 1s

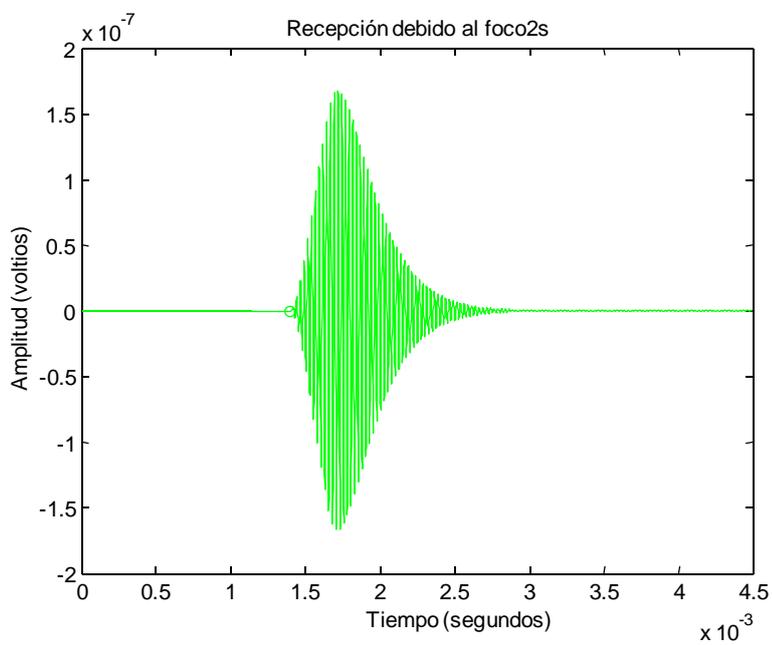


Figura 5.19: Reflexión debida al foco 2s

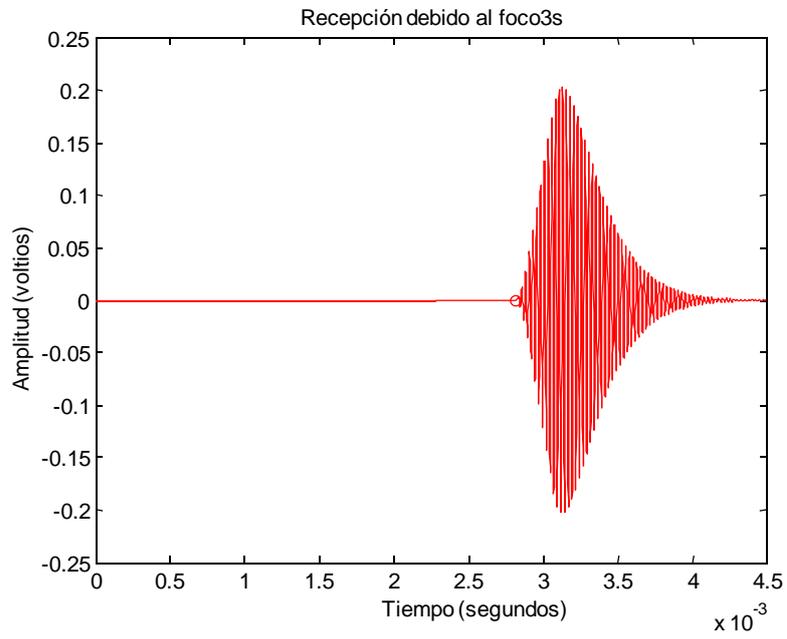


Figura 5.20: Reflexión debida al foco 3s

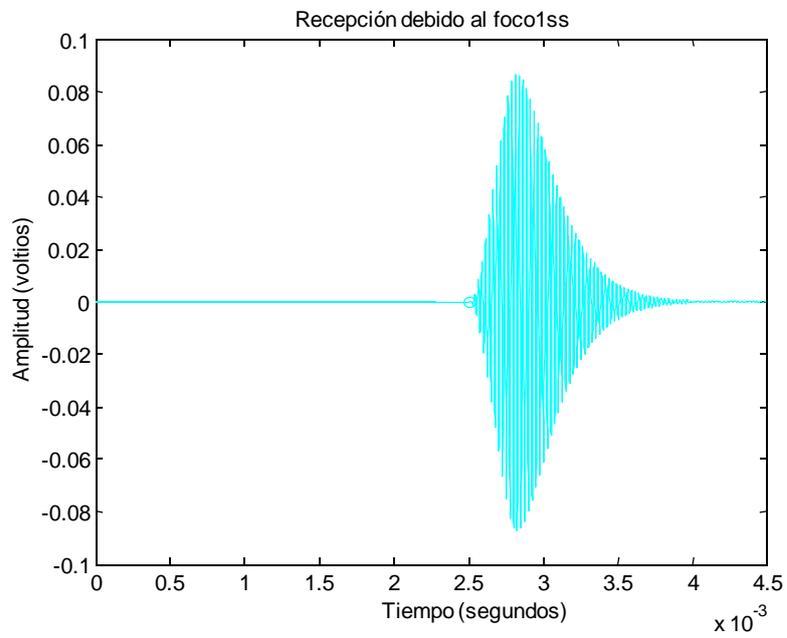


Figura 5.21: Reflexión debida al foco 1ss

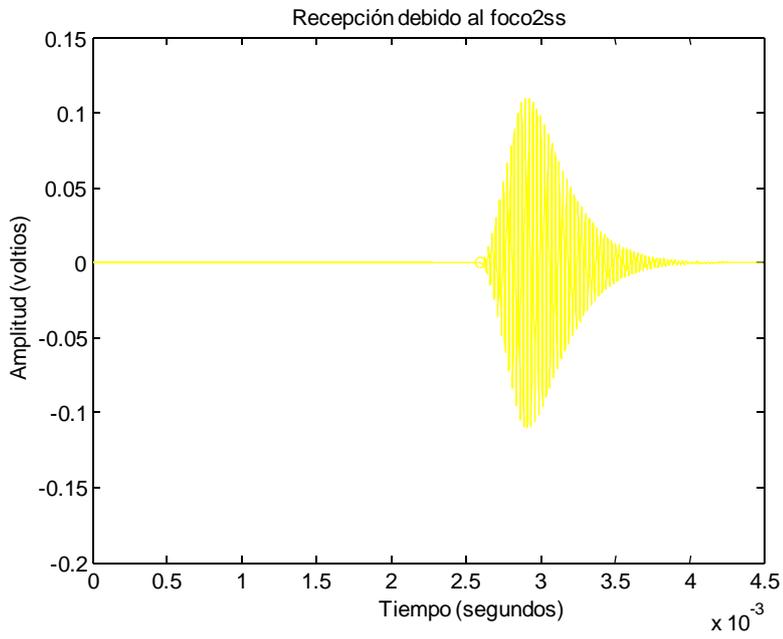


Figura 5.22: Reflexión debida al foco 2ss

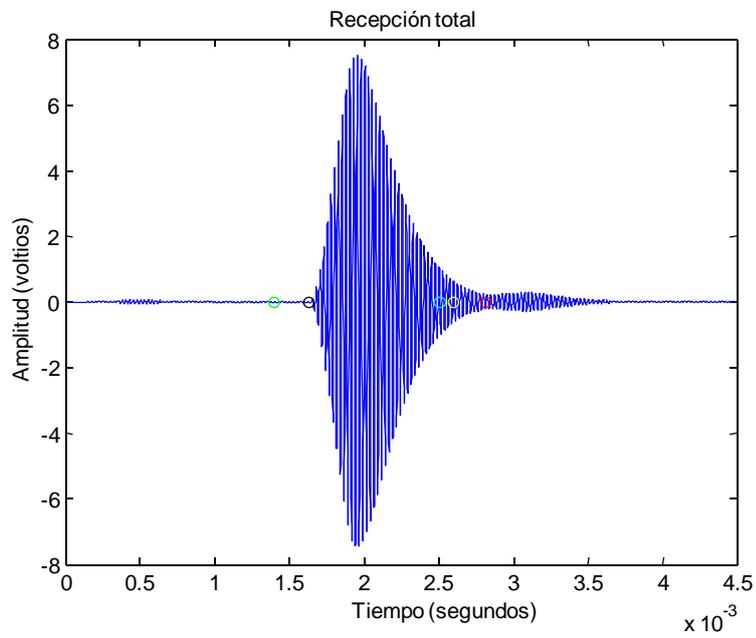


Figura 5.23: Reflexión total

En la tabla 5.1 se incluyen los valores de los tiempos de vuelo obtenidos para cada uno de los subecos y en la tabla 5.2 puede verse las coordenadas de los puntos más significativos de la esquina considerada cuya pared 1 está inclinada 21 grados respecto al eje y.

Del análisis del modelo establecido se pueden extraerse las siguientes conclusiones:

- Para los ecos recibidos que estén formados por múltiples subecos es interesante la obtención de los tiempos de vuelo para los  $n$  siguientes ecos de la señal, en vez de quedar limitado al primer eco. Para ello se van a programar los algoritmos de detección de los siguientes subecos y la obtención de los tiempos de vuelo de dichos subecos.

Subeco	Tiempo (s)
tdv11	0.0016
tdv12	0.0014
tdv13	0.0028
tdv14	0.0025
tdv15	0.0026

Tabla 5.1: Tiempos de vuelo de los subecos

Punto	Coordenadas(metros)
r1_p1	0.23+0.23i
r1_p2	0.35 - 0.35i
r2_p1	-0.6 - 0.13i
r2_p2	0.35 - 0.35i
emisor	0+0i
receptor	0-.02i
angulo	21 grados
foco1s	0.5324 + 0.1101i
foco2s	-0.1182 - 0.5105i
foco1ss	0.3115 - 0.8435i
foco2ss	0.8435 - 0.3115i
foco3s	0.7 - 0.7i

Tabla 5.2: Coordenadas de los puntos representativos de la esquina

- El cálculo de los tiempos de vuelo de los subecos se realizará a partir de los máximos, ya que en la mayoría de los casos los ecos pueden aparecer solapados con lo que es difícil de marcar directamente el punto de comienzo del subeco. Con el modelo de transitorio de la forma del eco realizado, ecuaciones 4.8 y 4.9, se puede inferir el comienzo de cada sub-eco dada la posición de su máximo.
- El primer tiempo de vuelo corresponde a un rebote directo, lo que da información directamente de la distancia a una de las dos paredes o a la unión. El resto de subecos pueden ir llegando en cualquier orden dependiendo de la posición respecto a las paredes. Pudiendo tener menos recorrido un rebote doble que uno directo.
- Si se desea poder comparar las diferencias de potencia entre diferentes subecos, debido por ejemplo al efecto del patrón de radiación, es necesario normalizar las amplitudes de cada subeco respecto al tiempo de vuelo para eliminar el efecto de la atenuación con la distancia.
- Los subecos de mayor amplitud normalizada corresponderán a las situaciones en que las paredes se encuentren más perpendicularmente mirando a los sensores o más próximas.
- Para los subecos que no estén solapados la amplitud correspondiente a cada señal está relacionada con el factor de direccionalidad del sensor empleado. De esta forma, conociendo las amplitudes normalizadas de cada señal se puede saber la inclinación que presenta cada una de las paredes de la esquina respecto a los sensores empleando su patrón de radiación.

## 5.7. Experimentación sobre una esquina cóncava de 65 grados.

Para validar el modelo programado se incluye a continuación una comparativa entre los ecos obtenidos a partir del modelo desarrollado y los ecos obtenidos de un experimento real con una esquina cóncava formando un ángulo de sesenta y cinco grados entre sus paredes.

En la figura 5.24 puede verse el montaje realizado para la toma de datos experimentales. Se ha diseñado un mecanismo, ver figura 5.25 que permite fijar la separación de los sensores mediante la transformación de un movimiento giratorio de un motor paso a paso, controlado desde el PC, en un movimiento lineal que permite la aproximación y separación entre el sensor emisor y los dos receptores situados simétricamente a ambos lados. De la misma forma mediante un segundo motor paso a paso se controla el giro del conjunto sensor con respecto a las paredes de la esquina. Así mismo todo el conjunto sensor con los dos motores indicados está colocado sobre una guía lineal que permite también su desplazamiento longitudinal.

Se sitúa el par emisor-receptor centrado angularmente en la esquina a una distancia de 50 cm de la unión de las dos paredes. Se realiza un barrido angular con un par de sensores emisor-receptor situado frente a dicha esquina.

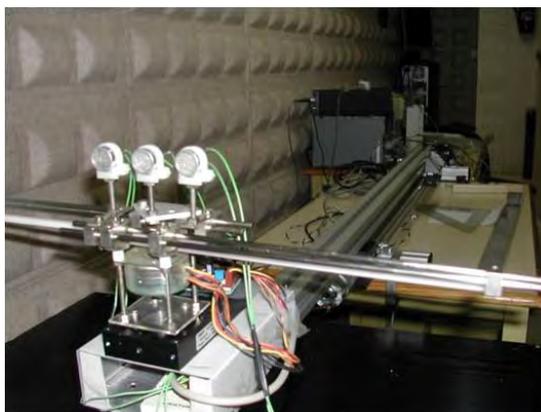


Figura 5.24: Montaje experimental

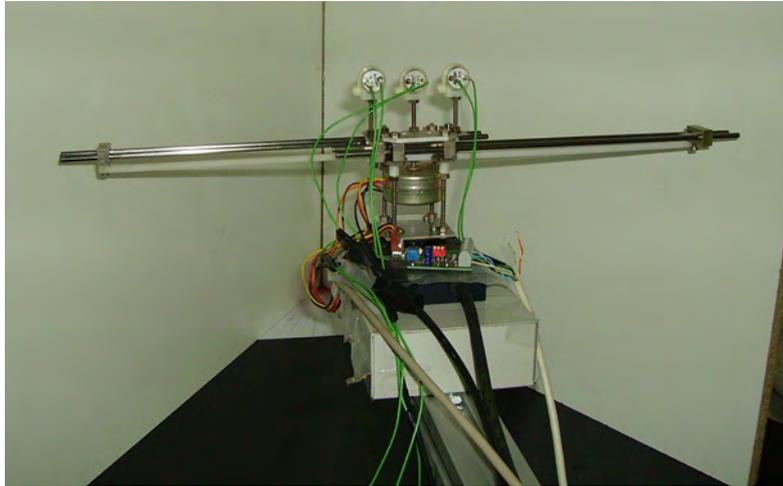


Figura 5.25: Mecanismo de desplazamiento

El barrido parte de la situación en que los sensores se encuentran enfrentados a una de las paredes de la esquina y se va girando el par emisor-receptor, con eje de giro en el emisor, en el sentido de las agujas del reloj hasta que se encuentra enfrentado a la otra pared que forma la esquina. El experimento se ha realizado tomando datos cada grado de giro. Para simplificar la representación gráfica se incluyen a continuación en las figura 5.26 a 5.33 únicamente los resultados para giros de diez en diez grados. En cada figura se muestra la posición del par emisor-receptor respecto a la esquina y la comparativa entre la señal real obtenida, en verde, y la generada por el modelo programado, en azul. Se incluye también, en color cian, la señal de excitación del sensor, para poder calcular los tiempos de vuelo. Para reducir el número de gráficas se ha seleccionado la parte del barrido que comienza donde se deja de ver la primera pared únicamente y empieza a recibirse información de la esquina, y termina donde solamente se recibe información de la segunda pared.

Se incluyen a continuación las figuras 5.34 a 5.41 los mismos casos de las figuras 5.26 a 5.33 pero mostrando únicamente las envolventes del eco real, en verde, y las envolventes del eco resultante del modelo programado, en azul. Así mismo en rojo, se muestra la curva del error como diferencia entre las dos curvas anteriores.

5.7. Experimentación sobre una esquina cóncava de 65 grados.

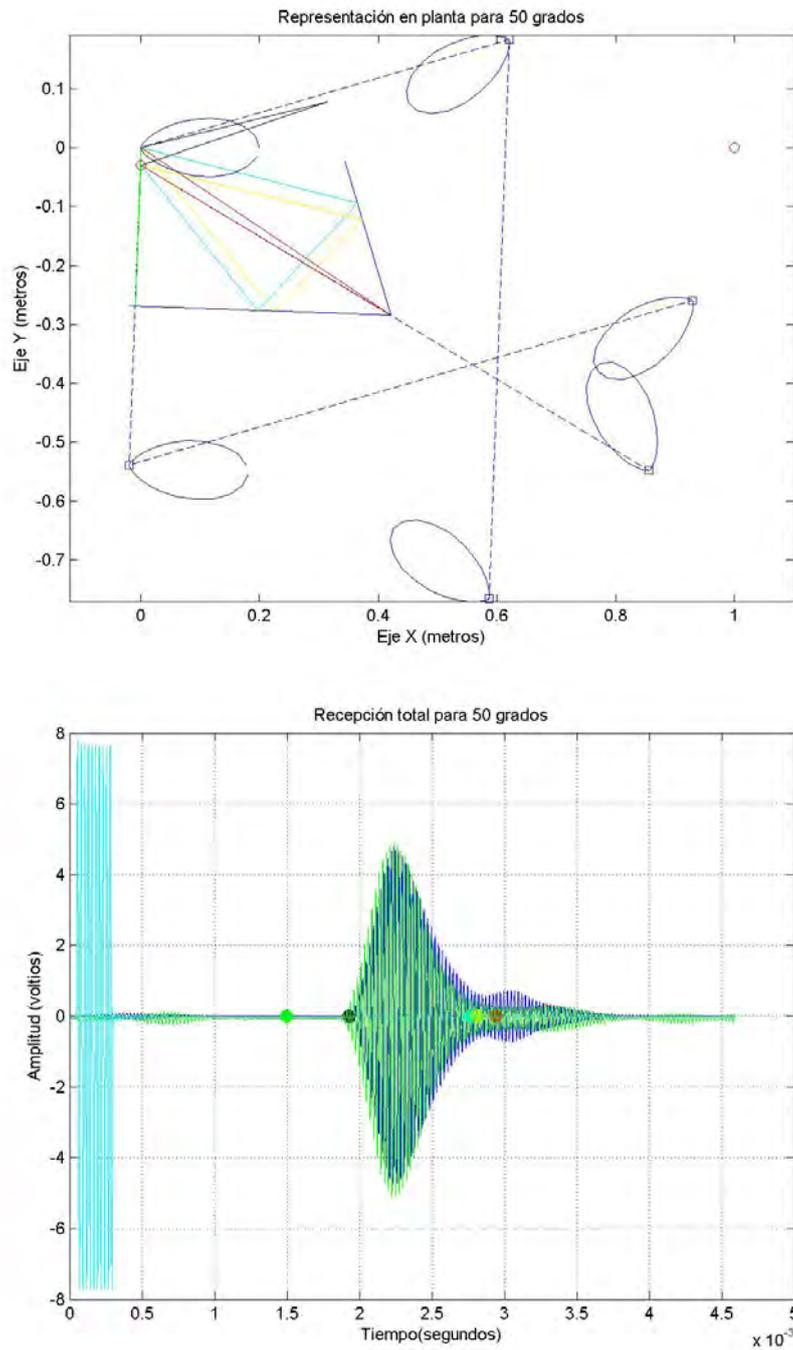


Figura 5.26: Inclinación de 50 grados

5. Modelo de transmisión de las ondas ultrasónicas.

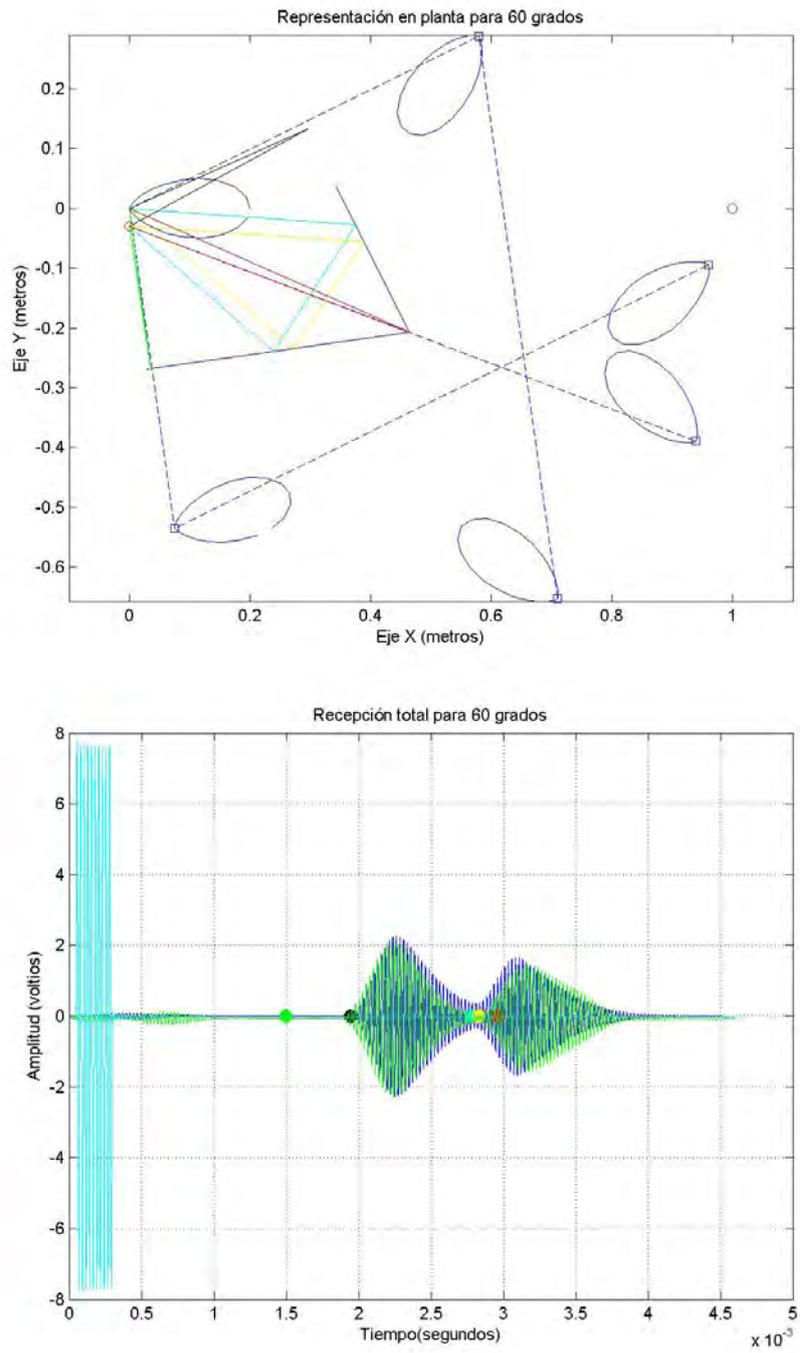


Figura 5.27: Inclinación de 60 grados

5.7. Experimentación sobre una esquina cóncava de 65 grados.

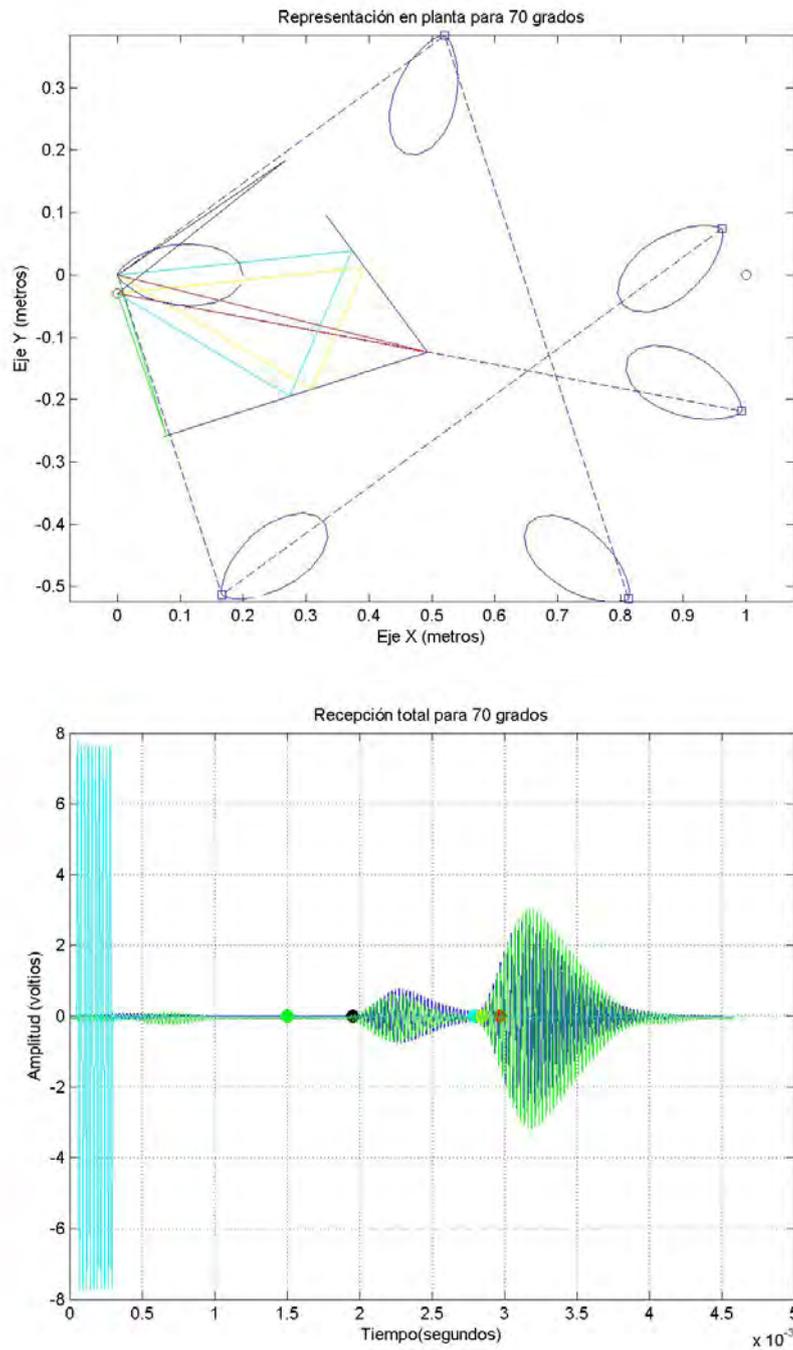


Figura 5.28: Inclinación de 70 grados

5. Modelo de transmisión de las ondas ultrasónicas.

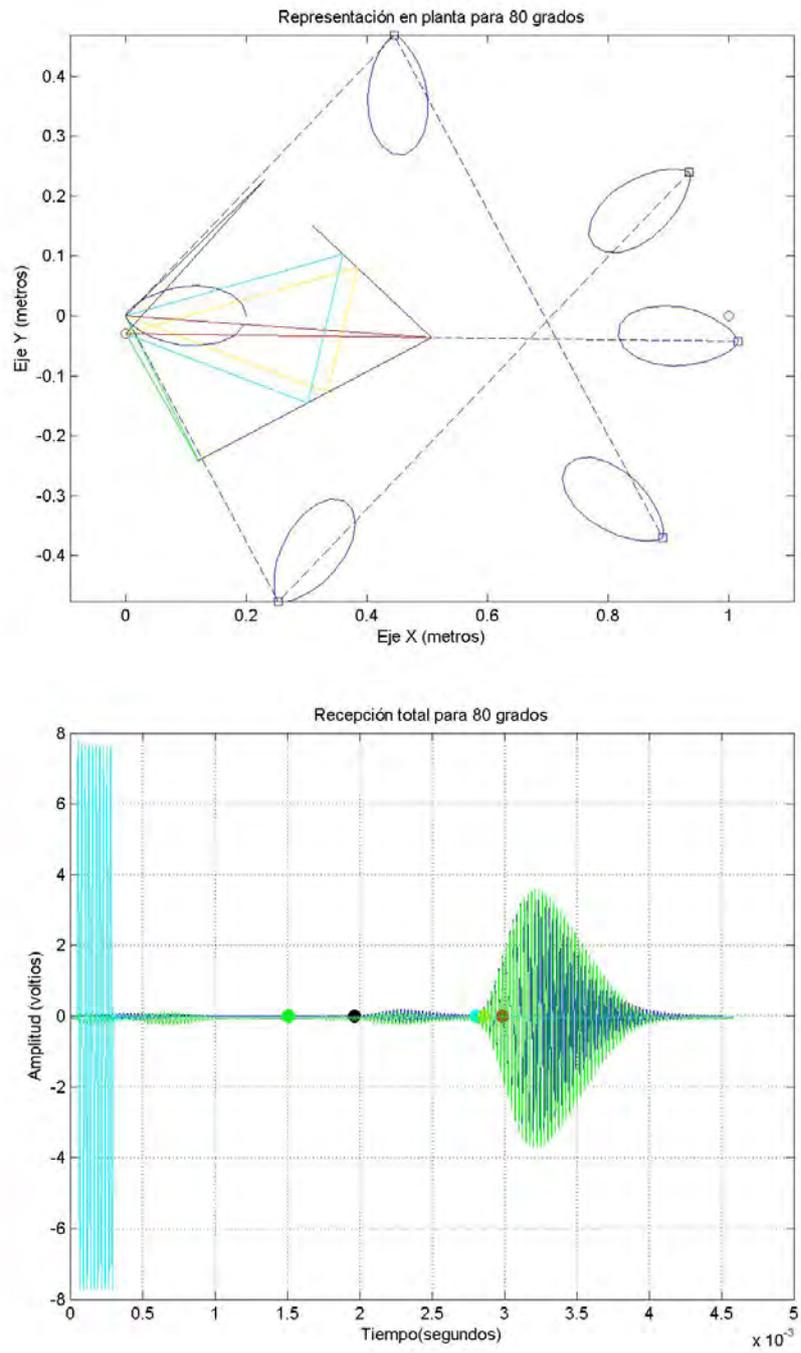


Figura 5.29: Inclinación de 80 grados

5.7. Experimentación sobre una esquina cóncava de 65 grados.

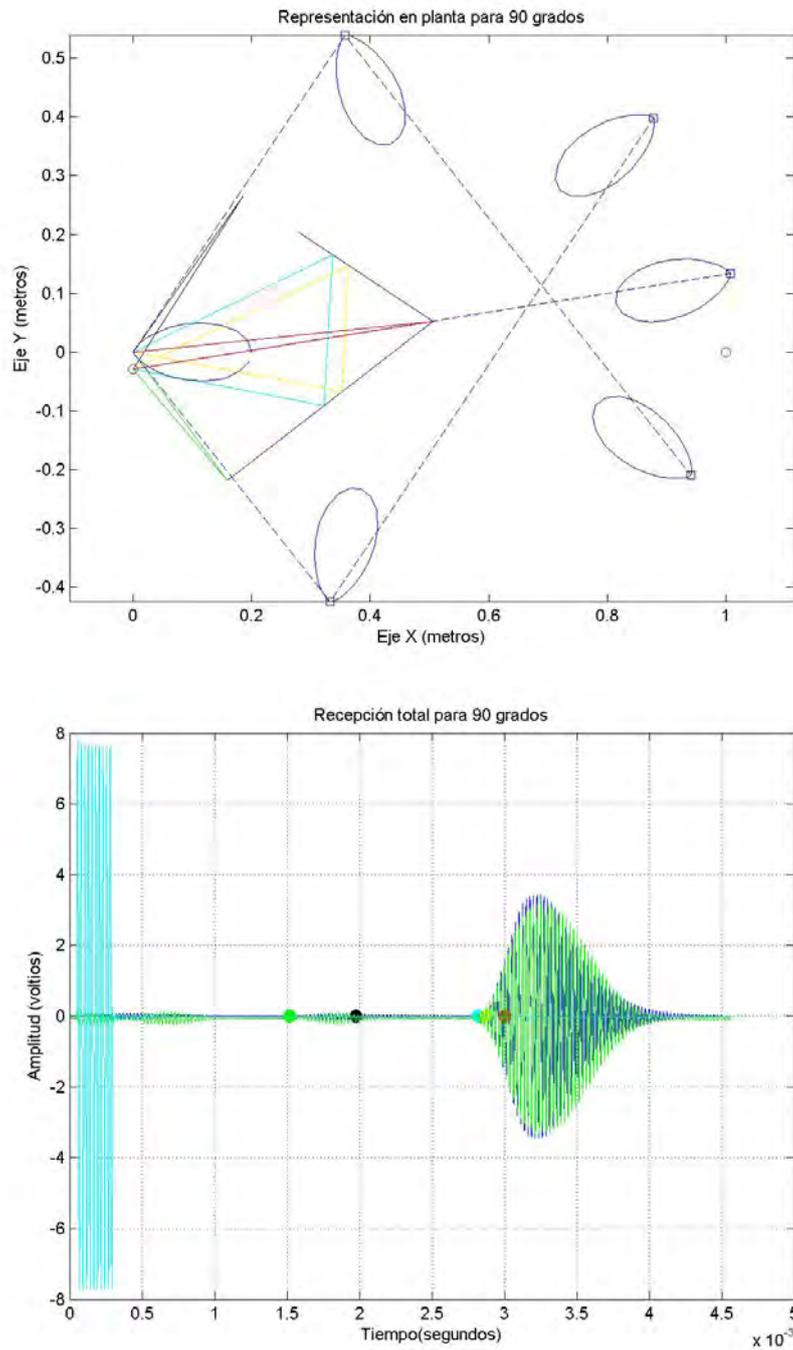


Figura 5.30: Inclinación de 90 grados

5. Modelo de transmisión de las ondas ultrasónicas.

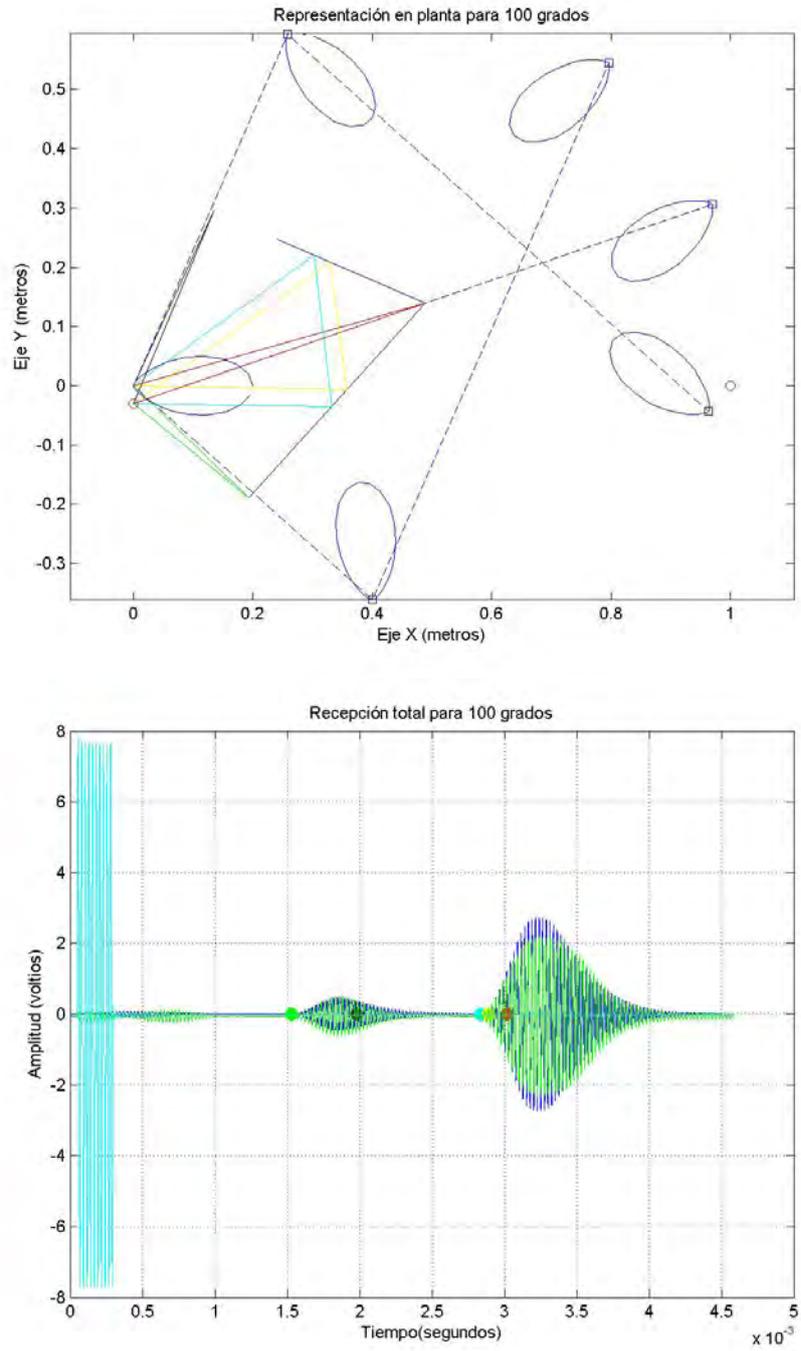


Figura 5.31: Inclinación de 100 grados

5.7. Experimentación sobre una esquina cóncava de 65 grados.

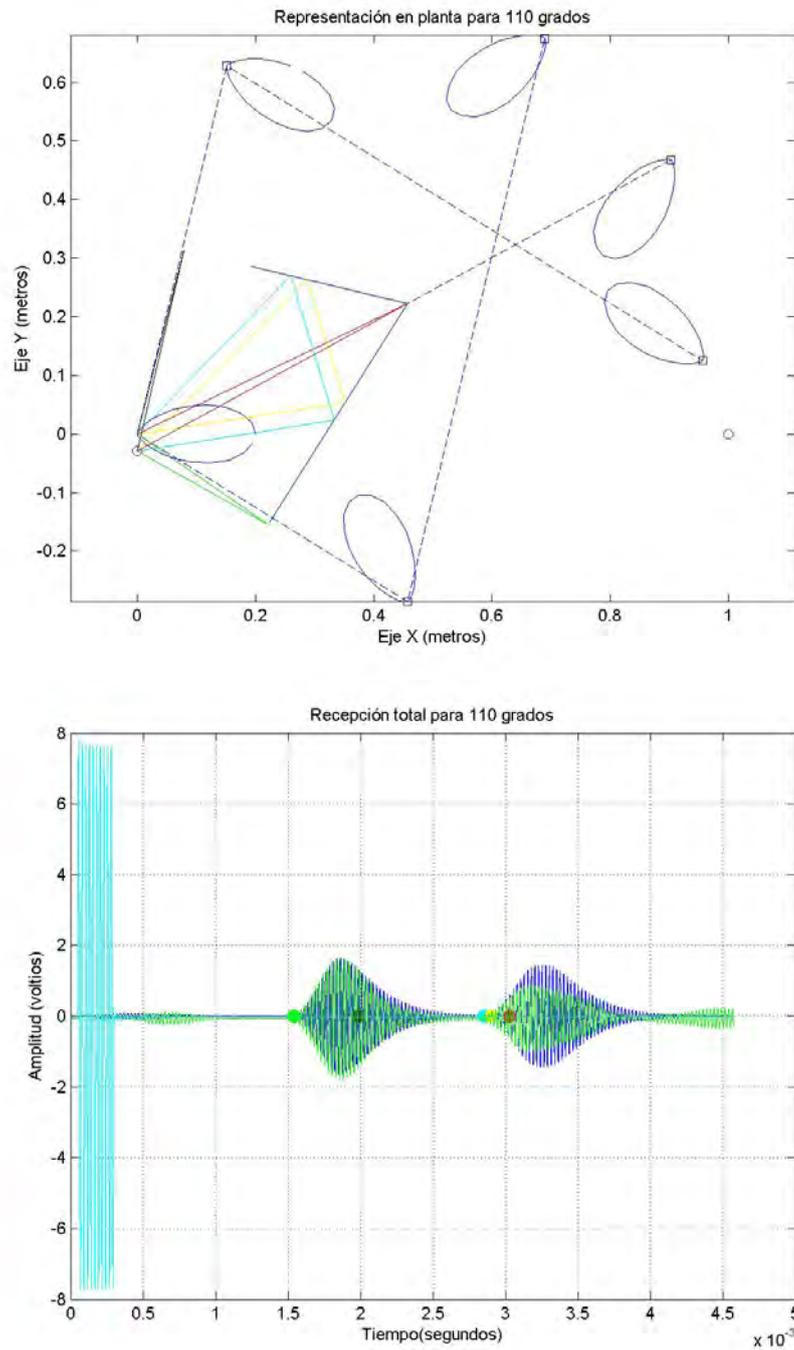


Figura 5.32: Inclutación de 110 grados

5. Modelo de transmisión de las ondas ultrasónicas.

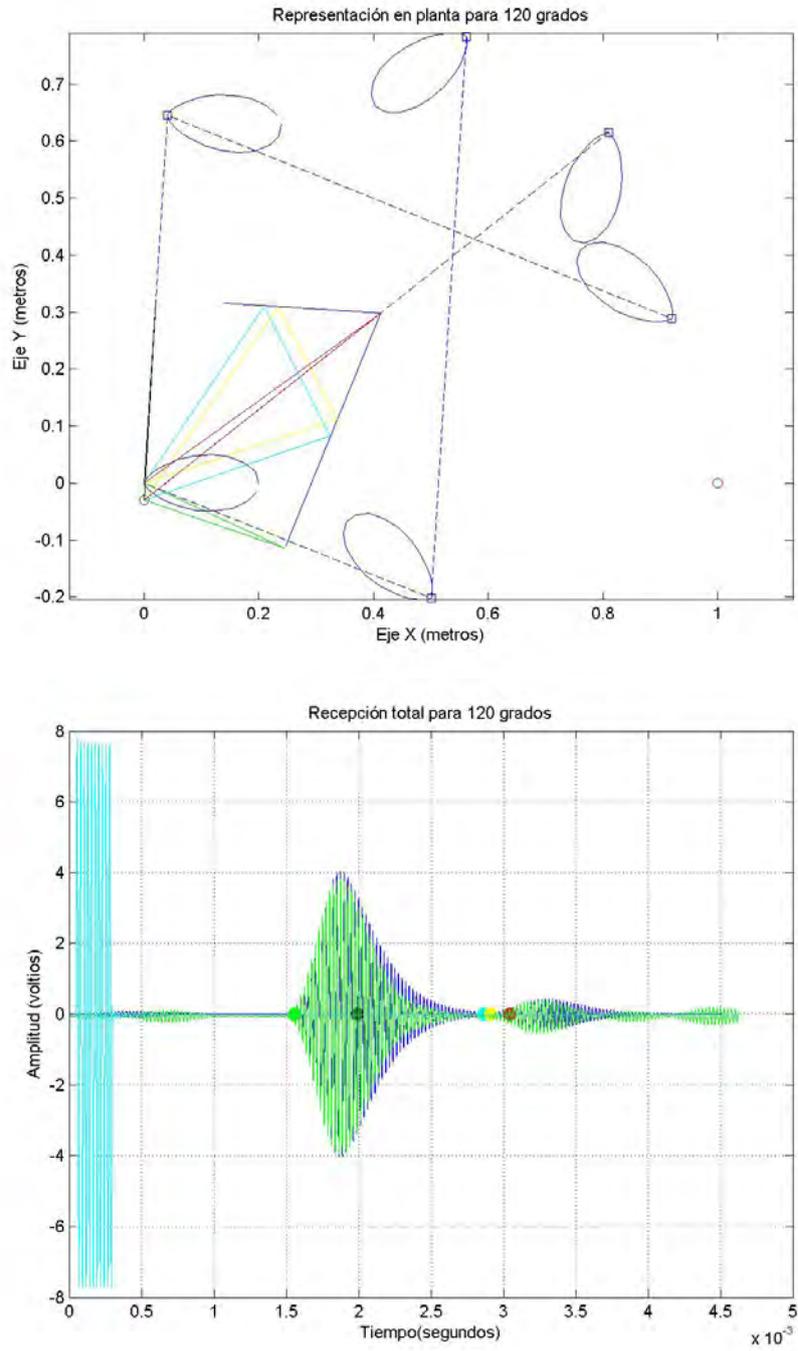


Figura 5.33: Inclinación de 120 grados

5.7. Experimentación sobre una esquina cóncava de 65 grados.

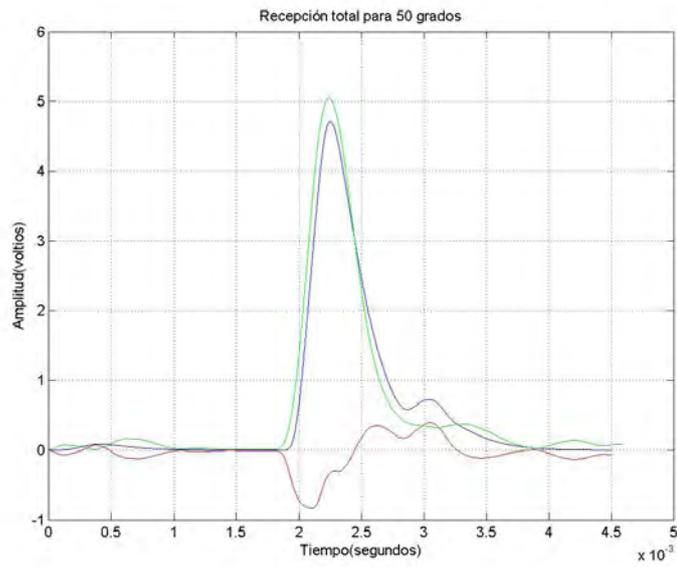


Figura 5.34: Envoltentes y error para 50 grados

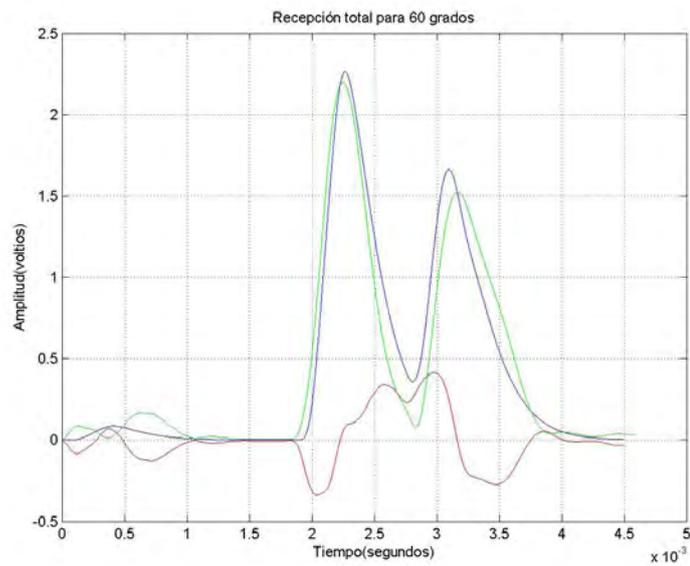


Figura 5.35: Envoltentes y error para 60 grados

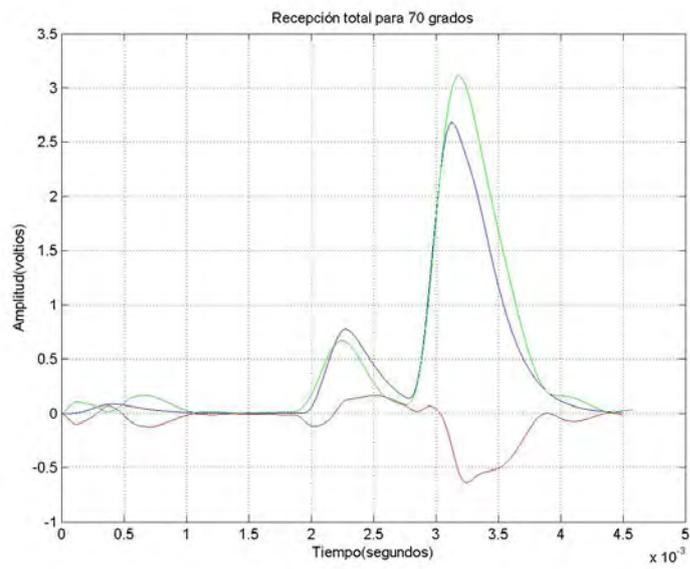


Figura 5.36: Envolventes y error para 70 grados

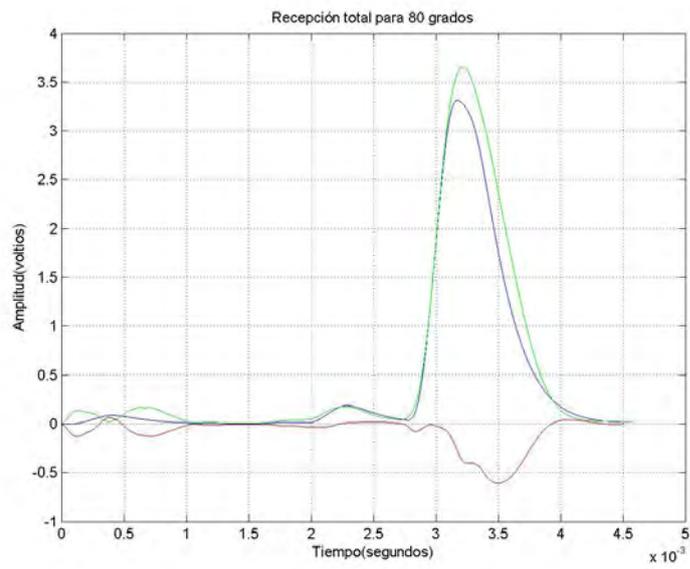


Figura 5.37: Envolventes y error para 80 grados

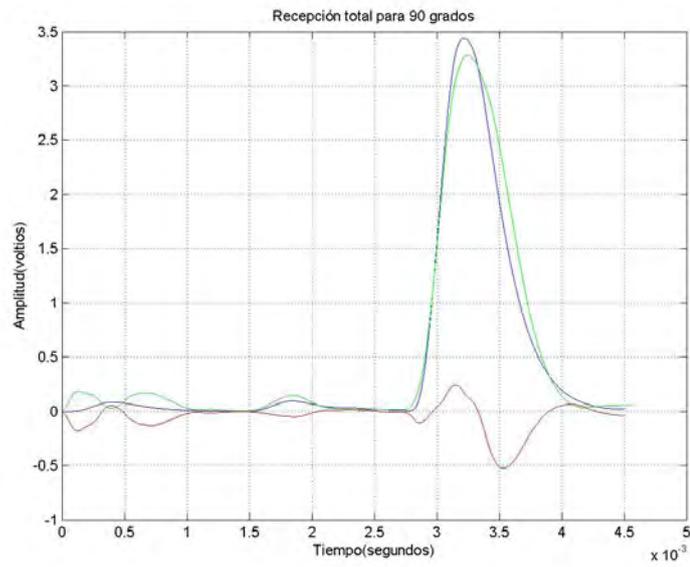


Figura 5.38: Envolventes y error para 90 grados

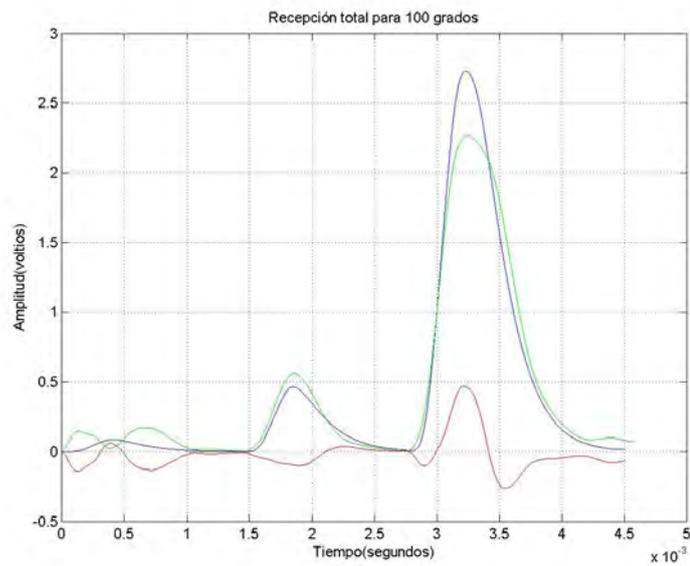


Figura 5.39: Envolventes y error para 100 grados

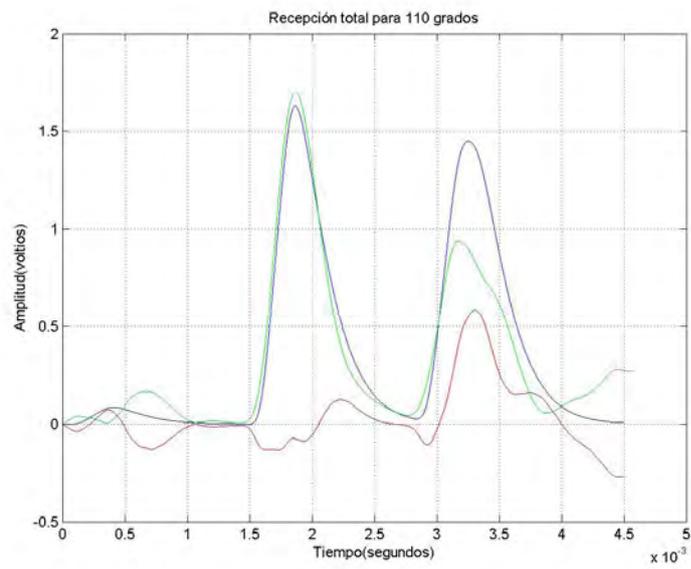


Figura 5.40: Envolventes y error para 110 grados

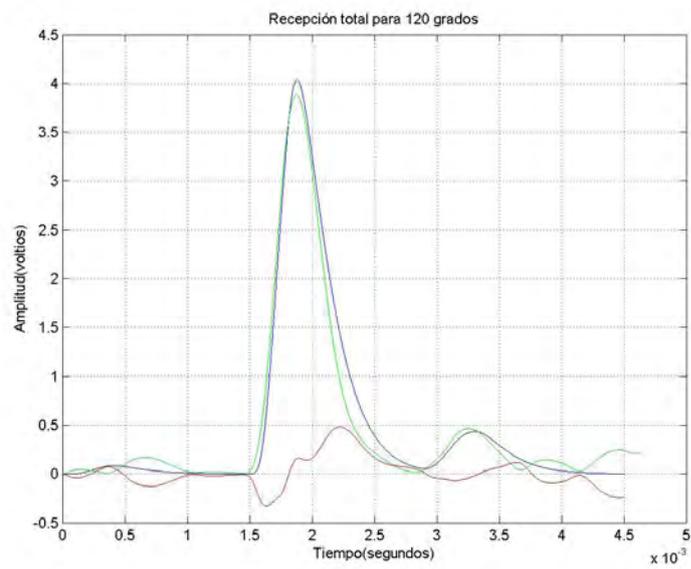


Figura 5.41: Envolventes y error para 120 grados

Y finalmente, para todas las posiciones angulares, con incrementos de un grado, y empleando la curva del error, se calcula el error cuadrático medio

empleando las expresiones siguientes:

$$error_{cuadratico} = \sum_{t=t_0}^{t=t_f} e(t)^2 \quad (5.35)$$

$$error_{cuadratico-medio} = \frac{\sqrt{error_{cuadratico}}}{n^{\circ}muestras} \quad (5.36)$$

Pueden verse los resultados del error cuadrático medio para todas las posiciones angulares del barrido en la figura 5.42.

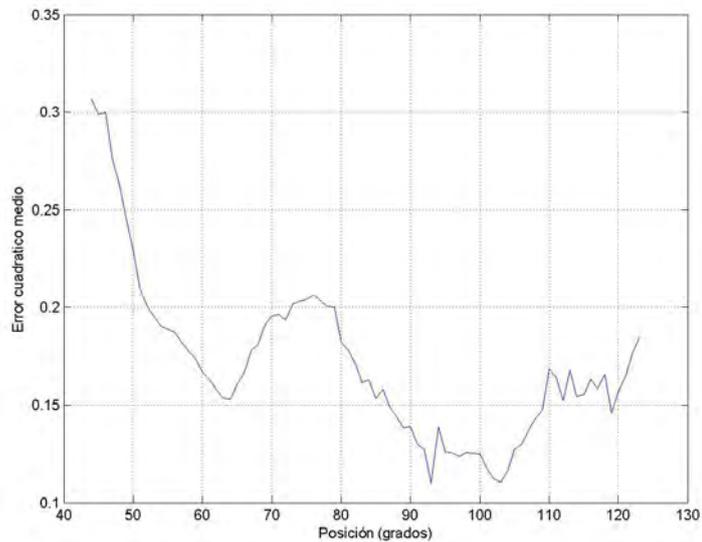


Figura 5.42: Error cuadrático medio

## 5.8. Experimentación sobre una esquina cóncava de 90 grados.

Después del caso general descrito en la sección anterior se incluye a continuación otro ejemplo para validar el modelo programado en este caso analizando el caso de una esquina cuadrada. Se ha seleccionado este tipo de esquinas por ser éstas las que más comúnmente aparecen en entornos interiores, ya que este modelo está pensado para ayudar a la navegación autónoma de los robots

en entornos interiores estructurados.

Para comprobar su validez se muestra igualmente una comparativa entre los ecos obtenidos a partir del modelo programado y los ecos obtenidos de un experimento real para un barrido angular mediante un par de sensores emisor-receptor situados frente a la esquina cóncava formando un ángulo de noventa grados entre sus paredes. Se sitúa el par emisor-receptor centrado angularmente en la esquina a una distancia de 50 cm de la unión de las dos paredes. Se parte de la situación de los sensores totalmente enfrentados a una de las paredes de la esquina y se va girando el par emisor-receptor hasta que se encuentra totalmente enfrentado a la otra pared de la esquina.

Se incluyen a continuación las figuras 5.43 a 5.51 donde puede verse en la parte superior de cada gráfica la representación de la posición entre el par de sensores emisor-receptor respecto de la esquina, los patrones de radiación y los caminos resultantes de cada una de las reflexiones existentes siguiendo el mismo patrón de colores que en el ejemplo anterior. Y en la parte inferior de las figuras se puede ver representada la comparativa, para cada una de las posiciones, entre la señal real obtenida y los ecos resultantes del modelo, donde se muestra en verde los ecos experimentales reales y en azul los ecos obtenidos a través del modelo programado. Se incluye también, en color cian, la señal de excitación del sensor, para poder calcular los tiempos de vuelo.

Igualmente que en el ejemplo anterior, para reducir el volumen de las gráficas se ha seleccionado la parte del barrido que comienza donde se deja de ver la primera pared únicamente y empieza a recibirse información de la esquina, y termina donde solamente se recibe información de la segunda pared. También por el mismo motivo se muestran los resultados a intervalos de diez grados.

Para tener una mejor visualización de la diferencia existente entre el caso real y el del modelo se incluyen a continuación las figuras 5.52 a 5.60 correspondientes a los mismos casos de las figuras 5.43 a 5.51 a pero mostrando únicamente las envolventes del eco real, en verde, y las envolventes del eco resultante del modelo programado, en azul. Así mismo en rojo, se muestra la curva del error como diferencia entre las dos curvas anteriores.

5.8. Experimentación sobre una esquina cóncava de 90 grados.

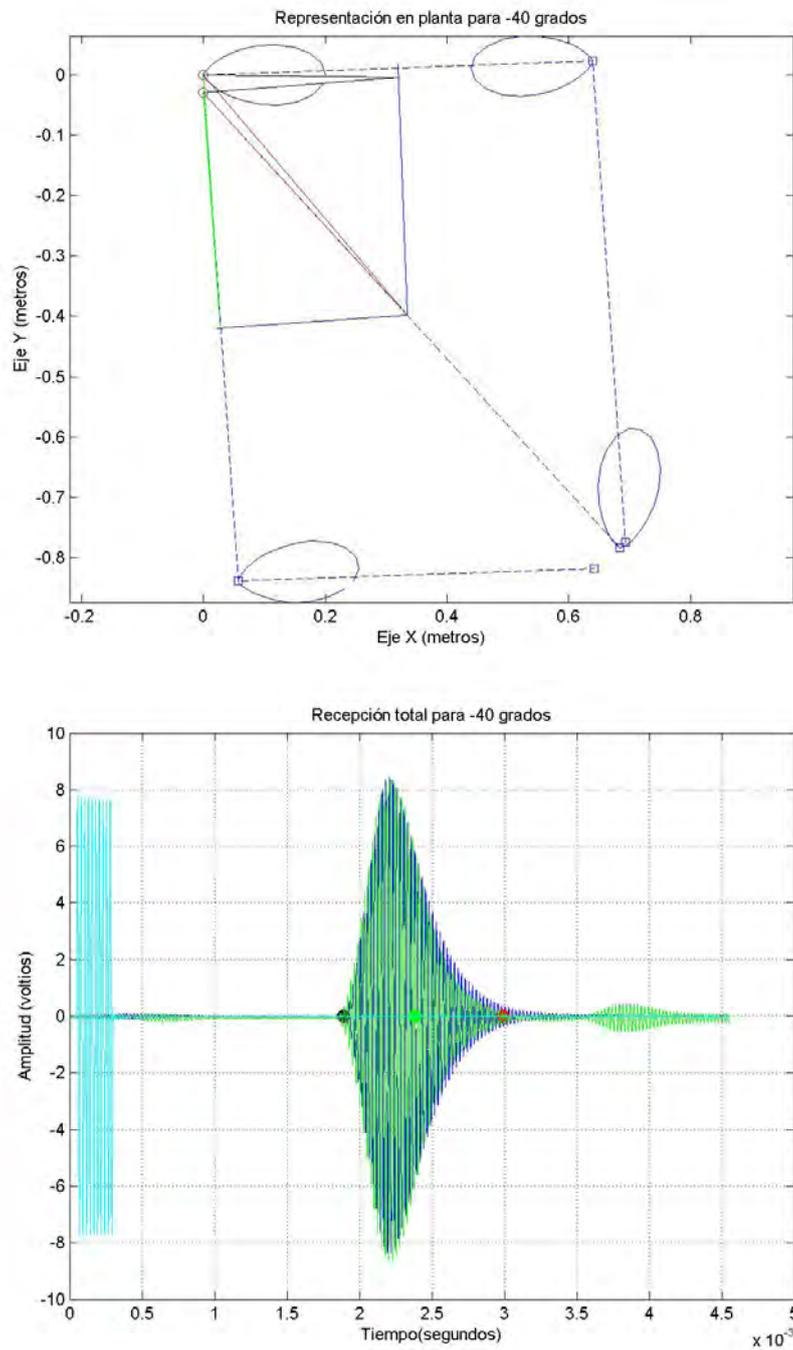


Figura 5.43: Inclinación de -40 grados

5. Modelo de transmisión de las ondas ultrasónicas.

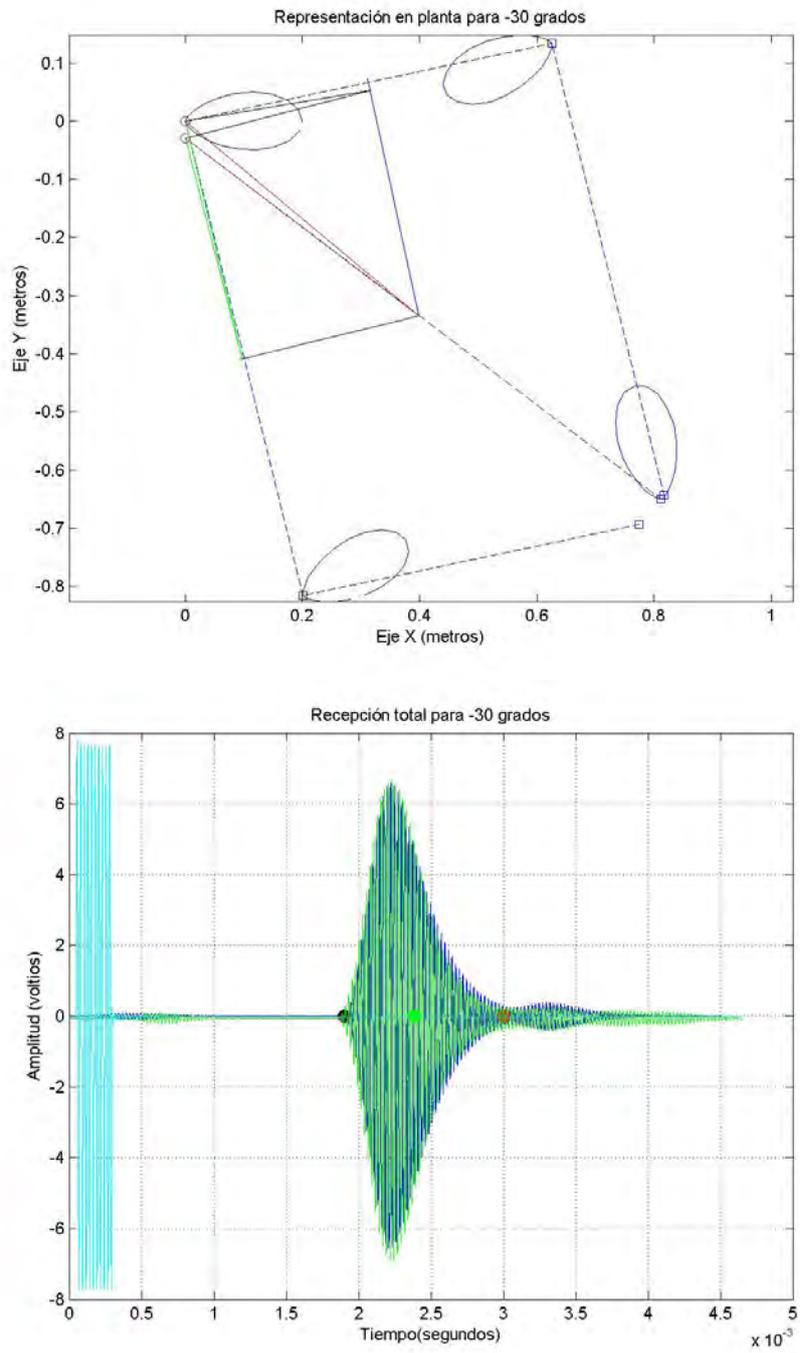


Figura 5.44: Inclinación de -30 grados

5.8. Experimentación sobre una esquina cóncava de 90 grados.

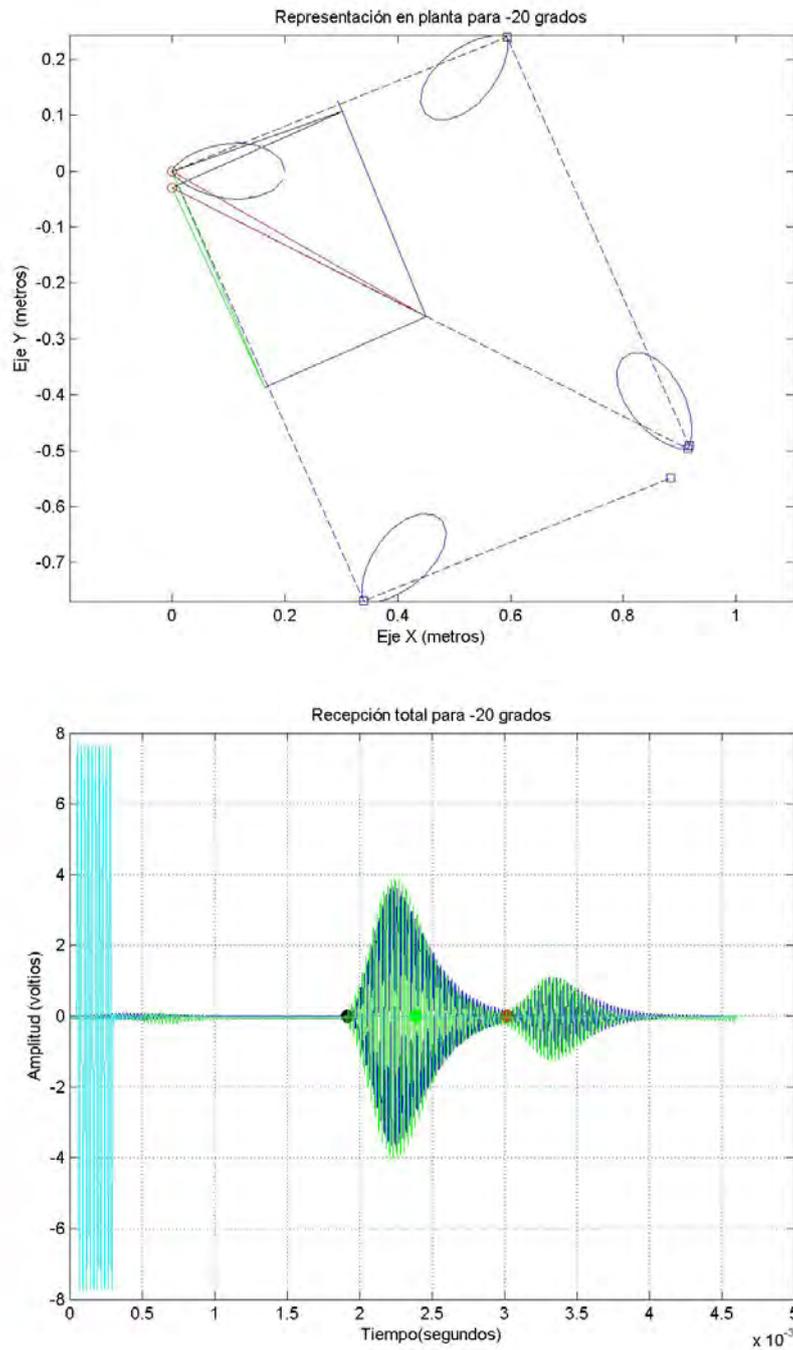


Figura 5.45: Inclinación de -20 grados

5. Modelo de transmisión de las ondas ultrasónicas.

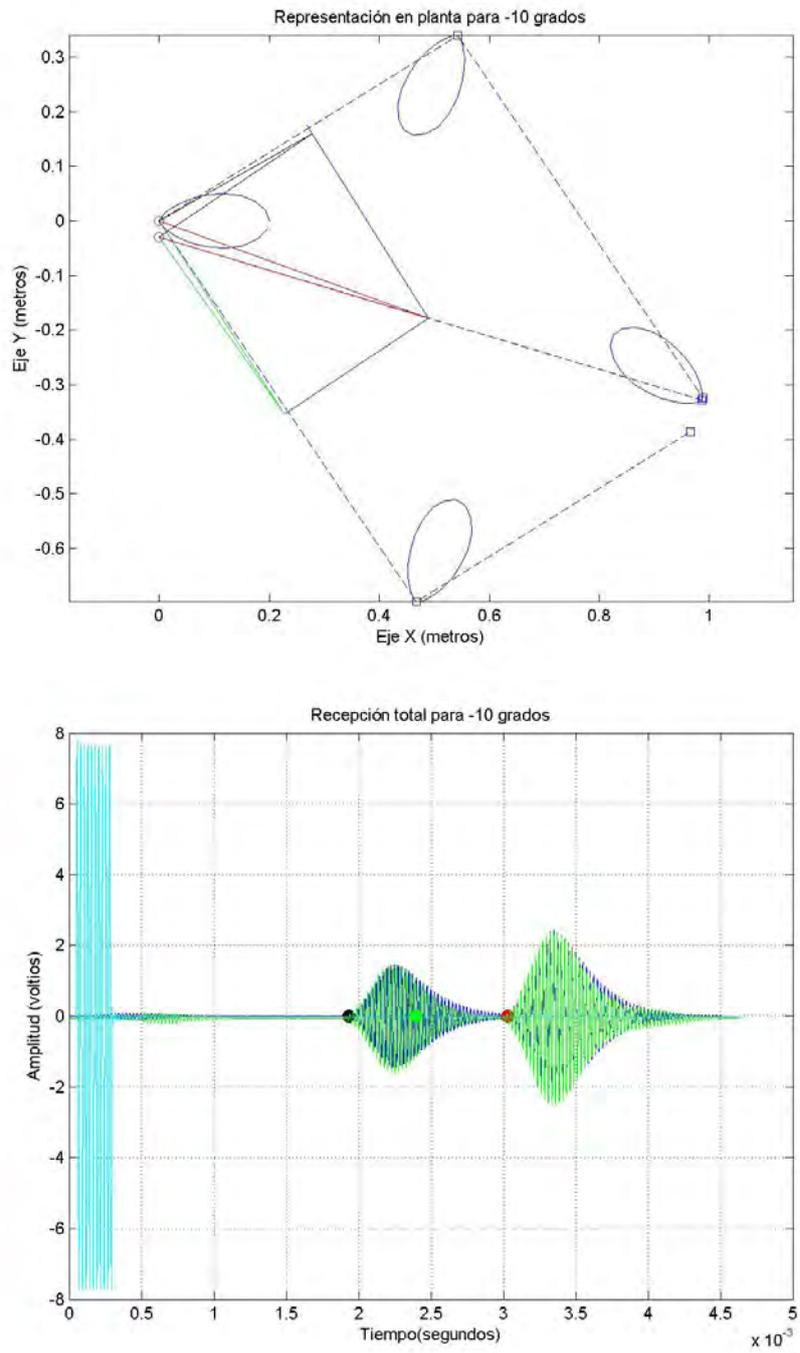


Figura 5.46: Inclinación de -10 grados

5.8. Experimentación sobre una esquina cóncava de 90 grados.

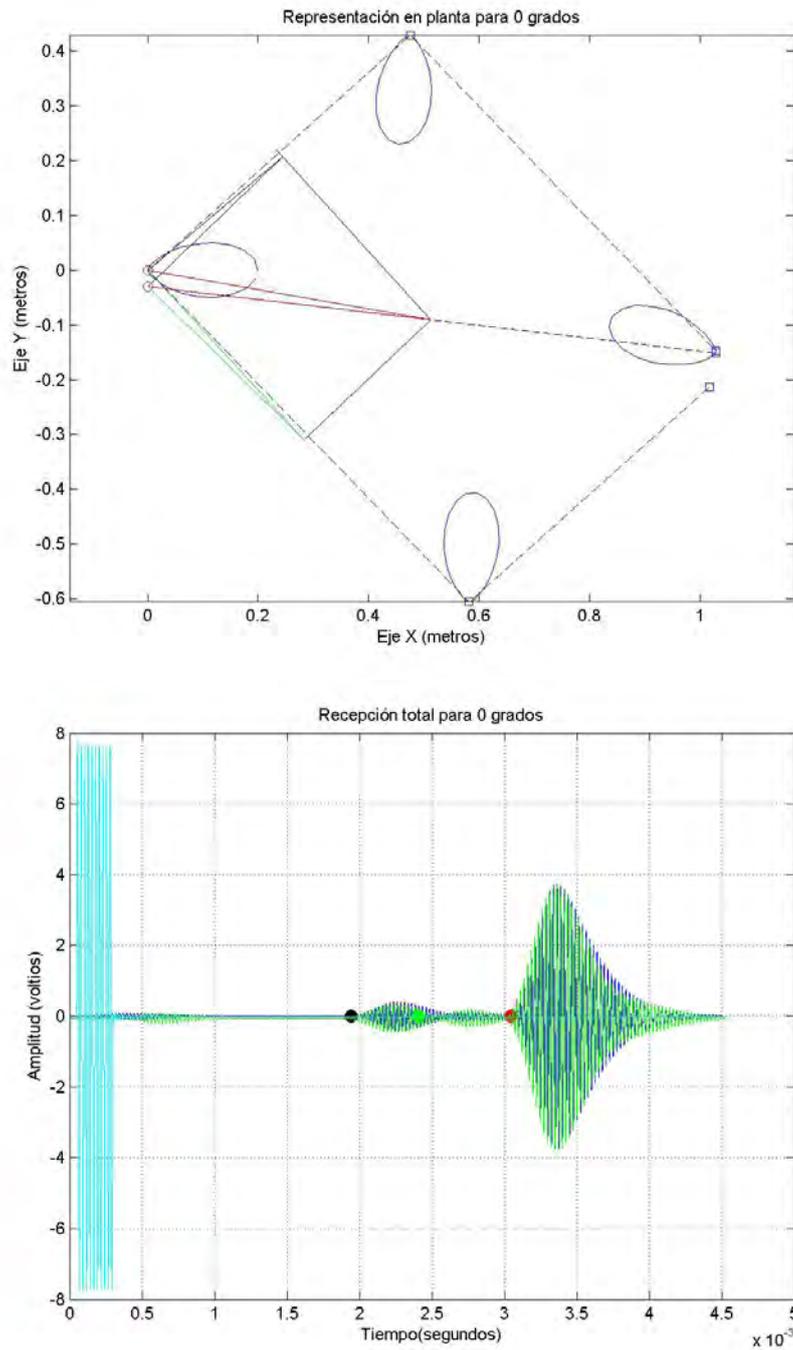


Figura 5.47: Inclinación de 0 grados

5. Modelo de transmisión de las ondas ultrasónicas.

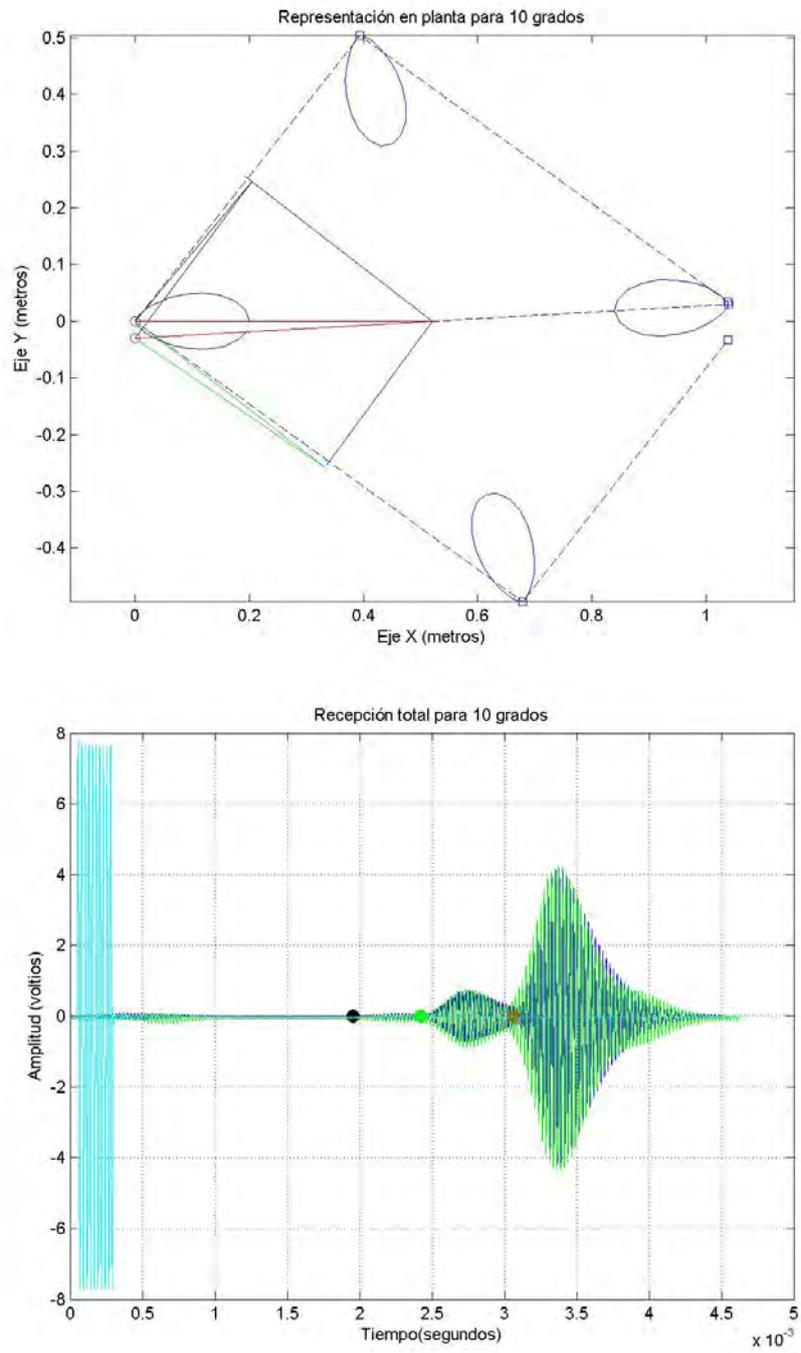


Figura 5.48: Inclinación de 10 grados

5.8. Experimentación sobre una esquina cóncava de 90 grados.

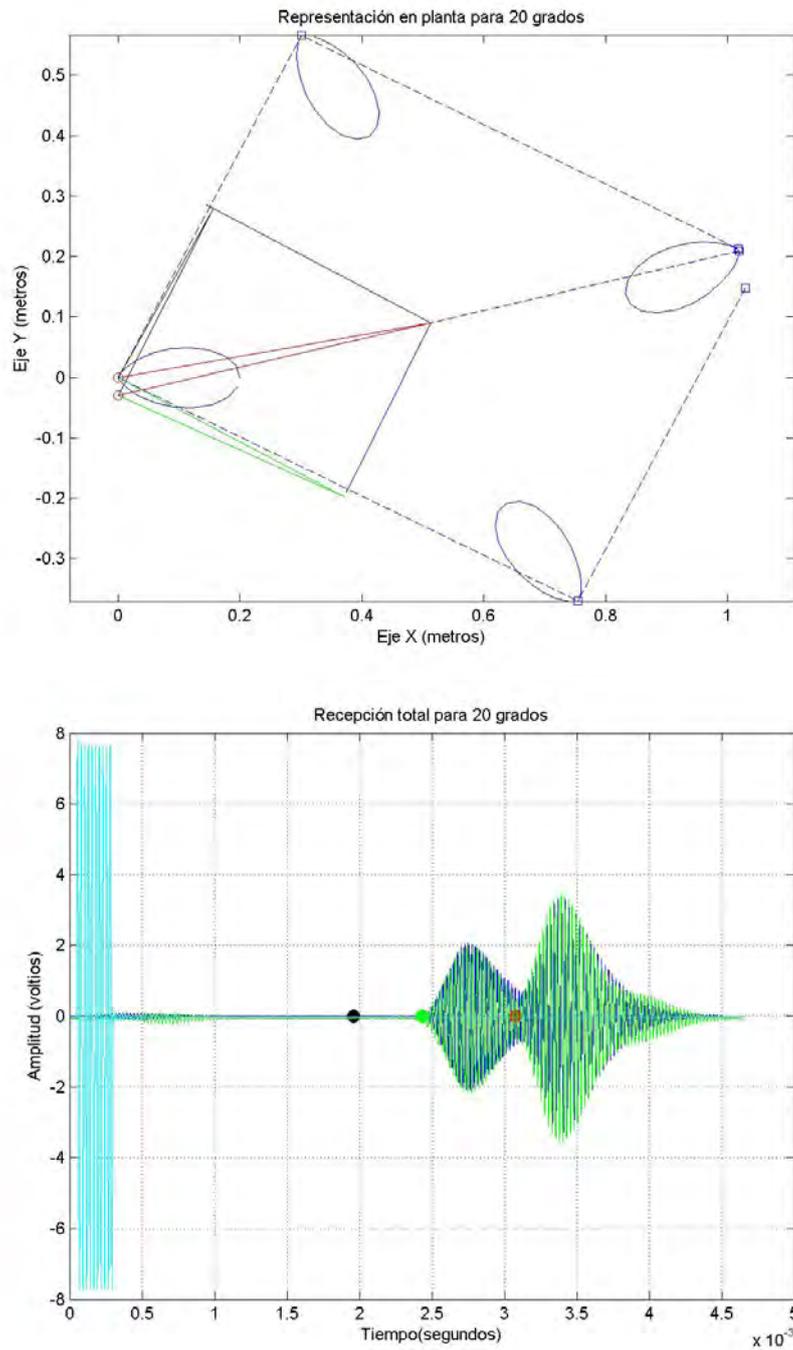


Figura 5.49: Inclinación de 20 grados

5. Modelo de transmisión de las ondas ultrasónicas.

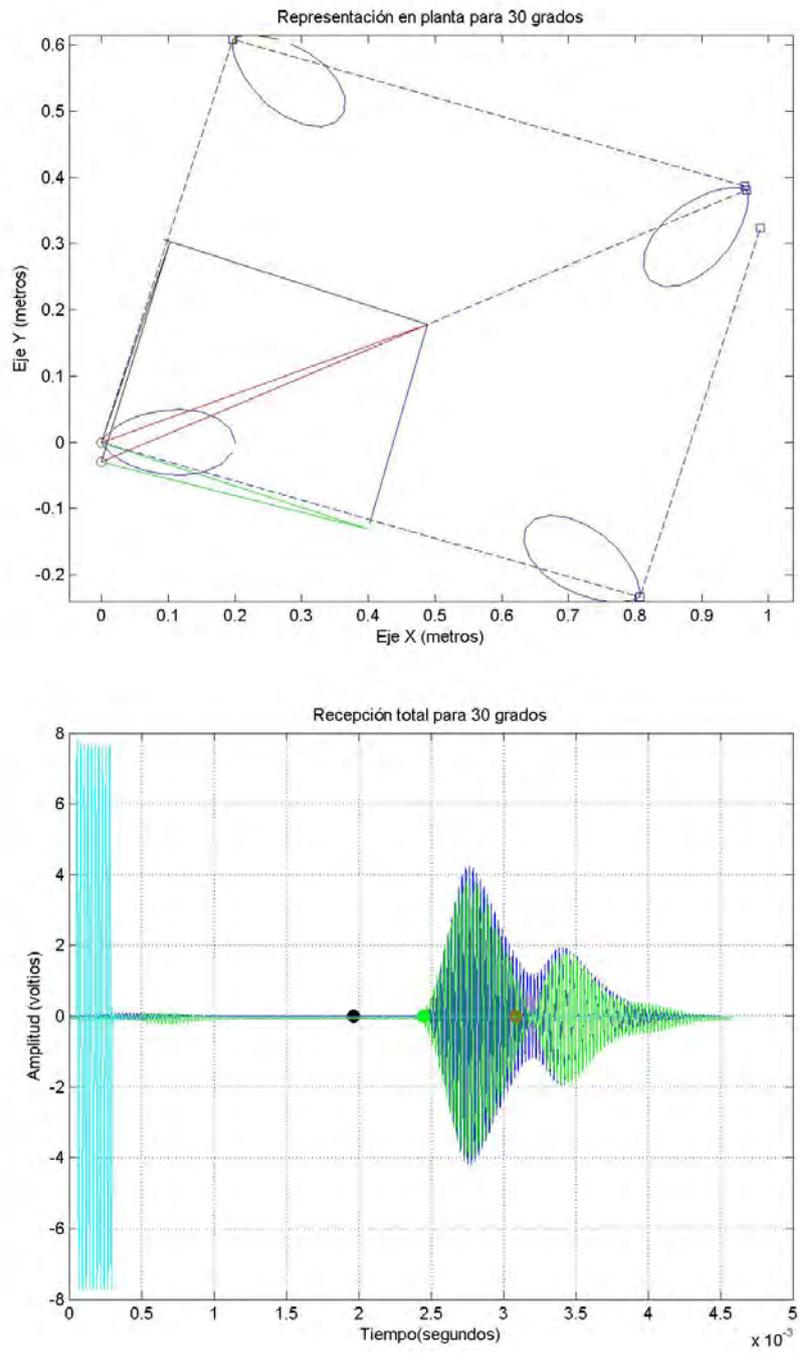


Figura 5.50: Inclinación de 30 grados

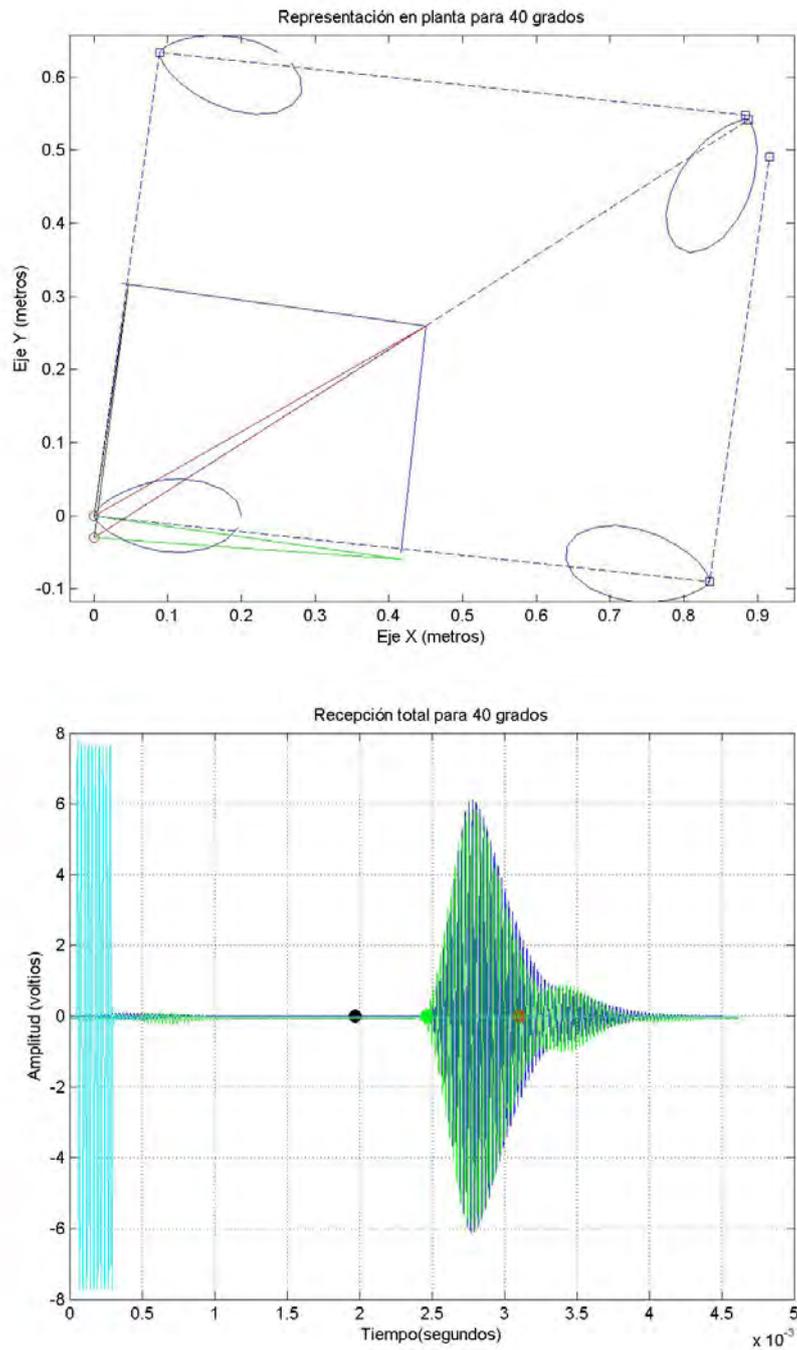


Figura 5.51: Inclinación de 40 grados

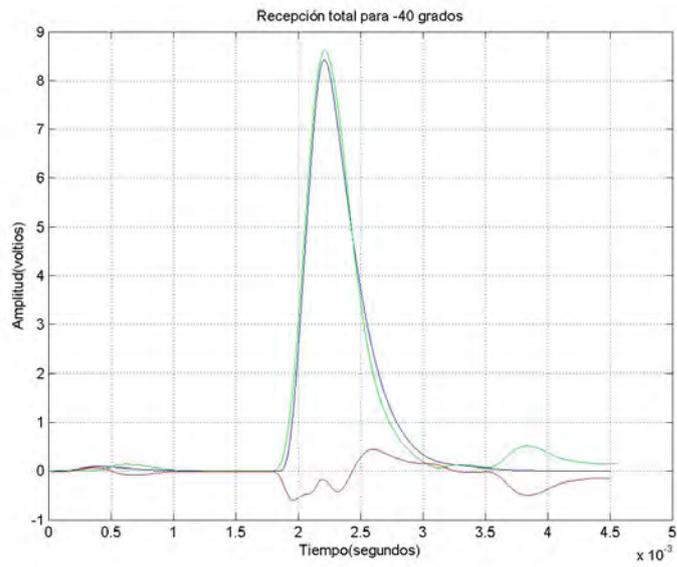


Figura 5.52: Envolventes y error para -40 grados

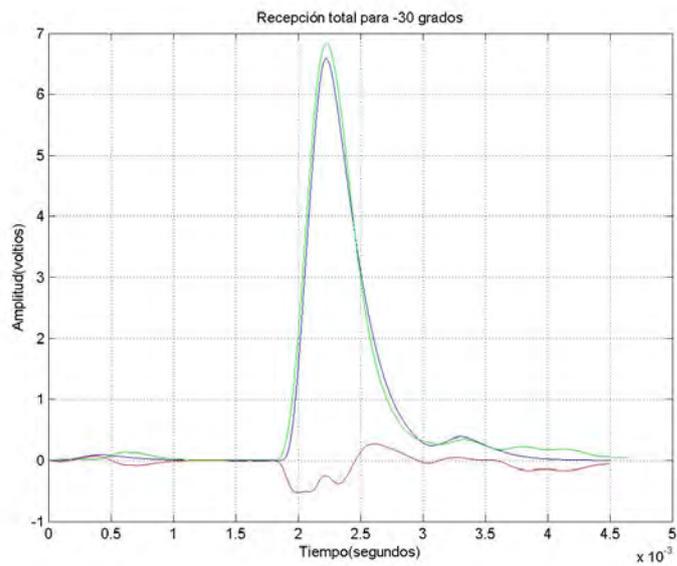


Figura 5.53: Envolventes y error para -30 grados

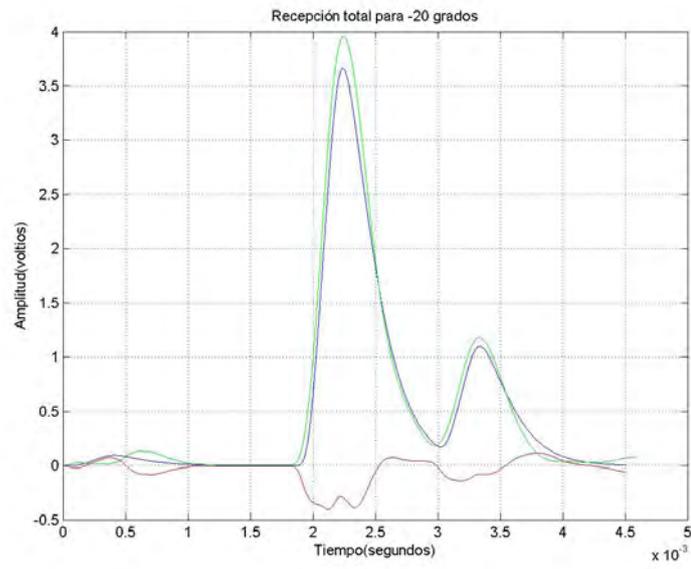


Figura 5.54: Envoltentes y error para -20 grados

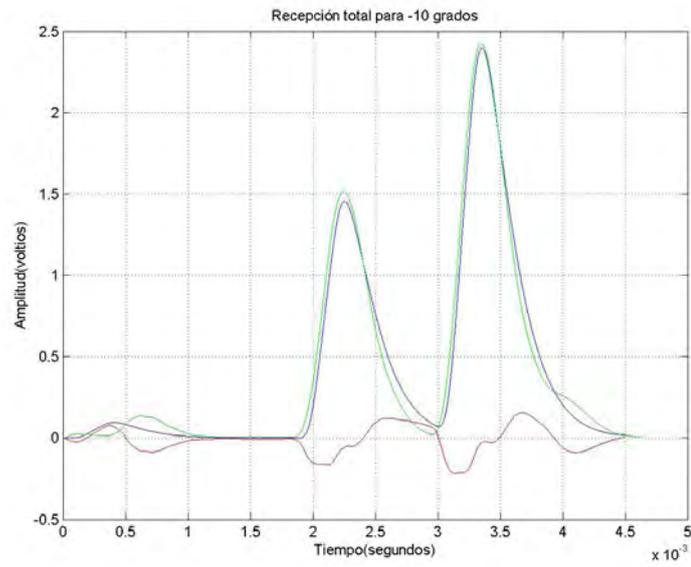


Figura 5.55: Envoltentes y error para -10 grados

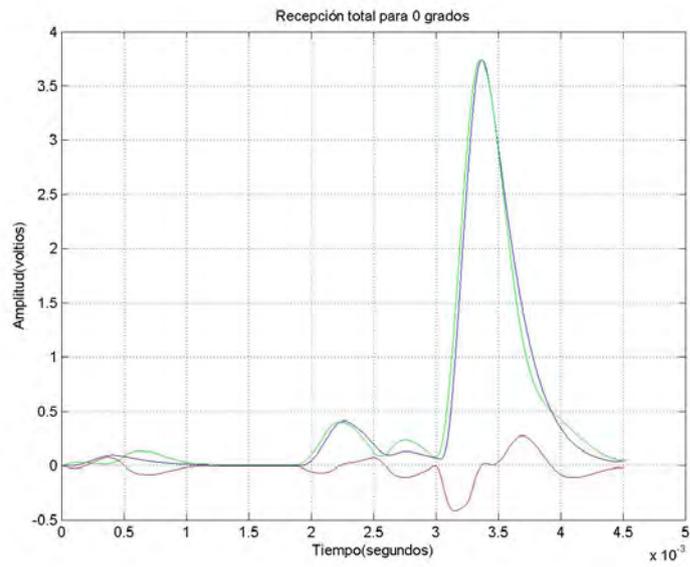


Figura 5.56: Envoltentes y error para 0 grados

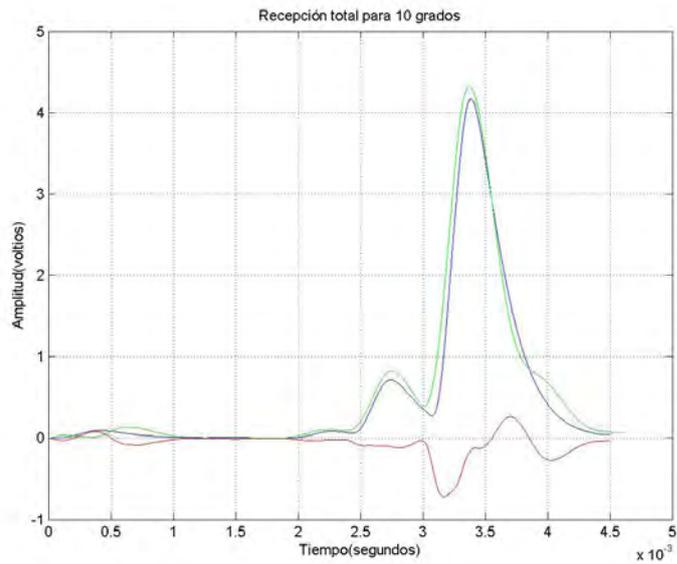


Figura 5.57: Envoltentes y error para 10 grados

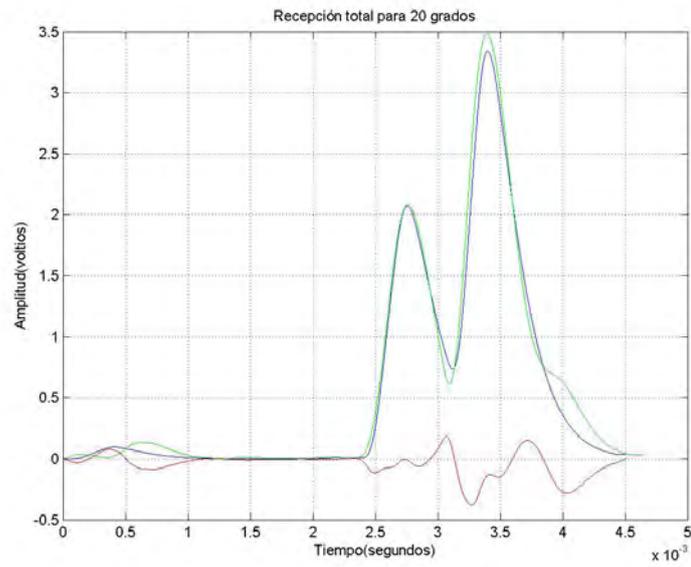


Figura 5.58: Envoltentes y error para 20 grados

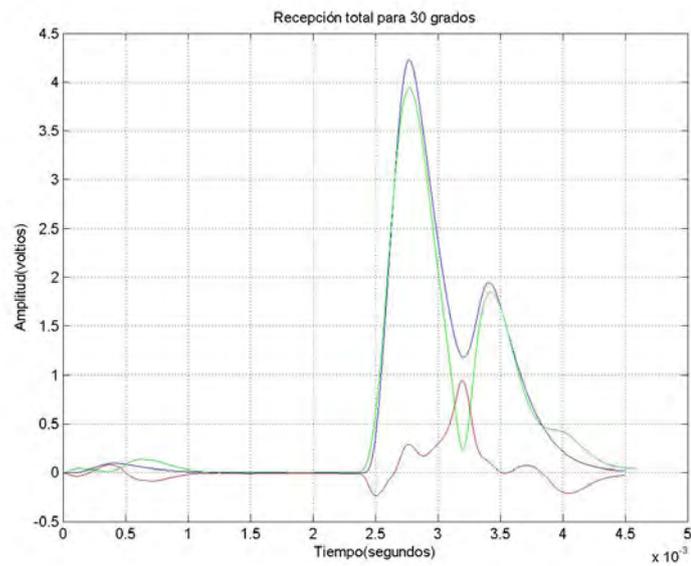


Figura 5.59: Envoltentes y error para 30 grados

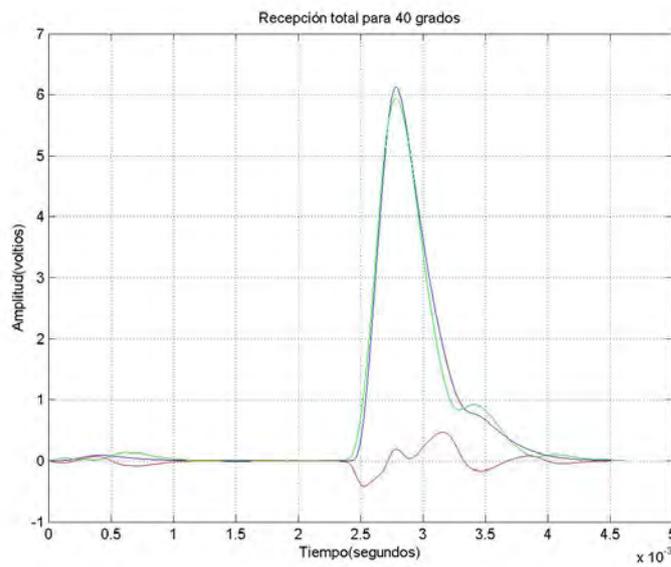


Figura 5.60: Envolventes y error para 40 grados

Se incluye a continuación en la figura 5.61 una gráfica con los valores de los errores cuadráticos medios según las expresiones 5.35 y 5.36 para desplazamientos de un grado desde la posición inicial a la final.

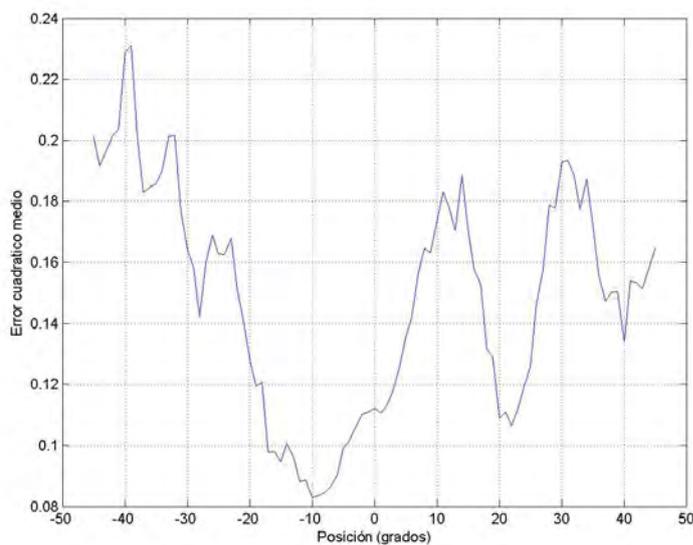


Figura 5.61: Errores cuadráticos medios de cada posición angular

## 5.9. Efecto del ángulo de apertura de la esquina cóncava.

En este apartado se pretende analizar el efecto que tiene el ángulo de apertura de una esquina cóncava sobre la forma del eco recibido. Se ha visto que el eco resultante del rebote de un pulso ultrasónico sobre una esquina cóncava está formado por la suma de cinco diferentes subecos. Los dos primeros provenientes de los rebotes directos sobre cada una de las dos paredes que forman la esquina. Los dos siguientes rebotes debidos a la reflexión sobre la primera pared seguida de la reflexión sobre la segunda y lo mismo en el caso de la reflexión en primer lugar sobre la segunda pared seguida de la reflexión sobre la primera. Y un quinto subeco debido al rebote justo sobre el borde de la esquina. Esta última aportación a la señal total del eco recibido es la que se pretende analizar en este apartado.

En el punto de unión de las dos paredes se produce un fenómeno de reflexión dispersa que difiere de la reflexión especular que se produce sobre las superficies planas.

Para su análisis se han tomado datos experimentalmente de esquinas con diferentes ángulos de apertura y con diferentes posiciones respecto al par de sensores emisor-receptor con la intención de aislar, lo más independientemente posible, el efecto del rebote del eco sobre la esquina del efecto de los segundos rebotes. Para ello se ha realizado una batería de experimentos considerando esquinas con ángulos de apertura que van desde los 60 grados hasta los 120 grados con incrementos de 10 grados. Se ha limitado el análisis a este rango de aperturas por las limitaciones físicas del montaje experimental que se muestra en la figura 5.24. Se ha situado el sensor emisor, en todos los casos, enfrente a la esquina a una distancia de 50 cm de ella y simétricamente situado respecto a las dos paredes. En esta situación el sensor receptor se ha ido situando a distancias de 3 cm, 6 cm y 12 cm respecto del sensor emisor para obtener diferentes recorridos de los rebotes del eco. Para cada una de estas situaciones se ha excitado el sensor emisor con un pulso de diez ciclos de señal de emisión y se ha capturado la señal en el sensor receptor.

A continuación se muestran tres ejemplos de los ensayos realizados y los resultados obtenidos. De todos los casos analizados se han seleccionado una serie de ellos en los que las distancias de los diferentes subecos que componen el eco sean lo suficientemente diferentes para que no se solapen totalmente y pueda apreciarse su efecto individual de la mejor forma posible.

### 5.9.1. Caso de esquina formada por dos paredes formando un ángulo de 60 grados.

Se plantean a continuación tres ejemplos experimentales para la validación del modelo sobre una esquina cuyas paredes forman un ángulo de 60 grados entre sí. Se busca encontrar el valor de ganancia correspondiente al subeco recibido de la unión de las dos paredes que modele la atenuación o amplificación de señal que se produzca en la esquina debido a la reflexión dispersa. Se han analizado los casos correspondientes a separaciones entre los sensores emisor y receptor de 3 cm, 6 cm y 12 cm, buscando encontrar una ganancia común a los tres casos. Así mismo las distancias correspondientes a los tiempos de vuelo de los cinco subecos permiten que el eco correspondiente al rebote justo sobre la esquina no se solape con los demás y se pueda analizar su aportación de forma independiente. En todos los casos se sitúa la esquina en torno a los 50 cm del emisor y centrado angularmente respecto a las dos paredes que forman la esquina.

En primer lugar se va a mostrar en que el par de sensores emisor-receptor se encuentran separados 3 cm entre sí. Se describe en la tabla 5.3 la situación real de la esquina respecto al sistema sensor. En dicha tabla se indican las distancias a las que se encuentran las paredes y el punto de unión de las dos paredes que forman la esquina respecto al emisor. Considerando que el emisor se encuentra en las coordenadas (0,0) para una vista en planta del montaje, se indican las coordenadas correspondientes a la esquina y a un punto de cada plano que representa cada una de las paredes y que dejan definida su posición respecto al sensor emisor. El sensor receptor se encuentra situado sobre el eje y negativo a una distancia de 3 cm. Puede verse dicha disposición en la figura 5.62.

Distancia del sensor emisor a la pared 1:	26.1 cm
Distancia del sensor emisor a la esquina:	52 cm
Distancia del sensor emisor a la pared 2:	26.1 cm
Distancia entre emisor y receptor:	3 cm
Angulo entre las dos paredes de la esquina:	60 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.1305 + 0.2260i$
Coordenadas de la esquina: r1_p2	$0.52+0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.1305 - 0.2260i$

Tabla 5.3: Coordenadas y posición de la esquina de 60 grados con 3 cm de separación

Además de la representación en planta de la situación del par emisor-receptor respecto de la esquina, también se representan en la figura 5.62 las fuentes virtuales correspondientes a los cinco subecos. Se representa mediante rayos los recorridos realizados por las ondas ultrasónicas desde que parten del sensor emisor para cada reflexión, con su punto de contacto y la llegada de dichos rayos al sensor receptor. Se muestran también los patrones de los lóbulos de radiación de los sensores y sus fuentes imagen. En color negro puede verse el recorrido para la reflexión sobre la pared 1, en verde sobre la pared 2, en rojo la reflexión dispersa en la unión de las dos paredes, en cian la reflexión doble primero sobre la pared 1 y después sobre la pared 2, y en amarillo la reflexión doble primero sobre la pared 2 y después sobre la pared 1.

Puede observarse desde la figura 5.63 a la 5.67 las aportaciones individuales de los cinco subeco de que está formada la señal recibida en el sensor receptor. En la figura 5.68 se marca con un círculo el comienzo del subeco correspondiente a dicho color. Así aparece con un círculo negro el punto de comienzo del subeco debido al rebote sobre la pared 1, en color verde el correspondiente al rebote directo sobre la pared 2, en rojo el rebote correspondiente a la unión de las dos paredes, en cian el correspondiente al segundo rebote de la reflexión primero sobre la pared 1 y después sobre la pared 2, y por último con un círculo amarillo el segundo rebote de la reflexión primero sobre la pared 2 y después sobre la pared 1.

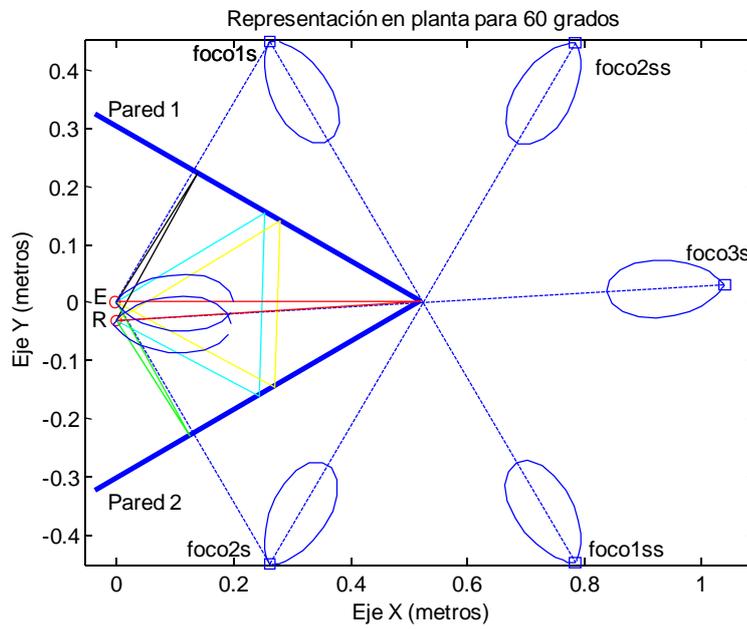


Figura 5.62: Representación en planta para esquina de 60 grados con 3 cm de separación entre sensores

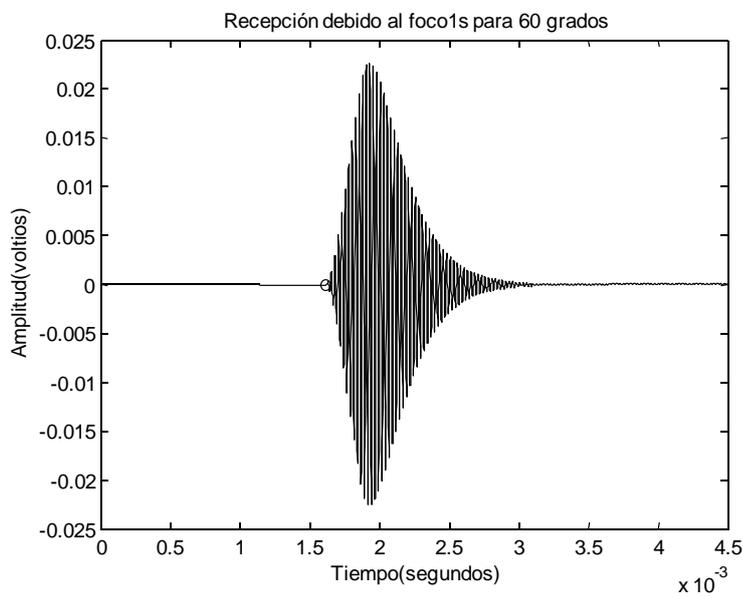


Figura 5.63: Reflexión directa en la pared 1 para esquina de 60gr con 3cm de separación

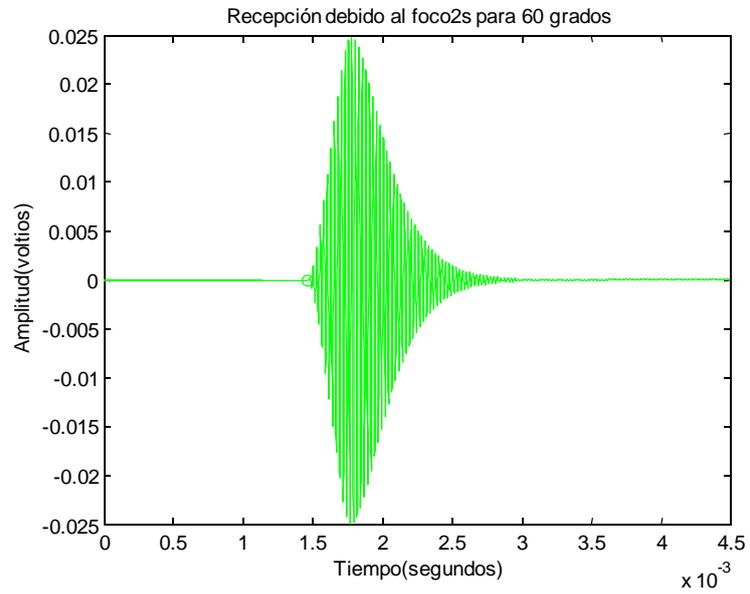


Figura 5.64: Reflexión directa en la pared 2 para esquina de 60gr con 3cm de separación

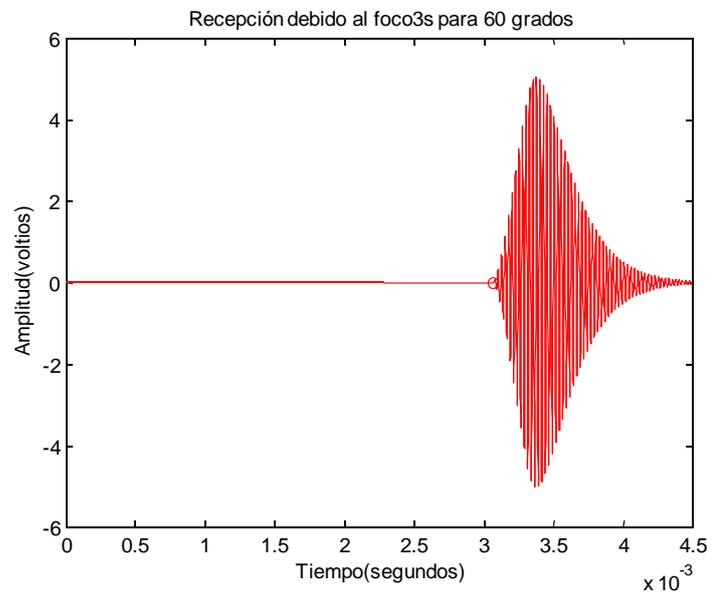


Figura 5.65: Reflexión directa en la unión de las dos paredes para esquina de 60gr con 3cm de separación

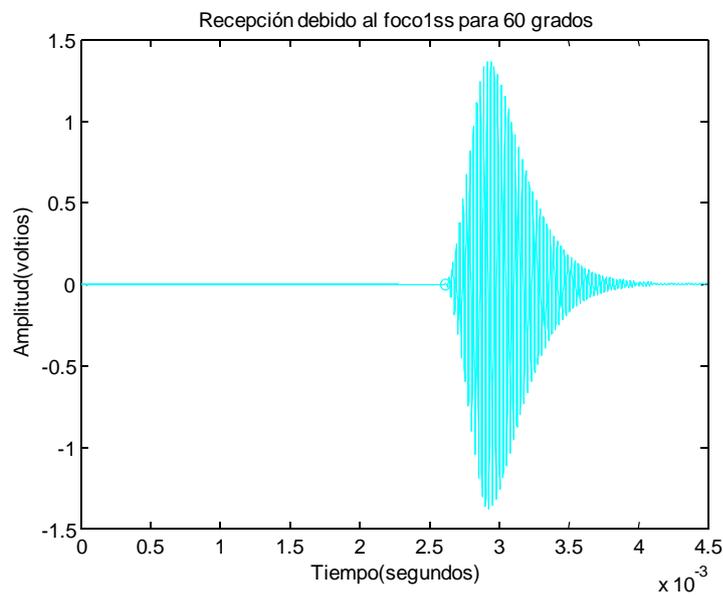


Figura 5.66: Reflexión primero en la pared 1 y después en la pared 2 para esquina de 60gr con 3cm de separación

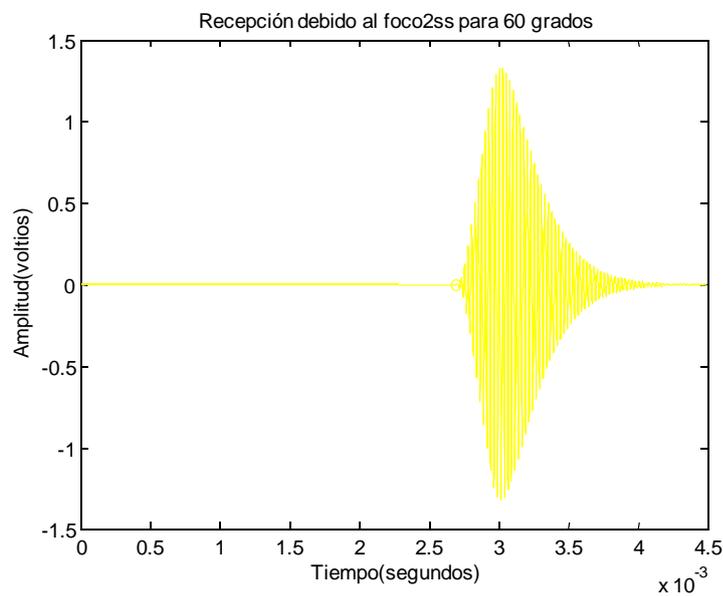


Figura 5.67: Reflexión primero en la pared 2 y después en la pared 1 para esquina de 60gr con 3cm de separación

Puede observarse en la figura 5.68 en verde el eco real capturado y en azul oscuro el obtenido con el modelo programado. Puede verse en este ejemplo, cómo las aportaciones de los subecos debidos al rebote directo sobre las paredes que forma la esquina son despreciables frente a los ecos debidos a los segundos rebotes y a la intersección de las paredes. Esto es debido a que al situar a los sensores enfocando a la esquina los rebotes directos de las paredes corresponden a señales muy atenuadas por el patrón de radiación de los sensores. Como puede observarse en la figura 5.62, los rayos parten y llegan a las zonas laterales del lóbulo de radiación que tiene una atenuación muy elevada.

También se puede observar en la figura 5.68 que los subecos debidos al  $foco_{1ss}$  y al  $foco_{2ss}$  están solapados, por lo que no se puede ver su efecto individual. En este caso al estar situado el sensor emisor centrado simétricamente respecto a las dos paredes estos dos ecos tienen prácticamente la misma distancia recorrida y presentan una amplitud muy similar, como puede verse en las figuras 5.66 y 5.67.

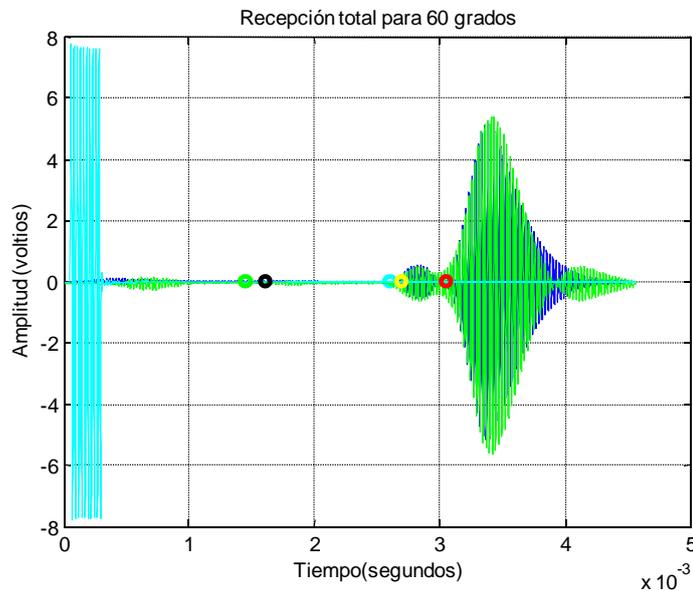


Figura 5.68: Eco completo para esquina de 60 grados con separación de 3 cm

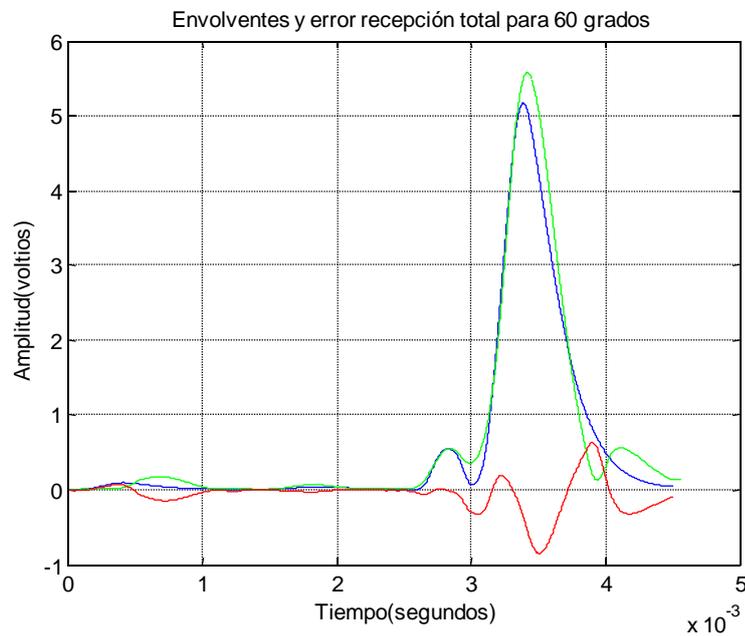


Figura 5.69: Envolventes y error para esquina de 60 grados con separación de 3 cm

Se incluye la figura 5.69 para una mejor comparación entre las respuestas real y del modelo, donde se representa en verde la envolvente del eco real capturado y en azul oscuro la envolvente del modelo experimental. Puede verse en rojo el error en cada punto entre el modelo y el eco real. Se ha comprobado que la ganancia empleada en el modelo experimental para el eco proveniente de la unión de las dos paredes coincide con la ganancia empleada para el resto de subecos, es decir, no se produce atenuación ni amplificación respecto a las demás aportaciones.

Aplicando las expresiones 5.35 y 5.36 a la señal del error representada por la línea roja se ha obtenido un error cuadrático medio de 0.2253.

Se comprueba ahora el mismo análisis para la esquina de 60 grados pero con una separación entre sensores de 6 cm. En este caso las distancias medidas experimentalmente a las paredes y las coordenadas de los puntos considerados de cada pared se muestran en la tabla 5.4.

Distancia del sensor emisor a la pared 1:	26.25 cm
Distancia del sensor emisor a la esquina:	51.54 cm
Distancia del sensor emisor a la pared 2:	26.25 cm
Distancia entre emisor y receptor:	6 cm
Ángulo entre las dos paredes de la esquina:	60 grados
Coordenadas de un punto de la pared 1: r1_p1	0.1312 + 0.2273i
Coordenadas de la esquina: r1_p2	0.5154+0i
Coordenadas de un punto de la pared 2: r2_p1	0.1312 - 0.2273i

Tabla 5.4: Coordenadas y posición de la esquina de 60 grados con 6 cm

A continuación se muestra en la figura 5.70 la representación en planta de la situación del par emisor-receptor respecto de la esquina, las fuentes virtuales correspondientes a los cinco subecos y sus correspondientes lóbulos de radiación y los caminos recorridos por cada uno de los subecos con su punto de contacto sobre la pared. Se mantiene en todos los ejemplos gráficos el mismo código de colores empleado en el primer ejemplo.

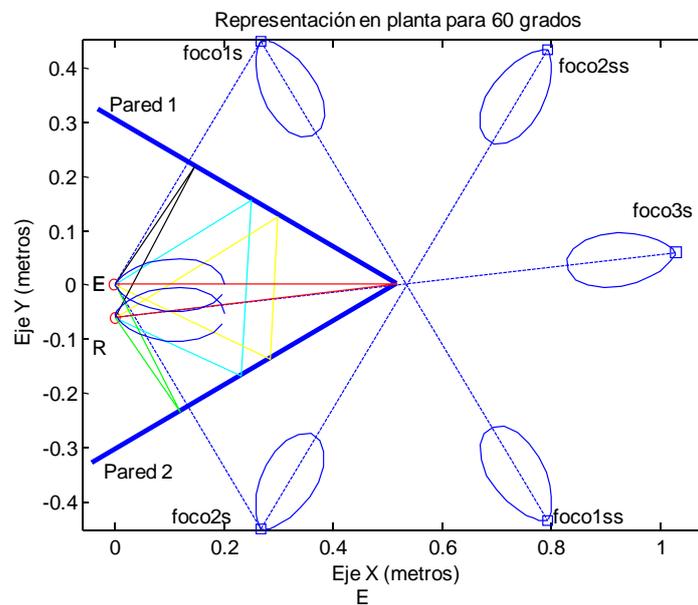


Figura 5.70: Representación en planta para esquina de 60 grados con 6 cm de separación entre sensores

Desde la figura 5.71 a la figura 5.75 pueden verse las aportaciones de los cinco subecos de forma individual. Igualmente que en el ejemplo anterior los rebotes directos sobre las dos paredes están muy atenuados por el ángulo de salida y llegada que presentan sobre el patrón de radiación del sensor. En cambio los segundos rebotes que se muestran en las figuras 5.74 y 5.75 se encuentran más separados entre sí debido a que se ha incrementado más la distancia en el recorrido del segundo rebote primero sobre la pared 2 y después sobre la pared 1, que el rebote primero sobre la pared 1 y después sobre la pared 2. También en este caso se puede observar la aportación del subeco sobre la esquina de forma independiente aunque algo más solapado. En este caso el error cuadrático medio obtenido ha sido de 0.1813.

Se repite ahora el mismo análisis para una separación entre sensores de 12 cm. Puede verse en la tabla 5.5 las distancias reales a las que se encuentran las paredes en el ensayo realizado y las coordenadas correspondientes a este caso. Y en la figura 5.78 la representación en planta de la situación del par emisor-receptor respecto de la esquina así como las fuentes virtuales correspondientes a los cinco subecos, caminos recorridos por los subecos y patrones de radiación.

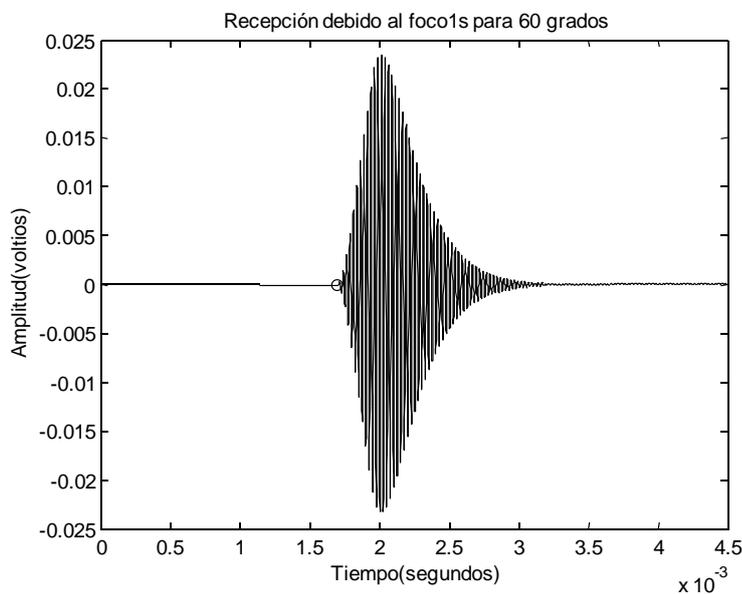


Figura 5.71: Reflexión directa en la pared 1 para esquina de 60 grados con 6 cm de separación

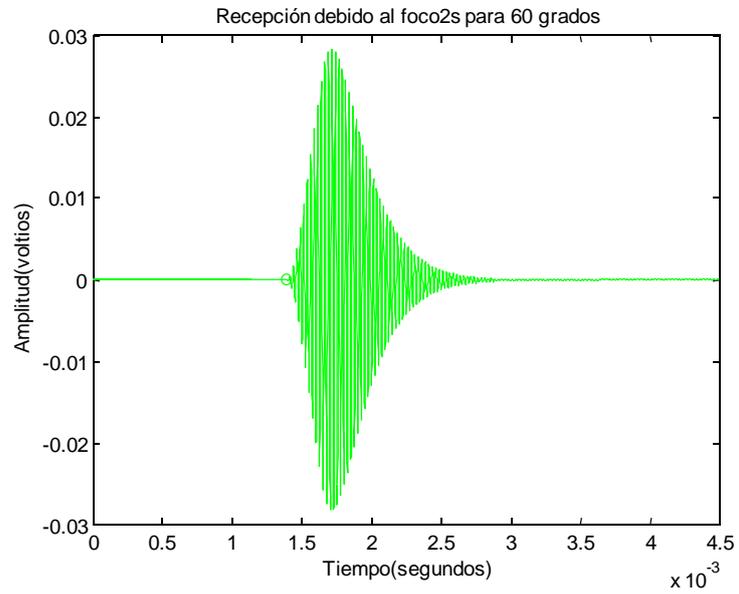


Figura 5.72: Reflexión directa en la pared 2 para esquina de 60 grados con 6 cm de separación

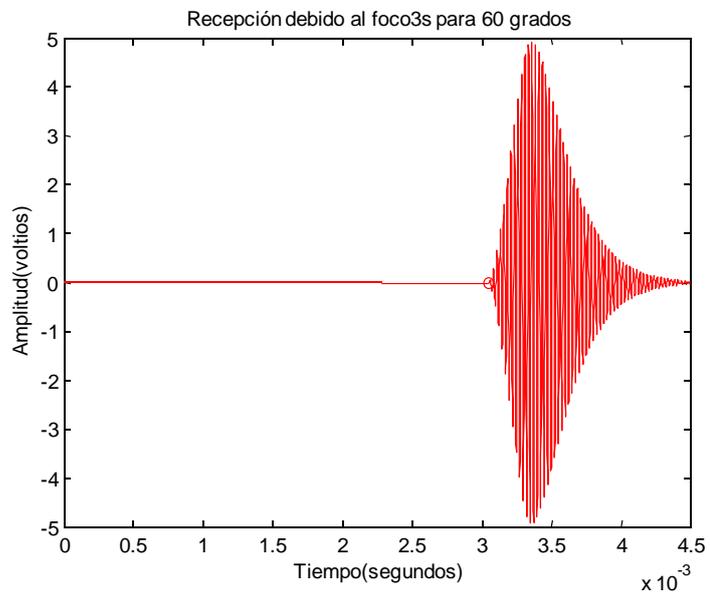


Figura 5.73: Reflexión directa en la unión de las dos paredes para esquina de 60 grados con 6 cm de separación

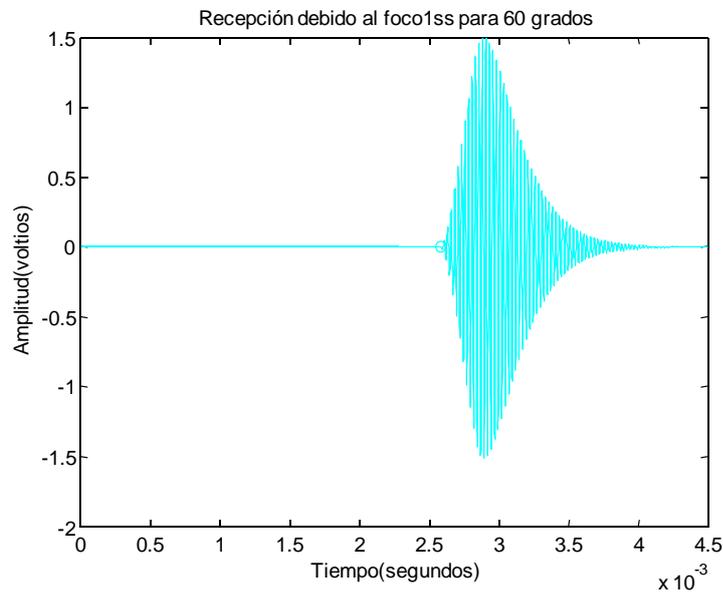


Figura 5.74: Reflexión primero en la pared 1 y después en la pared 2 para esquina de 60 grados con 6 cm de separación

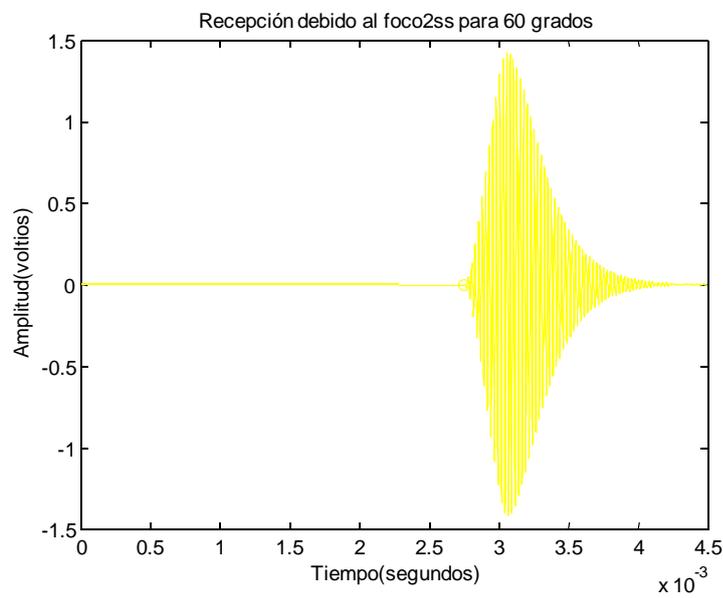


Figura 5.75: Reflexión primero en la pared 2 y después en la pared 1 para esquina de 60 grados con 6 cm de separación

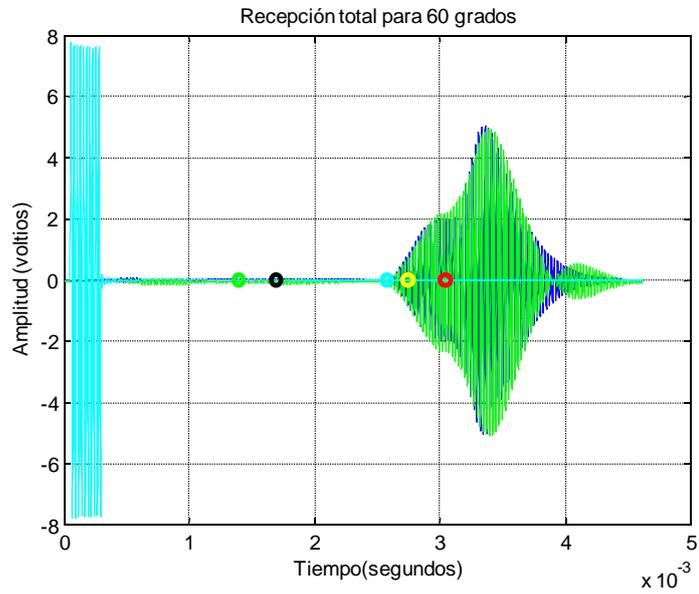


Figura 5.76: Eco completo para esquina de 60 grados con separación de 6 cm

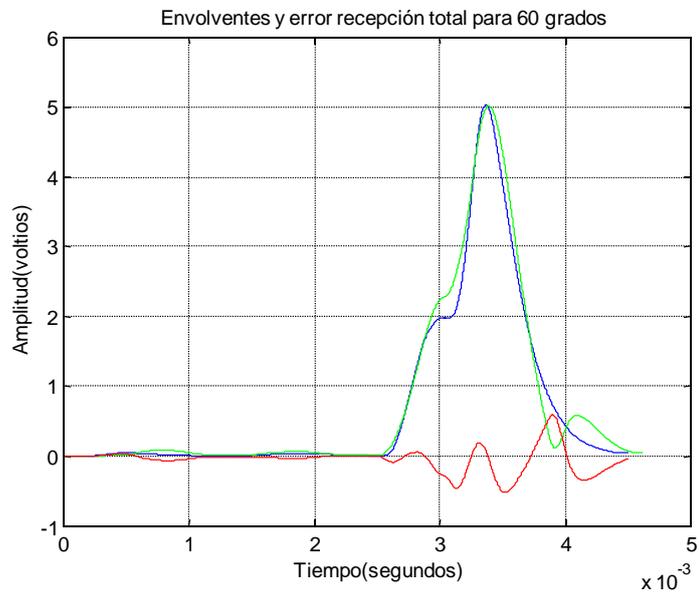


Figura 5.77: Envolturas y error para esquina de 60 grados con separación de 6 cm

Distancia del sensor emisor a la pared 1:	25.8 cm
Distancia del sensor emisor a la esquina:	51.3 cm
Distancia del sensor emisor a la pared 2:	25.8 cm
Distancia entre emisor y receptor:	12 cm
Ángulo entre las dos paredes de la esquina:	60 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.1290 + 0.2234i$
Coordenadas de la esquina: r1_p2	$0.5130+0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.1290 - 0.2234i$

Tabla 5.5: Coordenadas y posición de la esquina de 60 grados con 12 cm de separación

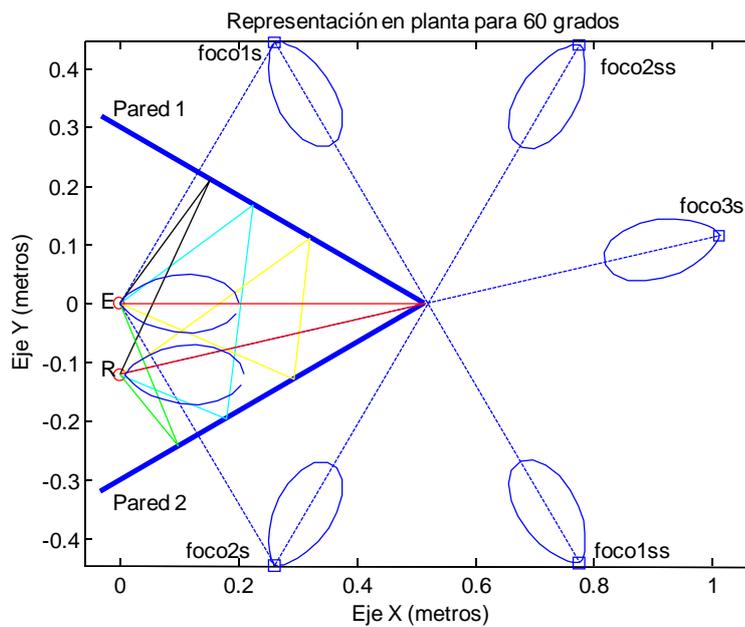


Figura 5.78: Representación en planta para esquina de 60 grados con 12 cm de separación entre sensores

Se incluyen a continuación desde la figura 5.79 hasta la figura 5.83 la representación gráfica de los cinco subecos que forman la respuesta, representados cada uno de ellos de forma independiente.

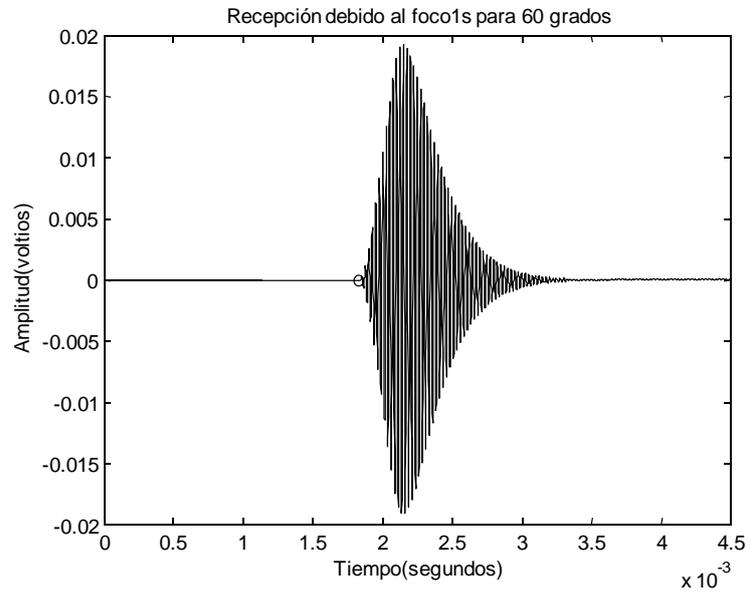


Figura 5.79: Reflexión directa en la pared 1 para esquina de 60 grados con 12 cm de separación

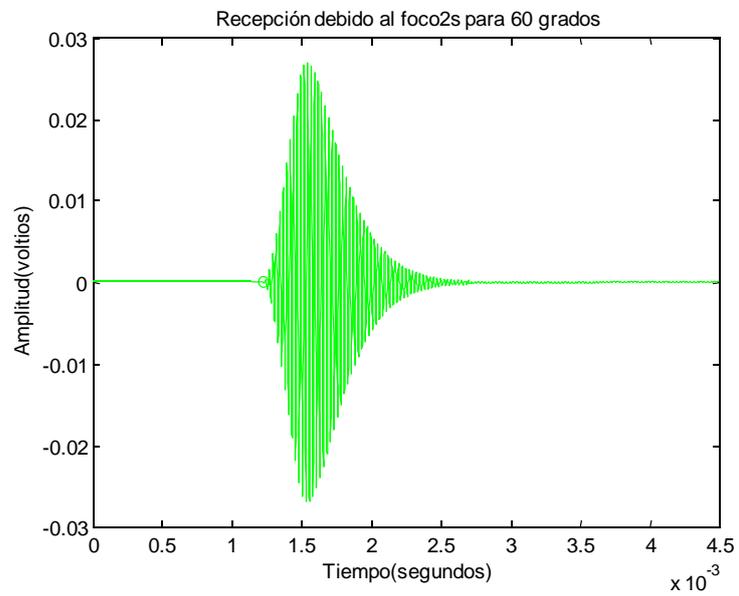


Figura 5.80: Reflexión directa en la pared 2 para esquina de 60 grados con 12 cm de separación

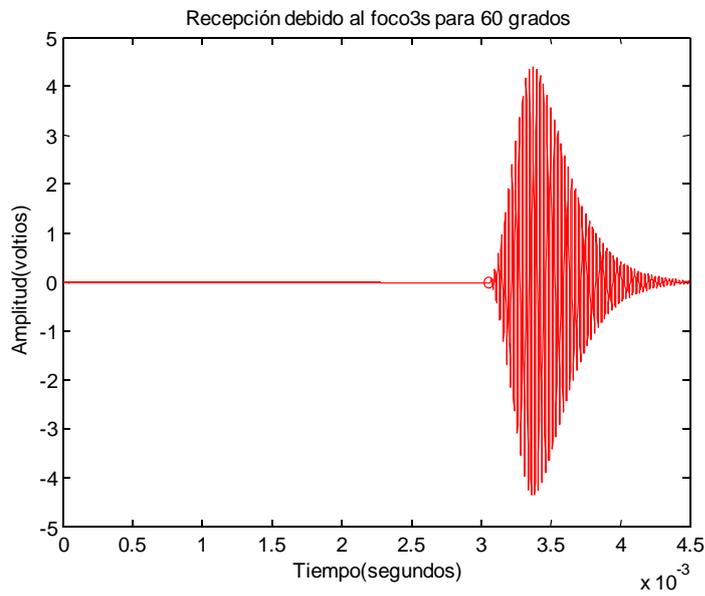


Figura 5.81: Reflexión directa en la unión de las dos paredes para esquina de 60 grados con 12 cm de separación

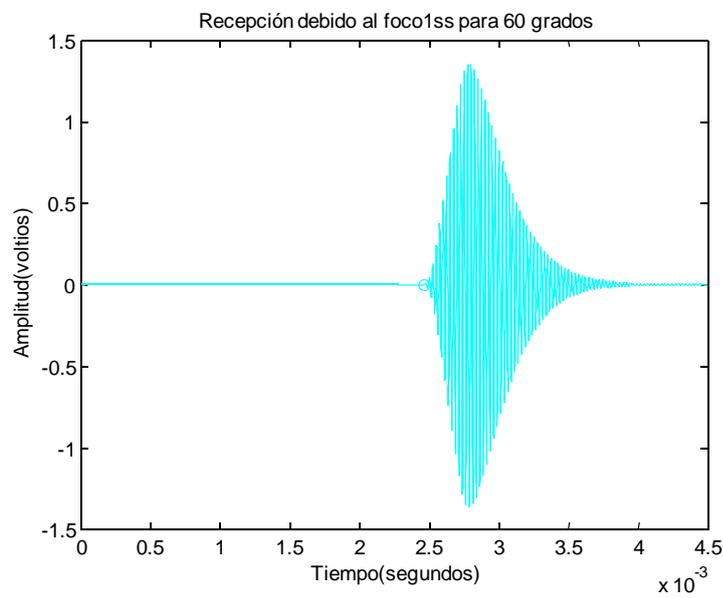


Figura 5.82: Reflexión primero en la pared 1 y después en la pared 2 para esquina de 60 grados con 12 cm de separación

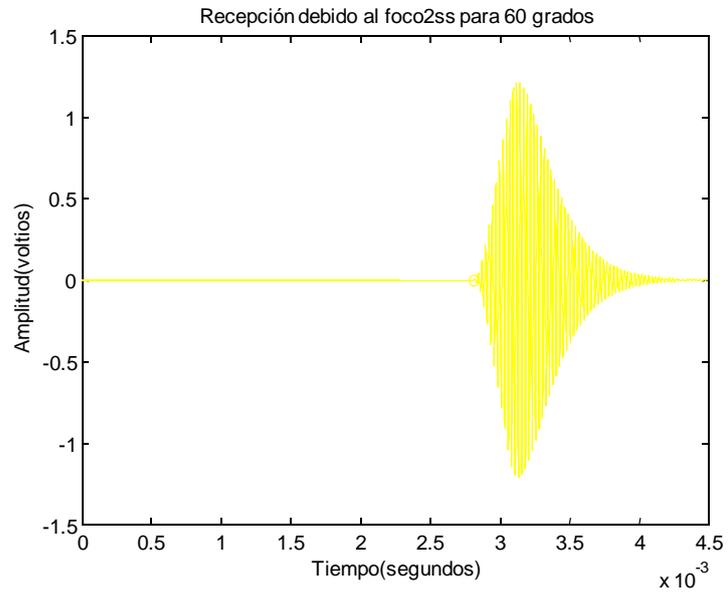


Figura 5.83: Reflexión primero en la pared 2 y después en la pared 1 para esquina de 60 grados con 12 cm de separación

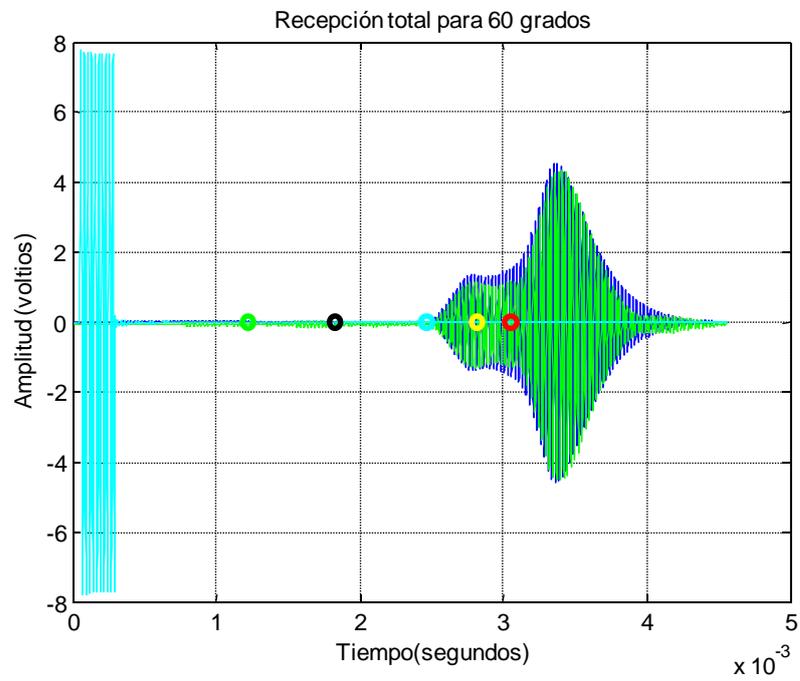


Figura 5.84: Eco completo para esquina de 60 grados con separación de 12 cm

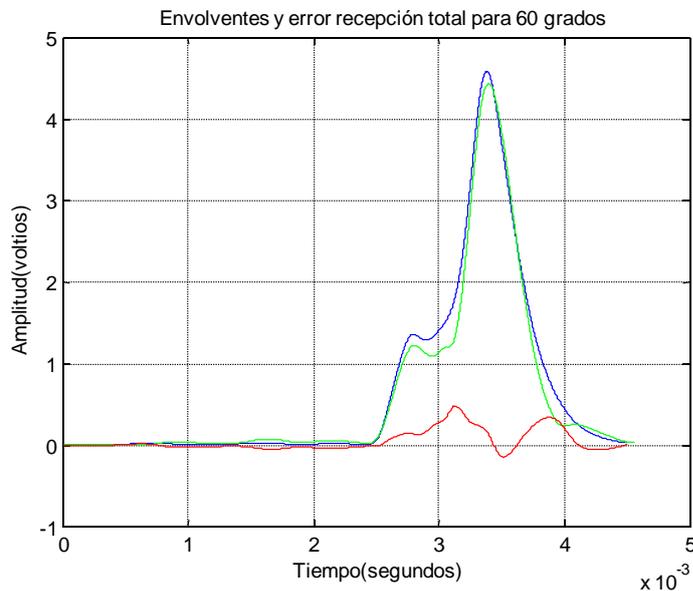


Figura 5.85: Envolventes y error para esquina de 60 grados con separación de 12 cm

Puede observarse en la figura 5.84 cómo los subecos de los segundos rebotes, en cian y amarillo, se separan aún más que en el caso anterior al separar la distancia entre el emisor y el receptor, pero siguen manteniendo la suficiente distancia con el subeco correspondiente al rebote directo sobre la pared, para no solaparse completamente y poderse ver su aporte de forma independiente.

Igualmente se muestran en la figura las envolventes del eco simulado, en azul, y el real, en verde, así como la diferencia entre ellas en rojo. Igualmente se calcula el error cuadrático medio del eco completo obteniéndose un valor de 0.1386.

En todos los casos la ganancia empleada para la señal proveniente del rebote directo sobre la esquina ha sido la misma que la empleada para los rebotes directos y para los segundos rebotes, con lo que se comprueba que la esquina se comporta como una pared normal.

### 5.9.2. Caso de esquina formada por dos paredes formando un ángulo de 90 grados.

Se incluye el mismo análisis para la esquina de 90 grados considerando los sensores separados 3, 6 y 12 cm entre sí. Como se ha comentado anteriormente este tipo de esquina es la más comúnmente encontrada en entornos estructurados.

En el caso de las esquinas de 90 grados no existen todos los segundos rebotes por lo que el problema se simplifica y puede verse el efecto de la reflexión dispersa en la unión sin mezclarse dicho subeco con otros procedentes de otros rebotes. Según la disposición física considerada como mucho aparece uno de los dos segundos rebotes o incluso hay casos en que no aparece ningún segundo rebote.

En primer lugar se analiza el caso con una separación entre sensores emisor y receptor de 3 cm. En esta configuración no aparece ningún segundo rebote. Puede verse en la figura 5.86 la representación en planta de la situación del par emisor-receptor respecto de la esquina, las fuentes virtuales correspondientes a los tres subecos, su patrones de radiación y los caminos recorridos por cada subeco.

En la tabla 5.6 se muestran las distancias mínimas a las paredes desde el sensor emisor así como las coordenadas de tres puntos de la esquina para la vista en planta.

Distancia del sensor emisor a la pared 1:	37.8 cm
Distancia del sensor emisor a la esquina:	52 cm
Distancia del sensor emisor a la pared 2:	37.2 cm
Distancia entre emisor y receptor:	3 cm
Ángulo entre las dos paredes de la esquina:	90 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.2673 + 0.2673i$
Coordenadas de la esquina: r1_p2	$0.52+0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.2630 - 0.2630i$

Tabla 5.6: Coordenadas y posición de la esquina de 90 grados con 3 cm de separación

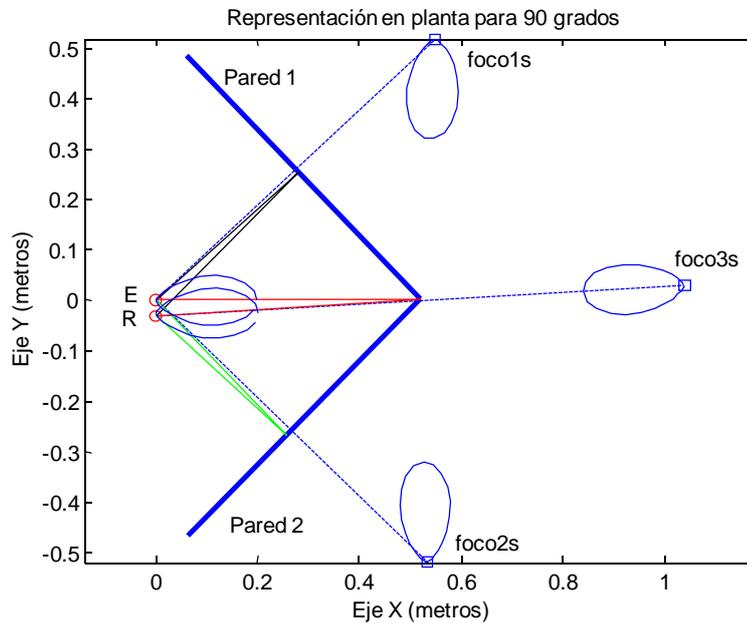


Figura 5.86: Representación en planta para esquina de 90 grados con 3 cm de separación entre sensores

Se muestran a continuación en las figuras 5.87, 5.88 y 5.89 los tres subecos, de forma independiente, correspondientes respectivamente al rebote sobre la pared 1, rebote sobre la pared 2 y rebote sobre la confluencia de las dos paredes. La figura 5.90 muestra el eco total resultante de la suma de los tres ecos anteriores. Puede observarse que, manteniendo las mismas distancias y posición relativa a las paredes que en el caso de la esquina de 60 grados, en la esquina de 90 grados los ecos provenientes del rebote directo sobre las dos paredes ya no son despreciables como ocurría en la esquina de 60 grados y además al encontrarse el sensor emisor centrado respecto a ambas paredes sus ecos son prácticamente idénticos (ver figuras 5.87 y 5.88), por lo que aparecen solapados, al ser sus distancias recorridas prácticamente idénticas, y tienen el mismo valor de amplitud al presentar prácticamente los mismos ángulos respecto a los patrones de radiación. También se observa en este caso que, al no existir segundos rebotes, puede observarse de forma independiente, sin solapamientos, el subeco sobre la unión de la esquina, lo que facilita el análisis de su amplitud y por tanto el cálculo de la ganancia asociada.

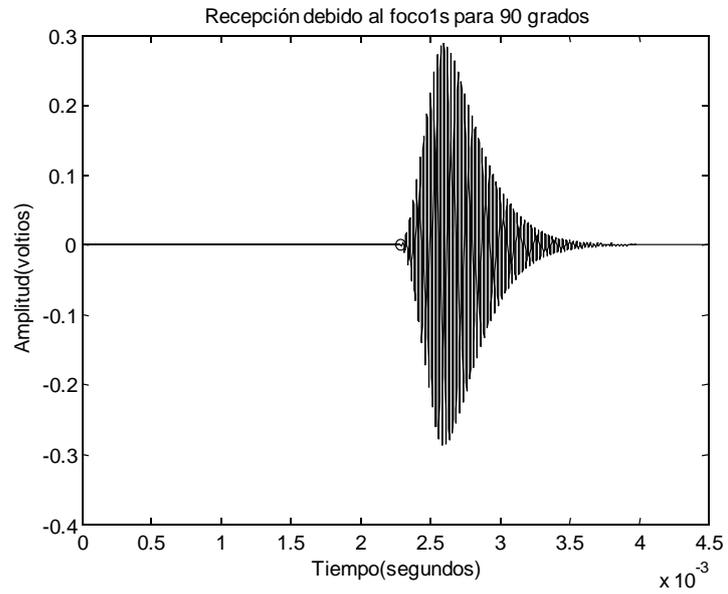


Figura 5.87: Reflexión directa en la pared 1 para esquina de 90 grados con 3 cm de separación

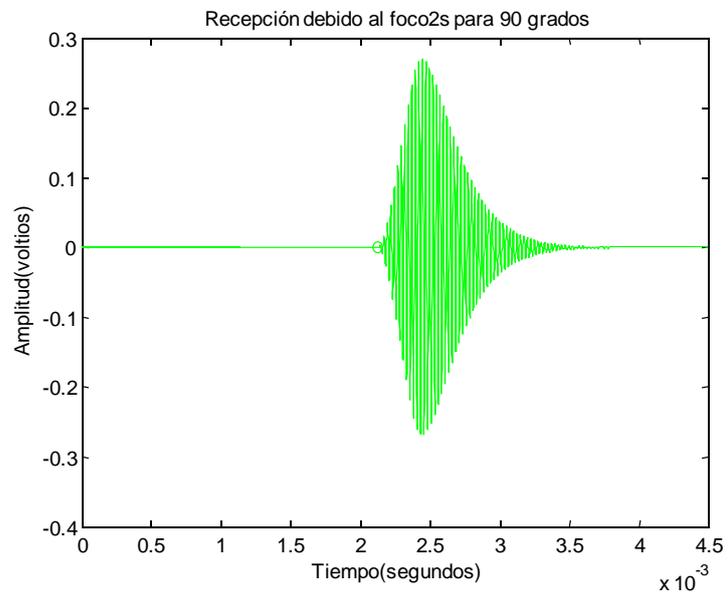


Figura 5.88: Reflexión directa en la pared 2 para esquina de 90 grados con 3 cm de separación

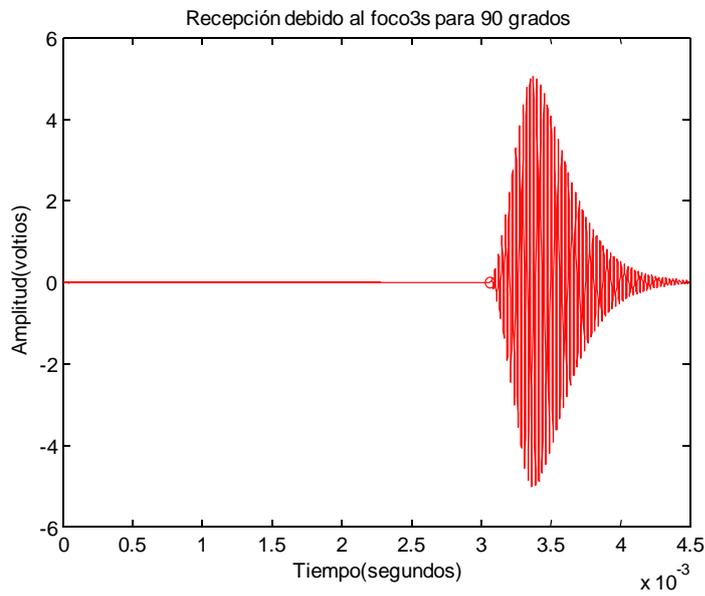


Figura 5.89: Reflexión directa en la unión de las dos paredes para esquina de 90 grados con 3 cm de separación

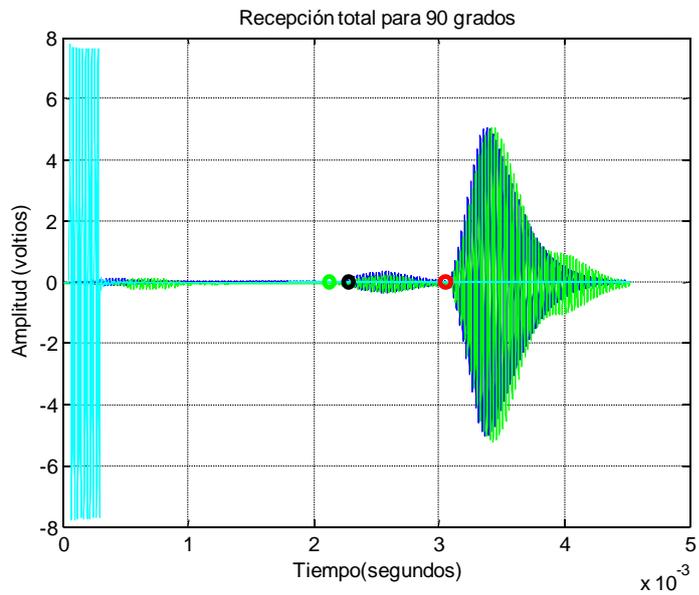


Figura 5.90: Eco completo para esquina de 90 grados con separación de 3 cm

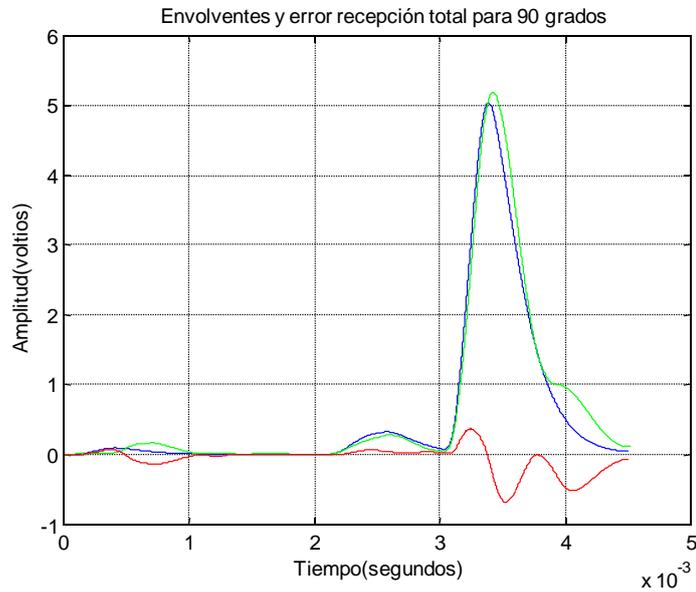


Figura 5.91: Envolventes y error para esquina de 90 grados con separación de 3 cm

En la figura 5.91 se pueden observar las envolventes del eco real, en verde, y el simulado en azul, así como su diferencia, en rojo. Esta respuesta corresponde a ajustar en el modelo del subeco de la unión la ganancia a valor unidad, obteniéndose un error cuadrático medio del eco completo de 0.1969.

Se repite igualmente el análisis para la esquina de 90 grados con una separación entre sensores de 6 cm. La tabla 5.7 se indica la disposición física experimental de la esquina.

A continuación se muestra en la figura 5.92 la representación en planta de la situación del par emisor-receptor respecto de la esquina así como las fuentes virtuales correspondientes a los tres subecos. Nuevamente en esta disposición no aparecen segundos rebotes por lo que el problema se simplifica al análisis de los tres subecos correspondientes a los rebotes directos y que se muestran en las figuras 5.93, 5.94 y 5.95.

Los subecos correspondientes a los rebotes directos sobre las dos paredes aparecen menos solapados que en el caso anterior, e igualmente que en el caso anterior el eco de la unión aparece lo suficientemente alejado de los rebotes directos sobre las dos paredes para que no haya solapamiento. En este caso

también la ganancia correspondiente al subeco de la unión de las dos paredes es de valor unidad y el error cuadrático medio obtenido para la totalidad del eco es de 0.1782

Distancia del sensor emisor a la pared 1:	37.55 cm
Distancia del sensor emisor a la esquina:	51.7 cm
Distancia del sensor emisor a la pared 2:	37.8 cm
Distancia entre emisor y receptor:	6 cm
Ángulo entre las dos paredes de la esquina:	90 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.2655 + 0.2655i$
Coordenadas de la esquina: r1_p2	$0.5170+0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.2673 - 0.2673i$

Tabla 5.7: Coordenadas y posición de la esquina de 90 grados con 6 cm

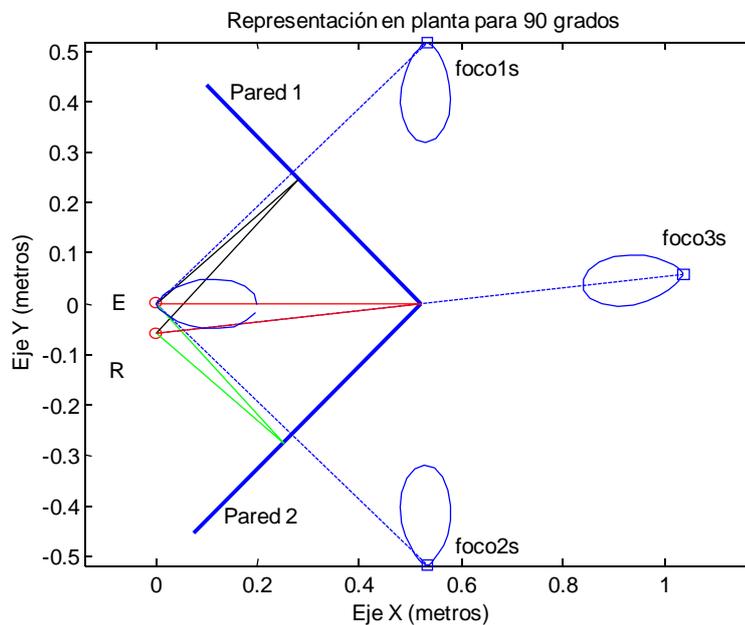


Figura 5.92: Representación en planta para esquina de 90 grados con 6 cm de separación entre sensores

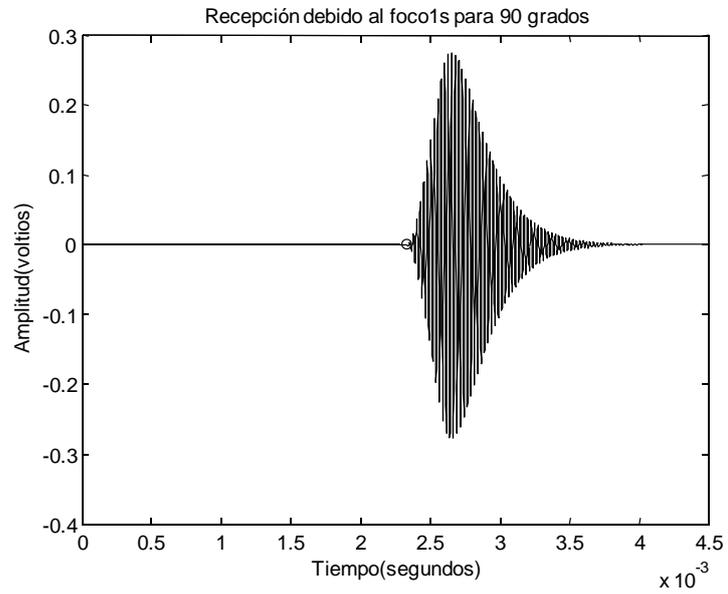


Figura 5.93: Reflexión directa en la pared 1 para esquina de 90 grados con 6 cm de separación

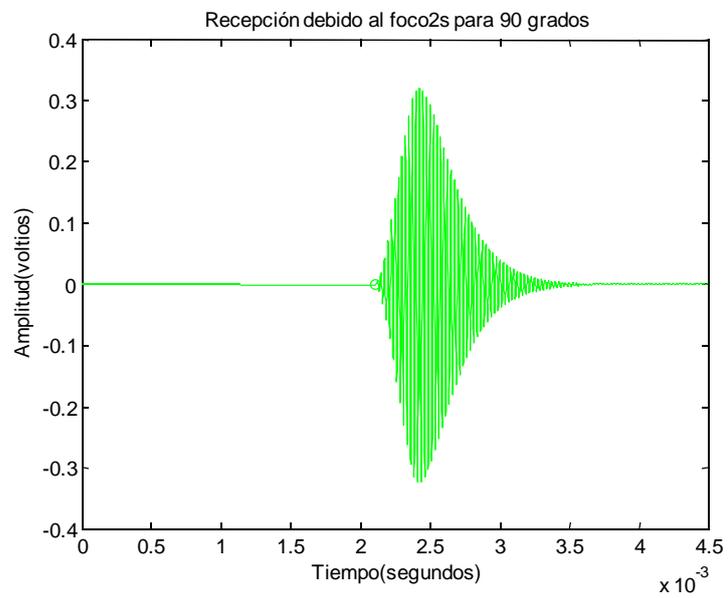


Figura 5.94: Reflexión directa en la pared 2 para esquina de 90 grados con 6 cm de separación

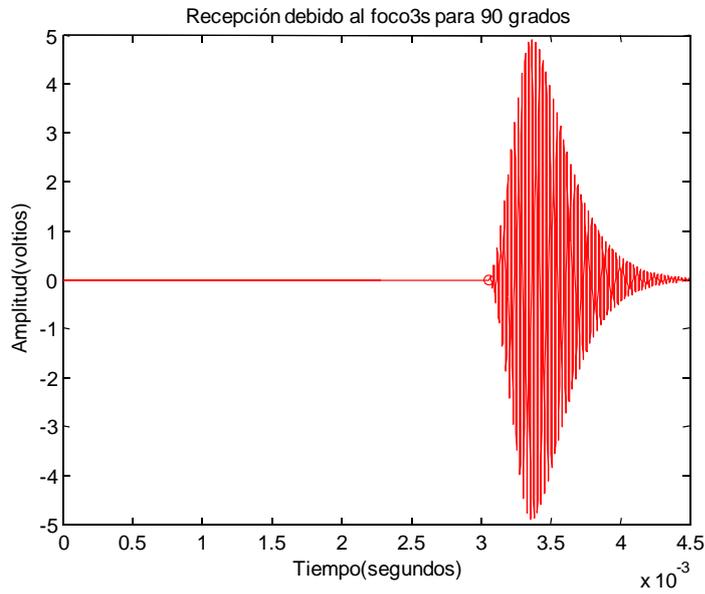


Figura 5.95: Reflexión directa en la unión de las dos paredes para esquina de 90 grados con 6 cm de separación

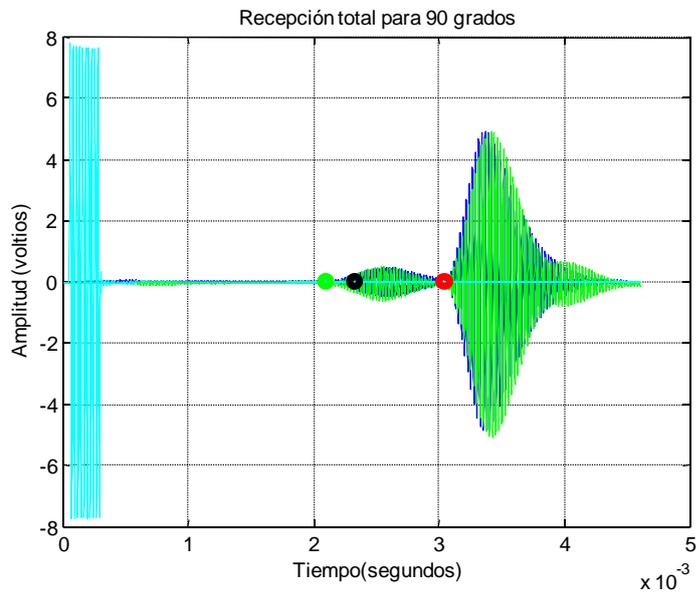


Figura 5.96: Eco completo para esquina de 90 grados con separación de 6 cm

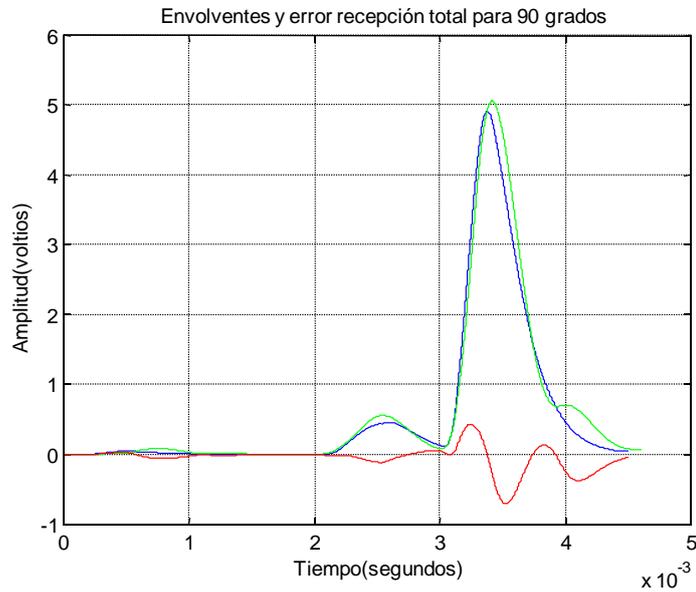


Figura 5.97: Envolventes y error para esquina de 90 grados con separación de 6 cm

Y en tercer lugar se expone el caso de esquina de 90 grados con los sensores separados 12 cm. Nuevamente la ganancia del eco correspondiente a la unión de las dos paredes coincide con la unidad y el error cuadrático medio obtenido en este caso es de 0.1106.

Distancia del sensor emisor a la pared 1:	37.55 cm
Distancia del sensor emisor a la esquina:	51.5 cm
Distancia del sensor emisor a la pared 2:	37.6 cm
Distancia entre emisor y receptor:	12 cm
Ángulo entre las dos paredes de la esquina:	90 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.2655 + 0.2655i$
Coordenadas de la esquina: r1_p2	$0.5150 + 0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.2659 - 0.2659i$

Tabla 5.8: Coordenadas y posición de la esquina de 90 grados con 12 cm de separación

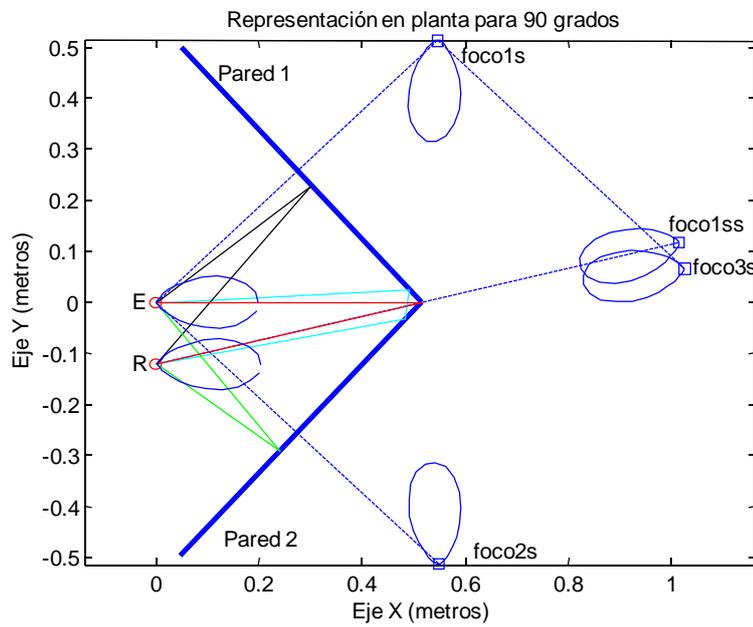


Figura 5.98: Representación en planta para esquina de 90 grados con 12 cm de separación entre sensores

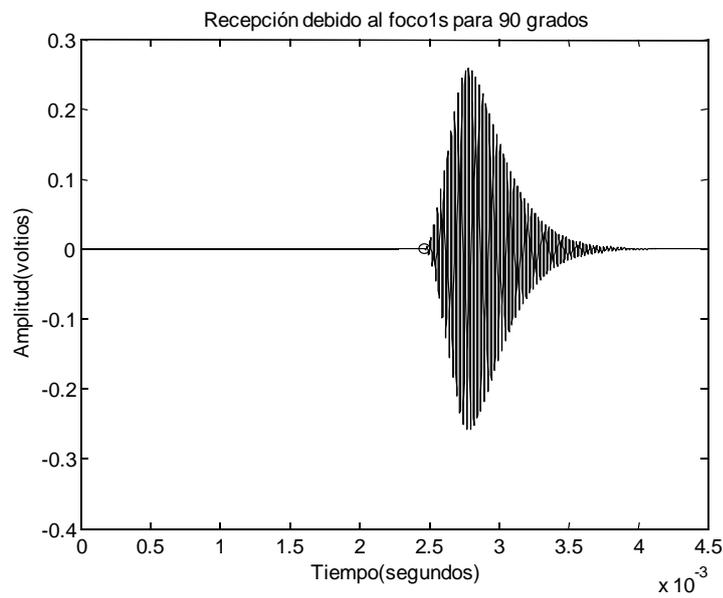


Figura 5.99: Reflexión directa en la pared 1 para esquina de 90 grados con 12 cm de separación

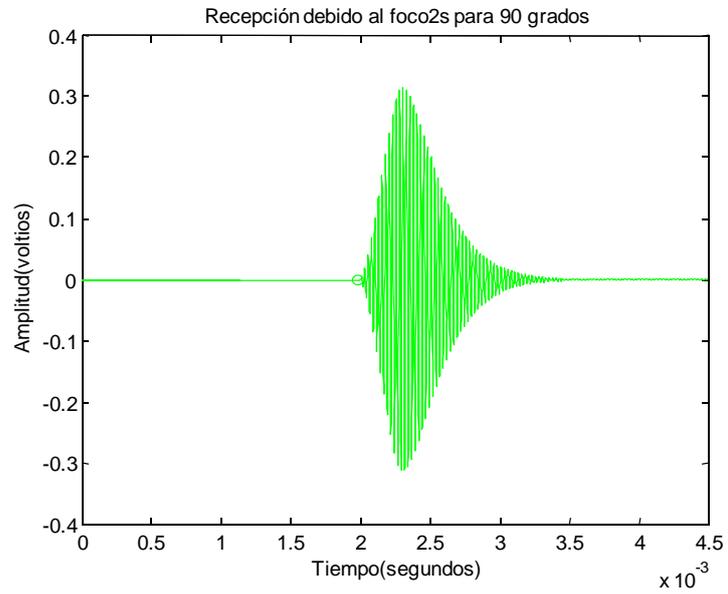


Figura 5.100: Reflexión directa en la pared 2 para esquina de 90 grados con 12 cm de separación

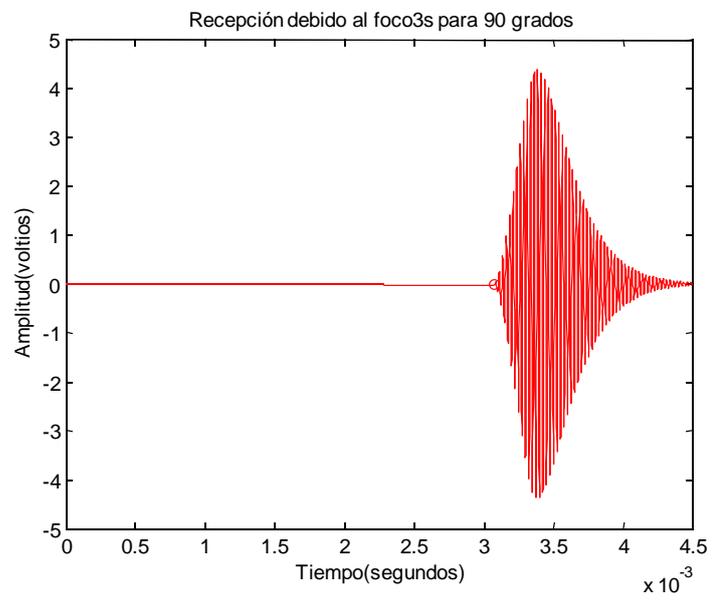


Figura 5.101: Reflexión directa en la unión de las dos paredes para esquina de 90 grados con 12 cm de separación

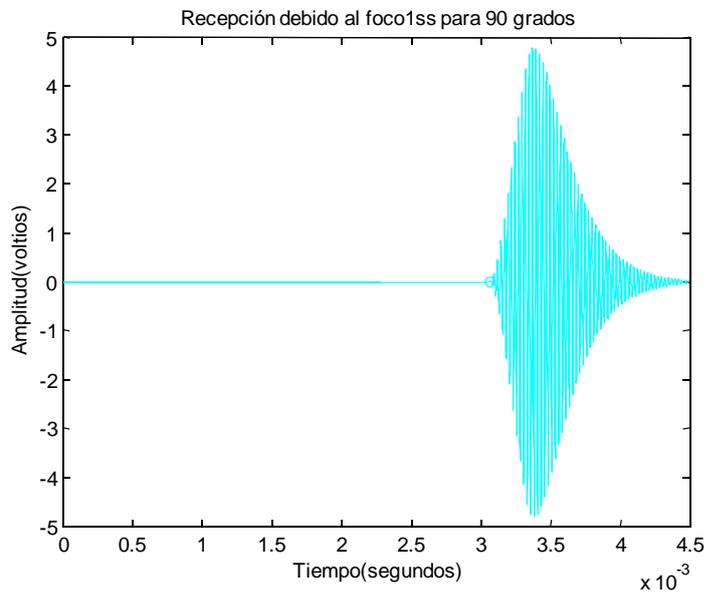


Figura 5.102: Reflexión primero en la pared 1 y después en la pared 2 para esquina de 90 grados con 12 cm de separación

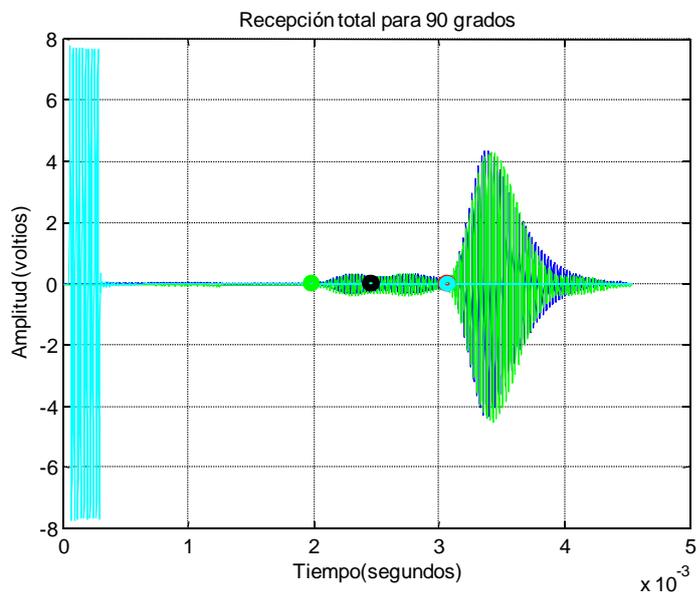


Figura 5.103: Eco completo para esquina de 90 grados con separación de 12 cm

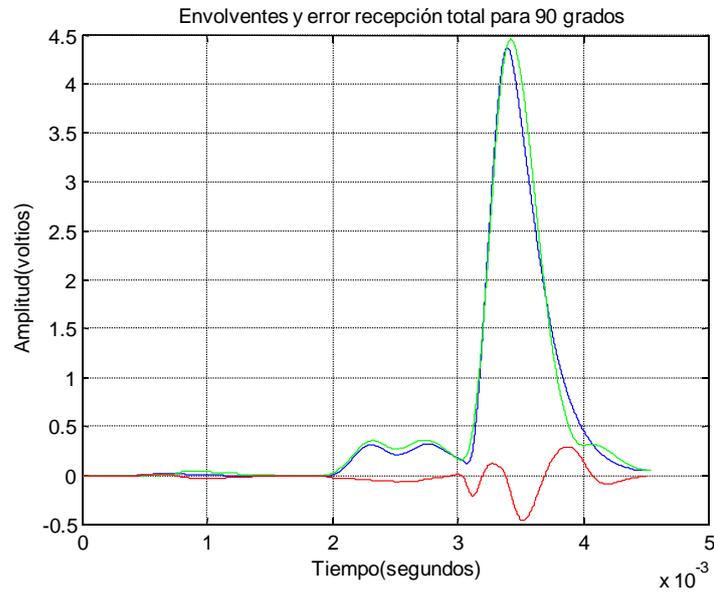


Figura 5.104: Envolventes y error para esquina de 90 grados con separación de 12 cm

### 5.9.3. Caso de esquina formada por dos paredes formando un ángulo de 120 grados.

Se muestra nuevamente el efecto de la reflexión dispersa en la unión de dos paredes, considerando ahora un caso en que las paredes forman un ángulo de 120 grados. Para una pared con un ángulo de apertura de 120 grados no existen subecos formados por rebotes sucesivos sobre las dos paredes, por lo que la respuesta total será la suma de los tres subecos siguientes: rebote directo sobre pared 1, rebote directo sobre pared 2 y rebote directo sobre la unión de las dos paredes.

Se muestra en primer lugar el caso de una esquina formada por un ángulo de 120 grados y el par de sensores emisor-receptor separados una distancia de 3 cm entre sí. En este caso se consigue que el eco correspondiente al rebote sobre la esquina no aparezca totalmente solapado con los ecos debidos a la reflexión directa sobre las dos paredes de la esquina con lo que permite un ajuste más fácil de la ganancia. Con estas condiciones el mejor ajuste se ha obtenido considerando una ganancia para el subeco de la esquina de valor 0.16

obteniéndose un error cuadrático medio de 0.0649.

Distancia del sensor emisor a la pared 1:	46.7 cm
Distancia del sensor emisor a la esquina:	52.98 cm
Distancia del sensor emisor a la pared 2:	46.265 cm
Distancia entre emisor y receptor:	3 cm
Ángulo entre las dos paredes de la esquina:	120 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.4044 + 0.2335i$
Coordenadas de la esquina: r1_p2	$0.5298+0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.4007 - 0.2313i$

Tabla 5.9: Coordenadas y posición de la esquina de 120 grados con 3 cm de separación

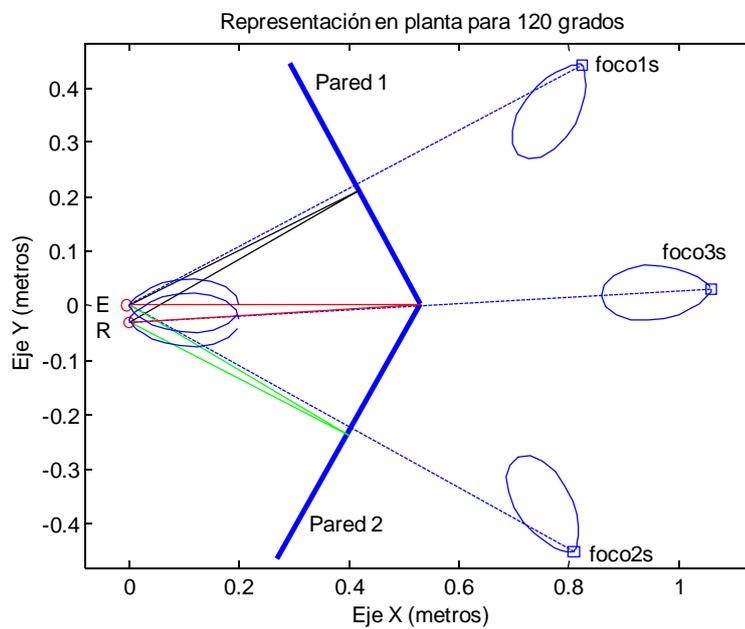


Figura 5.105: Representación en planta para esquina de 120 grados con 3 cm de separación entre sensores

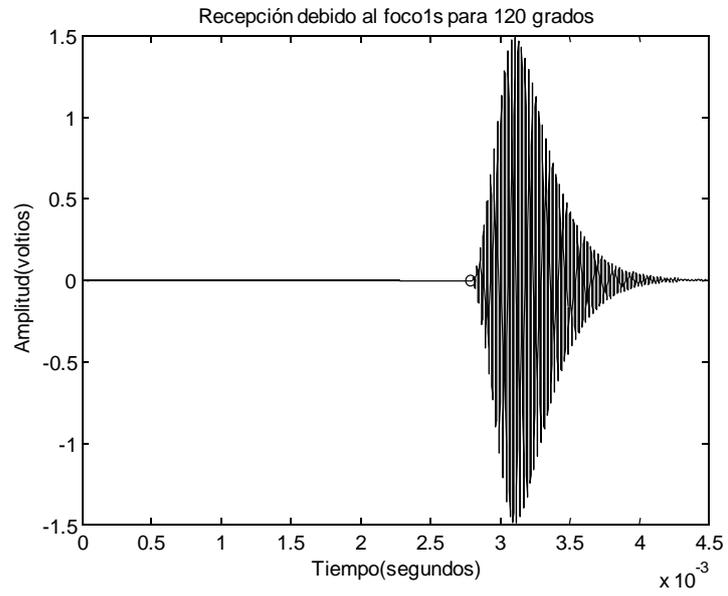


Figura 5.106: Reflexión directa en la pared 1 para esquina de 120 grados con 3 cm

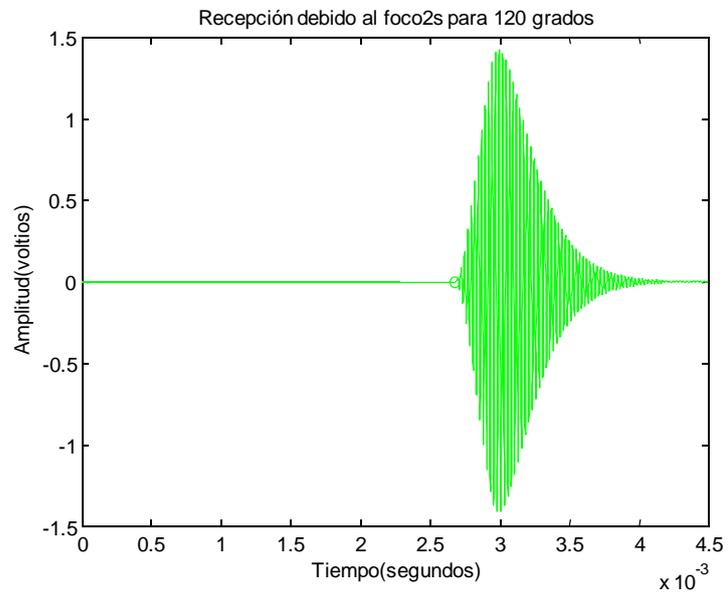


Figura 5.107: Reflexión directa en la pared 2 para esquina de 120 grados con 3 cm

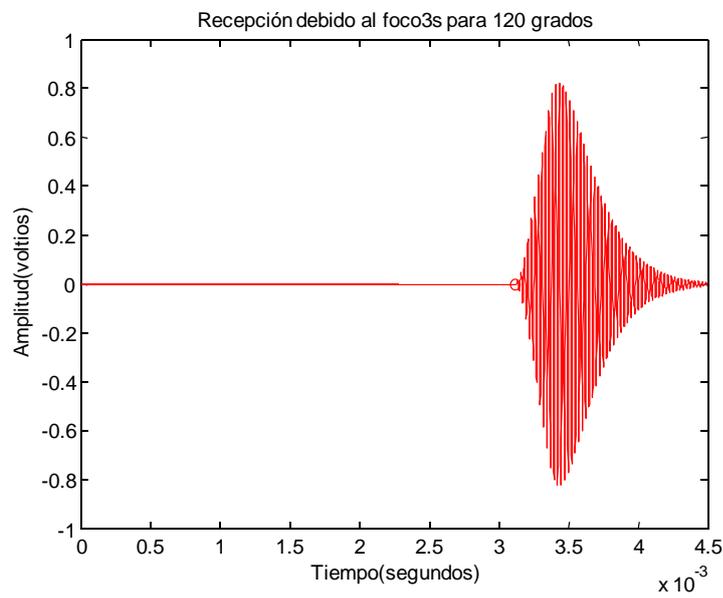


Figura 5.108: Reflexión directa en la unión de las dos paredes para esquina de 120 grados con 3 cm

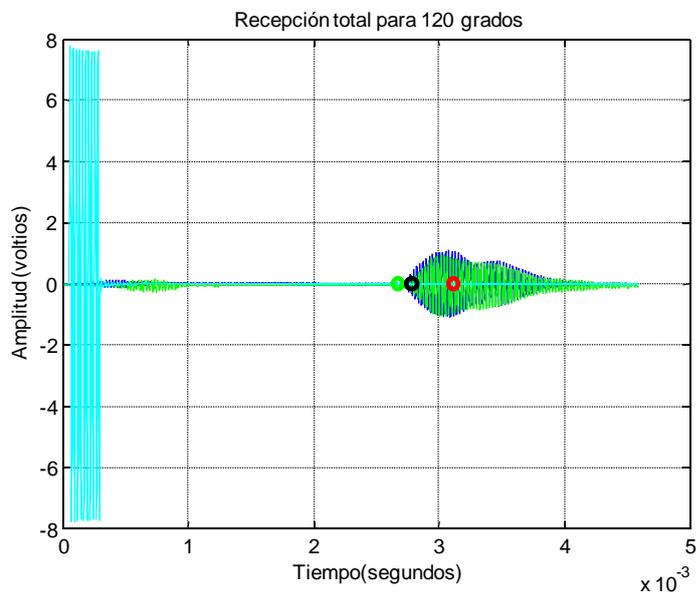


Figura 5.109: Eco completo para esquina de 120 grados con separación de 3 cm

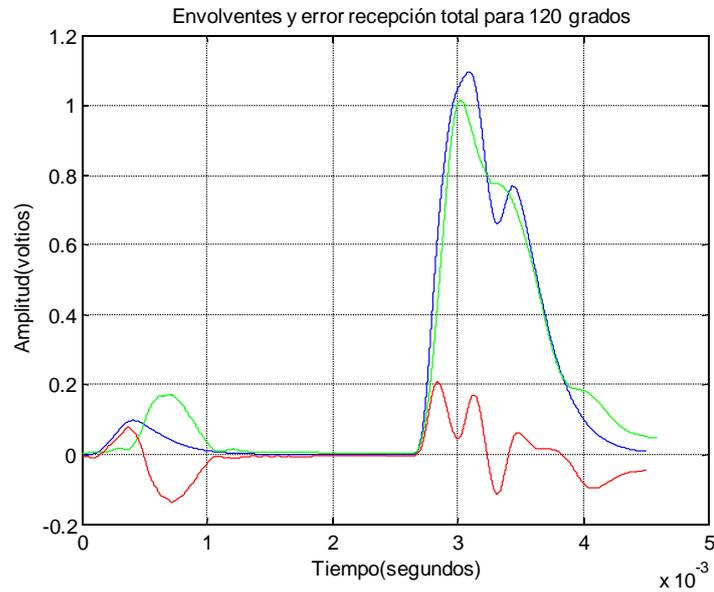


Figura 5.110: Envolturas y error para esquina de 120 grados con separación de 3 cm

Se plantea ahora otro caso para una esquina con un ángulo de 120 grados separando los sensores 6 cm entre sí. Igualmente en este caso se consigue que el eco correspondiente al rebote sobre la esquina no aparezca totalmente solapado con los ecos debidos a la reflexión directa sobre las dos paredes de la esquina con lo que permite un ajuste más fácil de la ganancia. Igualmente con una ganancia para el subeco de la esquina de valor 0.16 se obtiene un error reducido, en este caso de valor 0.0710 .

Distancia del sensor emisor a la pared 1:	45.7cm
Distancia del sensor emisor a la esquina:	52.9cm
Distancia del sensor emisor a la pared 2:	45.75m
Distancia entre emisor y receptor:	6 cm
Ángulo entre las dos paredes de la esquina:	120 grados
Coordenadas de un punto de la pared 1: r1_p1	0.3958 + 0.2285i
Coordenadas de la esquina: r1_p2	0.5290+0i
Coordenadas de un punto de la pared 2: r2_p1	0.3962 - 0.2287i

Tabla 5.10: Coordenadas y posición de la esquina de 120 grados con 6 cm de separación

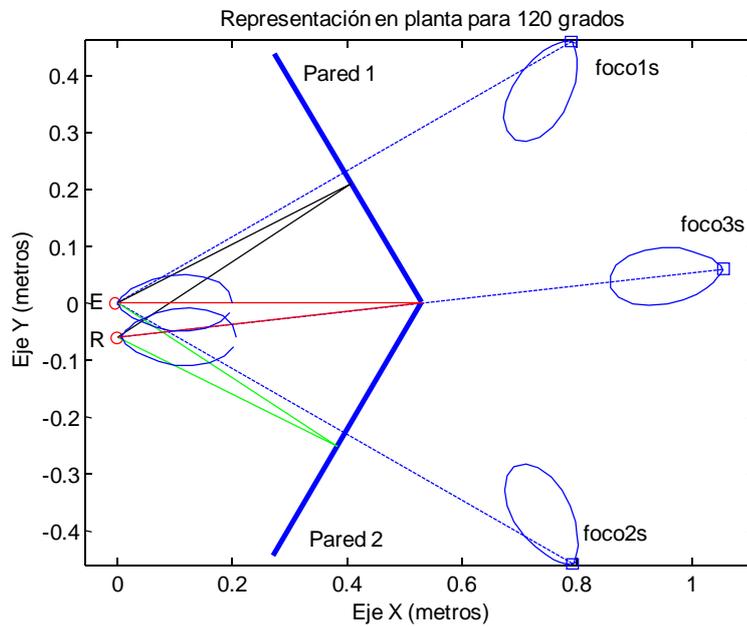


Figura 5.111: Representación en planta para esquina de 120 grados con 6 cm de separación entre sensores

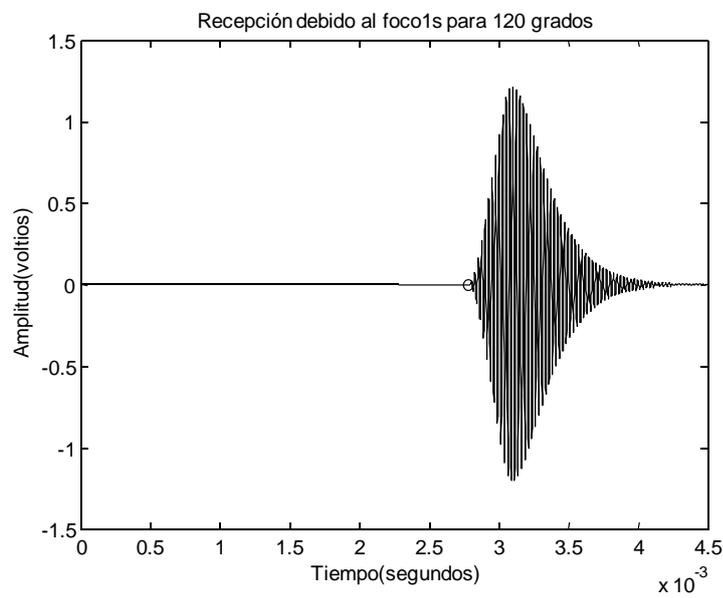


Figura 5.112: Reflexión directa en la pared 1 para esquina de 120 grados con 6 cm de separación

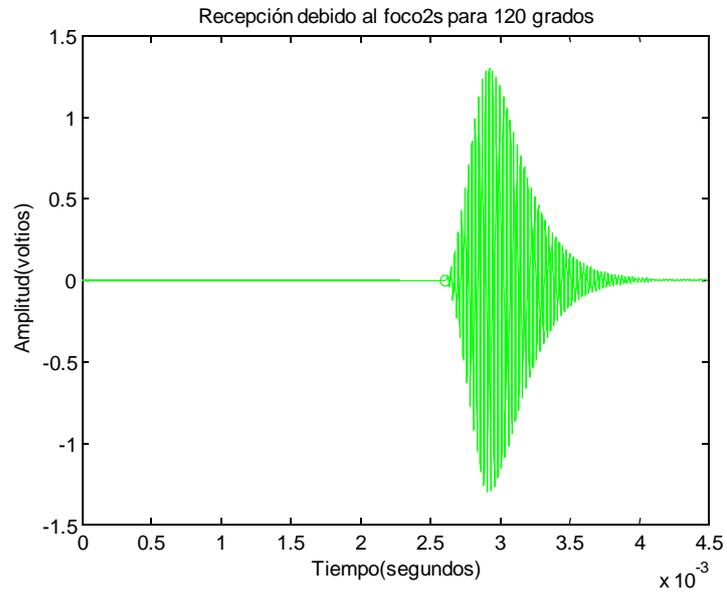


Figura 5.113: Reflexión directa en la pared 2 para esquina de 120 grados con 6 cm de separación

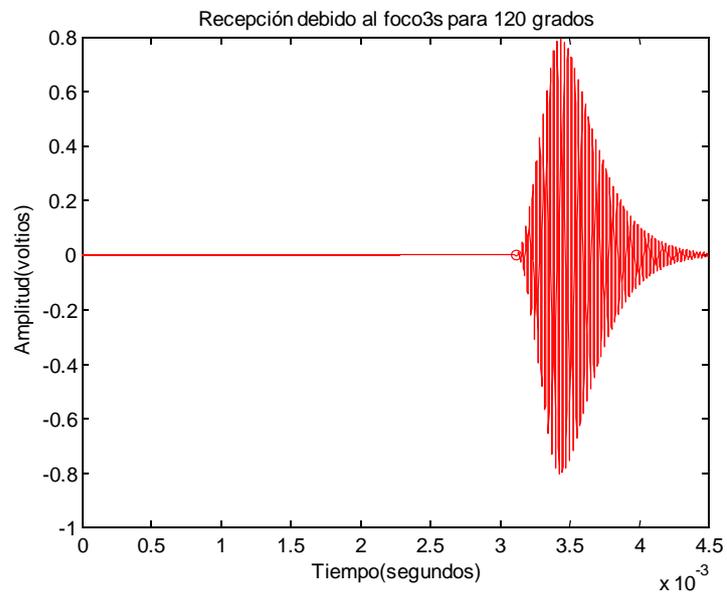


Figura 5.114: Reflexión directa en la unión de las dos paredes para esquina de 120 grados con 6 cm de separación

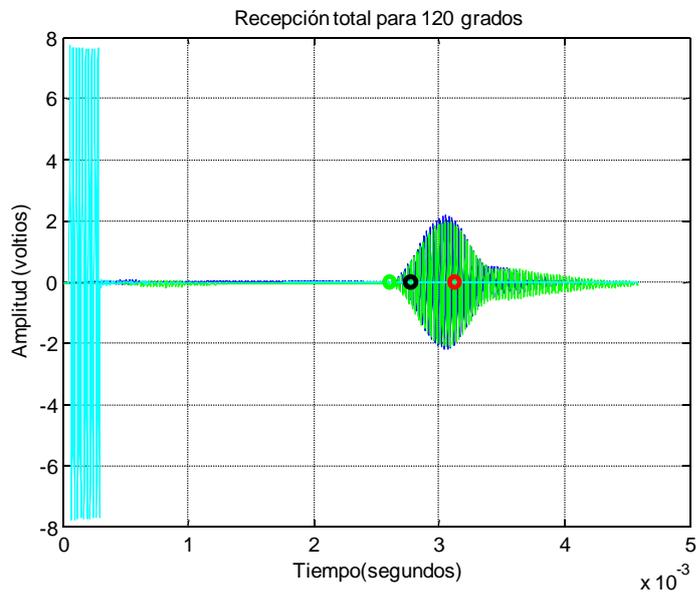


Figura 5.115: Eco completo para esquina de 120 grados con separación de 6 cm

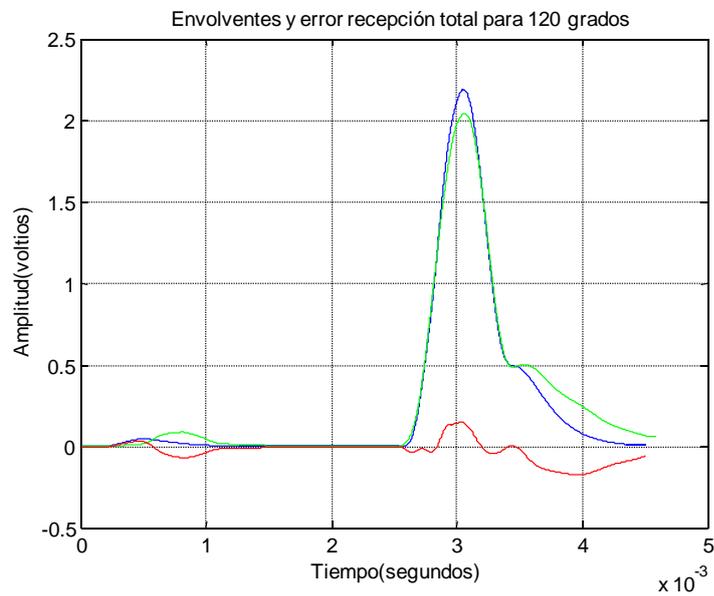


Figura 5.116: Envolventes y error para esquina de 120 grados con separación de 6 cm

Y como último ejemplo se plantea ahora una esquina con un ángulo de 120 grados separando los sensores 12 cm entre si. En este caso también se pueden observar por separado los efectos de cada subeco en la respuesta total e igualmente empleando una ganancia para el subeco de la esquina de valor 0.16 se obtiene un error cuadrático medio de 0.0904 .

Distancia del sensor emisor a la pared 1:	45cm
Distancia del sensor emisor a la esquina:	51.3cm
Distancia del sensor emisor a la pared 2:	45.3m
Distancia entre emisor y receptor:	12 cm
Ángulo entre las dos paredes de la esquina:	120 grados
Coordenadas de un punto de la pared 1: r1_p1	$0.3897 + 0.2250i$
Coordenadas de la esquina: r1_p2	$0.5130+0i$
Coordenadas de un punto de la pared 2: r2_p1	$0.3923 - 0.2265i$

Tabla 5.11: Coordenadas y posición de la esquina de 120 grados con 12 cm de separación

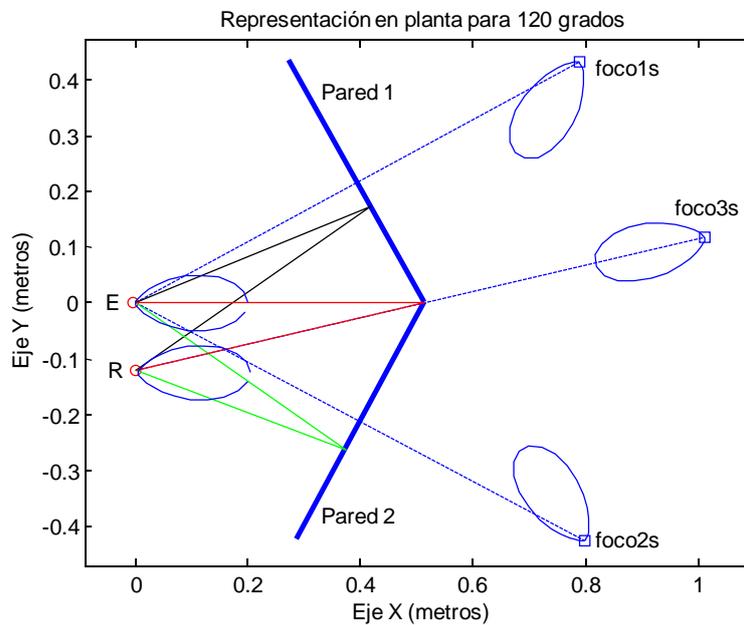


Figura 5.117: Representación en planta para esquina de 120 grados con 12 cm de separación entre sensores

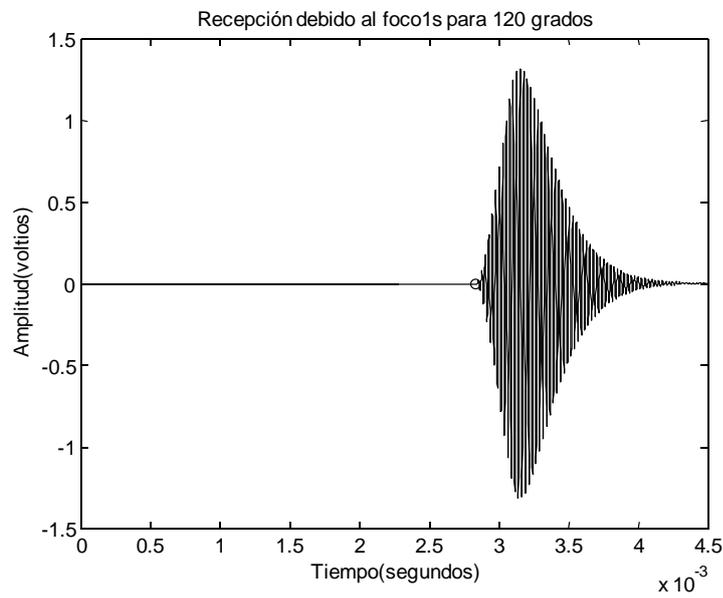


Figura 5.118: Reflexión directa en la pared 1 para esquina de 120 grados con 12 cm de separación

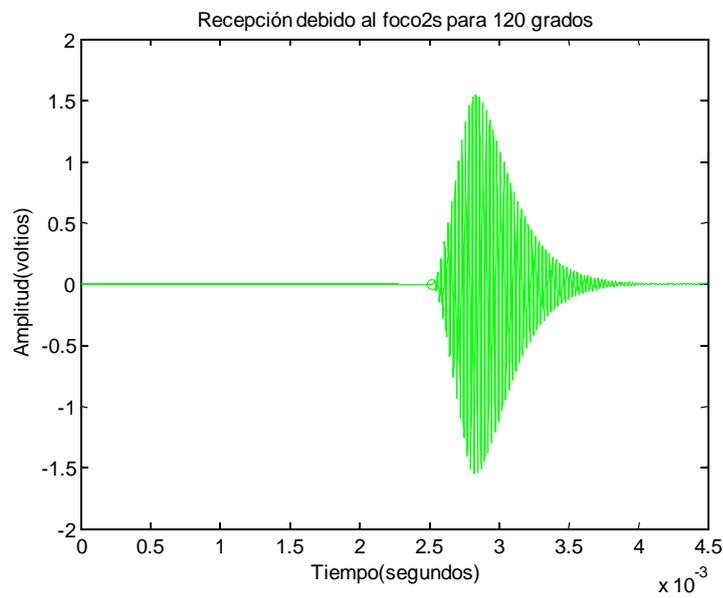


Figura 5.119: Reflexión directa en la pared 2 para esquina de 120 grados con 12 cm de separación

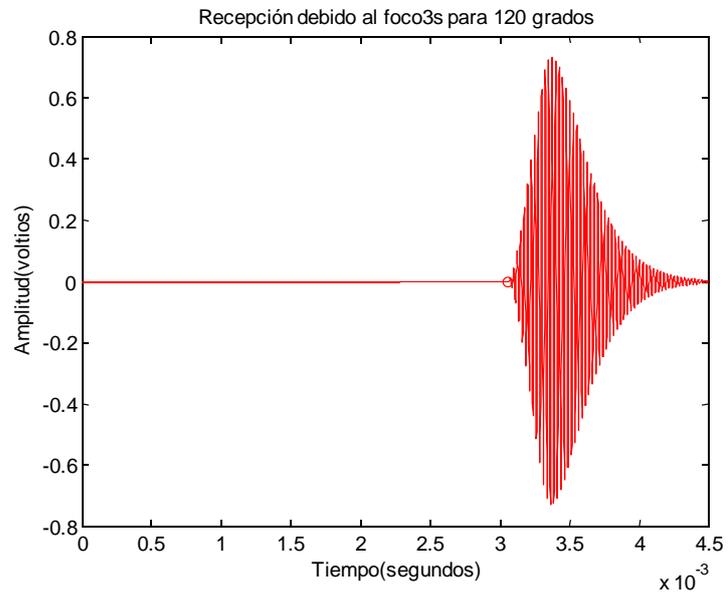


Figura 5.120: Reflexión directa en la unión de las dos paredes para esquina de 120 grados con 12 cm de separación

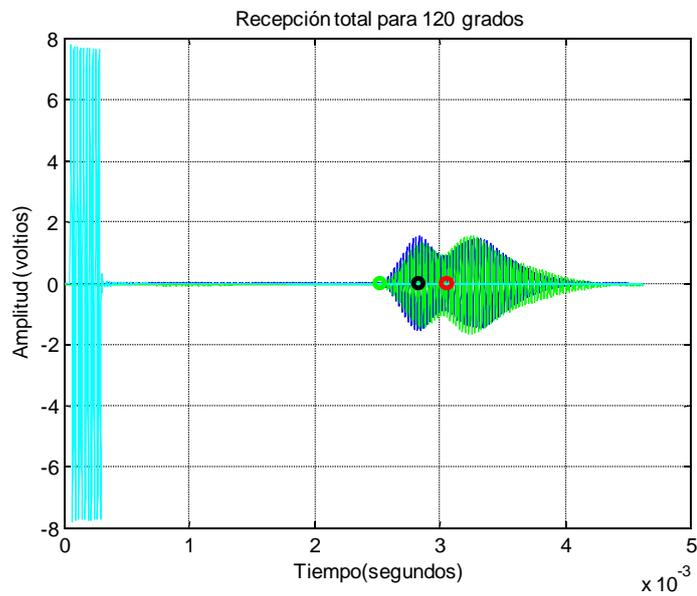


Figura 5.121: Eco completo para esquina de 120 grados con separación de 12 cm

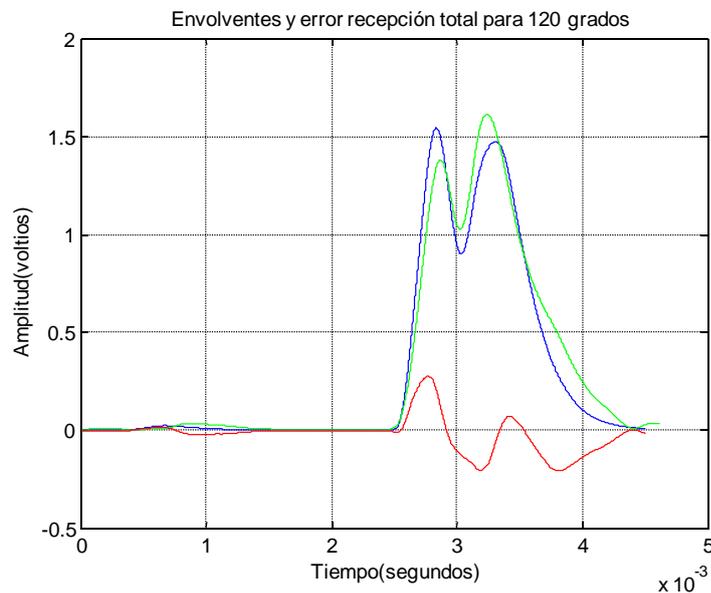


Figura 5.122: Envloventes y error para esquina de 120 grados con separación de 12 cm

Como conclusión sobre el análisis del efecto del ángulo de apertura de la esquina en la atenuación de su señal se puede concluir que para las esquinas de 90 grados o menos de apertura, la ganancia del subeco debido a la reflexión dispersa de las esquinas analizadas es la unidad y para ángulos mayores de 90 grados, la ganancia de dicho subeco se reduce a valores en torno a 0.16.

## 5.10. Resumen y conclusiones

Se ha realizado el estudio de la propagación y reflexión de ondas de ultrasonidos en aire, generadas por sensores de baja frecuencia, para su aplicación a la navegación autónoma de robots móviles en entornos estructurados. Y, basándose en dicho estudio, se ha propuesto un modelo de simulación de dichas respuestas, tanto para la propagación de los ultrasonidos por el aire como para la reflexión de dichas ondas sobre paredes planas y esquinas, el cual ha sido programado y verificado en numerosos experimentos y que permite obtener simulaciones para distancias de utilización reales como las que se pueda encontrar un robot móvil navegando por un entorno interior estructurado.

Este modelo ha sido programado basándose en la solución general de la ecuación de onda, la cual se ha ido particularizando para las características propias del medio de propagación, de las condiciones medioambientales y de las características propias del sensor, tales como su patrón de radiación real y su dinámica de funcionamiento ante señales de excitación de tipo pulso, que se analizaron en el capítulo 4.

Una vez definido el modelo completo, se ha comprobado su funcionamiento a través de una batería de experimentos, donde se han considerado esquinas con diferentes ángulos de apertura y posiciones relativas entre el par de sensores emisor-receptor y las paredes de la esquina.

Se ha prestando especial interés en ajustar el modelo correspondiente a la reflexión dispersa que se produce en la confluencia de las dos paredes de una esquina y que caracteriza de forma particular su respuesta. Para ello se han analizado las respuestas obtenidas por un conjunto de situaciones relativas entre sensores y esquina, variando en este caso la distancia entre emisor y receptor además del ángulo de apertura de la esquina.



# Capítulo 6

## Localización de esquinas mediante algoritmos genéticos.

### 6.1. Introducción

En este capítulo se propone un método de localización de esquinas para su aplicación en la generación de mapas de entorno y en la generación trayectorias para su uso en navegación autónoma mediante robots móviles.

Se pretende desarrollar un método que permita la aplicación del modelo de transmisión y reflexión de los ultrasonidos sobre esquinas, programando en el capítulo 5, en la obtención de la posición de esquinas. Este modelo estaba planteado para obtener la simulación de la respuesta ultrasónica que recibiría un par emisor-receptor cuando se está enfocando hacia una esquina a una distancia y posición relativa concreta.

Se propone este capítulo una solución al problema inverso al planteado en el capítulo anterior, es decir, dado un eco incógnita correspondiente a una situación desconocida en un entorno de navegación, localizar dicha esquina y encontrar la posición relativa que dicha esquina tiene respecto al sensor emisor.

Debido a la complejidad, por la interrelación de funciones existente, del modelo desarrollado en el capítulo 5, no es posible obtener la solución del problema inverso directamente, por lo que se va a intentar resolver empleando la ayuda que brindan los algoritmos genéticos para este tipo de situaciones.

Los algoritmos genéticos van a servir de herramienta para intentar optimizar la respuesta buscada, es decir, la localización de esquinas, basándose en un modelo que no está definido por una ecuación matemática, sino empleando el desarrollo realizado en el capítulo 5.

Los algoritmos genéticos van a permitir utilizar dicho modelo como una caja negra, es decir, generando ecos de respuesta para situaciones de esquinas conocidas, para encontrar una solución al problema inverso, generar posición de esquinas dado un eco de respuesta.

## 6.2. Introducción a los algoritmos genéticos.

Los algoritmos genéticos son una de las técnicas de inteligencia artificial, cuya utilización se presenta hoy en día de gran interés en múltiples disciplinas. Los algoritmos genéticos son métodos de búsqueda y optimización muy útiles para encontrar soluciones a problemas basándose en los métodos de selección empleados en la evolución natural. Pretenden imitar a los procesos de selección natural de las especies presentes en la naturaleza según se desarrolla en la teoría de Charles Darwin.

Estos métodos tratan progresivamente de encontrar la solución que mejor se adapte para resolver un determinado problema, por medio de un proceso iterativo de evolución y basándose su funcionamiento en criterios probabilísticos. Es decir, buscan aquellas soluciones que mejor se ajuste a las condiciones de su entorno.

Los primeros desarrollos de esta teoría se remontan a los años 50 cuando una serie de biólogos empezó a utilizar computadores para simular la teoría evolutiva sobre sus sistemas biológicos y a partir de ahí es cuando se comenzó a desarrollar las primeras aplicaciones de la teoría evolutiva a sistemas y en 1975 fue J. H. Holland quien ya reflejó en un libro esta teoría [31]. Hoy en día gran cantidad de investigadores dedican sus esfuerzos en desarrollos que continúan en esta línea [27, 23, 58].

Los algoritmos genéticos son procedimientos que presentan simultáneamente una gran sencillez de implementación y un comportamiento muy robusto a

la hora de encontrar soluciones, incluso en problemas de gran complejidad, lo que les convierte en una opción que puede ser adecuada en un gran número de aplicaciones de las más variadas áreas.

En los siguientes apartados se describen las principales características de los Algoritmos Genéticos, sus operadores básicos y su modo de funcionamiento.

### **6.3. Algoritmos genéticos y los métodos clásicos**

Los algoritmos genéticos se presentan como otra opción a emplear en la resolución de problemas de optimización además de los métodos clásicos. Donde realmente se pueden ver las ventajas de estos métodos frente a los métodos clásicos es cuando se plantea la optimización de sistemas complejos, donde existan muchas variables interrelacionadas, y en aquellos casos en que los parámetros de optimización no estén formulados matemáticamente de tal forma que no puedan emplearse los métodos clásicos, como por ejemplo en el caso de no tener una función a optimizar derivable. De esta forma los algoritmos genéticos buscan soluciones óptimas empleando procedimientos que difieren completamente de los utilizados por los métodos clásicos de optimización. Entre las ventajas que presentan estos métodos cabe destacar las siguientes:

1. Se trata de un proceso iterativo de búsqueda de soluciones óptimas donde, en caso de exista convergencia, en cada repetición del algoritmo las soluciones se irán aproximando cada vez más a los valores deseados.
2. Una de las grandes ventajas que ofrecen los algoritmos genéticos frente a otros sistemas de optimización clásicos es que éstos no necesitan tener definidos los criterios de optimización mediante una función matemática.
3. Derivado de lo anterior se tiene también que al no ser necesario tener una función de optimización definida matemáticamente, tampoco es necesario conocer la derivada de la función de optimización tal como se requiere para los métodos tradicionales. De esta forma sistemas con restricciones que no podían ser optimizables mediante métodos clásicos,

como por ejemplo, por contener funciones no derivables, por problemas de continuidad, etc., pueden mediante los algoritmos genéticos tener una solución.

4. Otra ventaja de este método está en que la búsqueda de soluciones no parte de un único punto sino que comienza simultáneamente desde diferentes lugares del espacio de búsqueda con lo que se realiza un mayor barrido inicial del espacio de búsqueda, pudiéndose encontrar el óptimo absoluto del problema, frente a los óptimos relativos que pueden alcanzarse con los métodos tradicionales.
5. De la misma forma no evolucionan hacia una solución única sino que se generan normalmente el mismo número de soluciones que puntos de partida se han tomado, con lo que se llega a encontrar un conjunto de soluciones en vez de una única solución.
6. Los diferentes operadores que utilizan los algoritmos genéticos para encontrar las soluciones no emplean métodos deterministas, sino que son probabilísticos, es decir, su comportamiento no es fijo y predecible con total seguridad, sino que va a depender de las probabilidades asignadas.
7. Los algoritmos genéticos no operan directamente sobre las soluciones potenciales que se van generando sino sobre una versión codificada de las mismas que es más manejable para la aplicación de estos métodos.

## 6.4. Elementos básicos de un algoritmo genético

Los algoritmos genéticos son métodos de búsqueda estadística útiles para resolver problemas de optimización. Estos métodos tratan de imitar las leyes de evolución por medio de la aplicación de una serie de reglas basadas en las teorías de Darwin y la genética.

Se trata de un proceso iterativo en el que las soluciones van evolucionando hacia la solución final en cada ciclo de ejecución del algoritmo.

Los algoritmos genéticos operan sobre una población de individuos, que son las potenciales soluciones al problema, aplicando el principio de supervivencia de los individuos mejor adaptados. Por medio de la aplicación de reglas similares a las de la genética, los individuos con mayor aptitud formarán una nueva población. Y así se irán obteniendo en sucesivas generaciones individuos más aptos para la resolución del problema, es decir, mejor adaptados a su entorno.

A continuación se indican los principales elementos de que están formados los algoritmos genéticos:

- Población: Los algoritmos genéticos se aplican sobre una *población* donde se incluye toda la información inicial con la que trabaja el algoritmo y que va evolucionando con el tiempo.
- Individuos: Las *poblaciones* están formadas por *individuos*, donde cada uno de ellos es una solución potencial al problema a resolver. Cuanto mayor sea el número de individuos mayor es el número de zonas que se exploran a la hora de encontrar una solución óptima, pero mayor será también el tiempo que se necesitará para realizar cada iteración del algoritmo.
- Cromosomas: Cada uno de estos *individuos* está definido por una cadena llamada *cromosoma* que contiene codificadas las características del *individuo*. Cada individuo estará definido por un único cromosoma.
- Genes: A su vez el *cromosoma* está formado por *genes*. Cada uno de estos genes contiene el valor de una característica del individuo codificada según el alfabeto empleado. Por ejemplo si se emplea el alfabeto binario, los valores de las características estarán codificadas en binario. El cromosoma correspondiente al conjunto de los genes se representa mediante una sola cadena con el total de los genes concatenados formando un vector  $c = g_1, g_2, \dots, g_n$   $g_i \in A$  donde  $c$  representa al cromosoma,  $n$  al número de genes  $g$  de que está formado el cromosoma y  $A$  al alfabeto al que pertenecen los genes.
- Alelos: Los *alelos* serán cada uno de los valores diferentes que *puede*

contener el alfabeto empleado. Por ejemplo en el caso de genes binarios, sólo existen dos posibles alelos, el 0 y el 1.

- Genoma: Se denomina *genoma* a la totalidad de la información genética que poseen los individuos.
- Genotipo: Se denomina *genotipo* al conjunto de información genética que define un individuo en concreto, es decir, a los valores particulares de sus cromosomas. Como se emplea un único cromosoma para cada individuo, entonces el genotipo coincide con su cromosoma.
- Fenotipo: El conjunto de características propias del individuo que están codificadas en el genotipo se denomina *fenotipo*. Al crear el cromosoma se codifican las características del individuo, y a esta información codificada es a la que se le aplica el proceso de búsqueda. Es más tarde cuando a partir del genotipo se descodifican dichas características para poder volver a reconstruir al individuo real a partir de su información genética. El fenotipo pertenece al dominio de la variable de decisión. Cuando se obtiene el fenotipo a partir de los valores contenidos en la cadena del cromosoma es cuando puede verse el significado de la solución obtenida y determinar la aptitud de los individuos de una población dada.
- Generación: A cada nueva población obtenida después de realizar una iteración completa del algoritmo se le denomina *generación*.
- Función objetivo: La función objetivo se utiliza para evaluar el comportamiento de un determinado individuo, es decir, evalúa lo apto que es un determinado individuo para resolver el problema planteado. Por tanto a cada individuo se le asignará un nivel de aptitud determinado que luego será utilizado para realizar la selección de los más aptos bajo la premisa de que aquellos que tengan mayor aptitud tendrán mayor probabilidad de ser seleccionados.
- Operadores genéticos: Los operadores genéticos implementan los procesos de evolución y selección de individuos imitando a los procesos naturales. Estos operadores actúan sobre los genotipos de los individuos. La

similitud de estos algoritmos con los procesos reales de evolución y la efectividad de los mismos dependerá de la complejidad de los operadores empleados. También hay que tener en cuenta que según se va aumentando la complejidad de los operadores genéticos el algoritmo requerirá más recursos del sistema y más tiempo de computación. Por lo tanto, igual que se dijo con el tamaño de la población, estos operadores deben adecuarse a las necesidades del proceso. Por ejemplo, si se desea que el algoritmo pueda trabajar en tiempo real será necesario emplear versiones lo más simples posibles de dichos operadores.

## **6.5. Etapas de desarrollo de un algoritmo genético.**

El proceso realizado por los algoritmos genéticos puede dividirse en diferentes etapas. En general las etapas vendrán marcadas por el operador empleado. En primer lugar hay una etapa que se realiza únicamente la primera vez, en la que se genera la población inicial. El resto de las etapas se repiten cíclicamente para cada iteración del algoritmo. Estas etapas serán: evaluación de individuos, selección y reproducción, cruzamiento y mutación. En los siguientes apartados se irán viendo cada una de ellas.

### **6.5.1. Generación de la población inicial**

El primer paso de un algoritmo genético es la creación de la población inicial de individuos. Como los individuos se diferencian unos de otros por el contenido de su cromosoma, esta primera generación de individuos se obtendrá mediante la producción de forma aleatoria de los cromosomas correspondientes.

El número de individuos de una población suele estar entre treinta y cien. Según se incrementa este valor, se aumenta el número de zonas de exploración del espacio de búsqueda con lo que se incrementa la probabilidad de encontrar individuos óptimos, pero por el contrario se incrementa también la carga computacional del algoritmo. También existe una variante de los algoritmos

genéticos llamada micro algoritmos genéticos que utiliza poblaciones muy pequeñas con la idea de poder ejecutarse en tiempo real.

El cromosoma de un individuo esta formado por una cadena con los valores de los genes ordenados. Por lo tanto en esta primera fase se ha decidir el tipo de codificación que se va a emplear para dichos genes, es decir, estos podrán ser binarios, enteros, reales, etc. dependiendo del alfabeto empleado. La eficacia del algoritmo genético está influenciada por el tipo de representación utilizada para los genes.

Para hablar propiamente de algoritmos genéticos los cromosomas deben estar representados en notación binaria. Cuando se utilizan cromosomas diferentes de los binarios se conoce como programación evolutiva. A continuación, para el caso de la utilización de algoritmos genéticos puros, se presentan posibles representaciones.

**Cromosomas formados por genes binarios** En el caso más simple, así los valores de las características correspondientes a los individuos de un problema son del tipo “cierto” o “falso”; o “activado” o “desactivado”, etc.; es decir, únicamente en el caso de que las características sólo pudieran tomar dos valores diferentes, se emplearían cromosomas binarios. Los cromosomas binarios emplearán por tanto el alfabeto binario para sus genes:  $A = \{0,1\}$ . De esta forma los valores que pueden tener los alelos son únicamente 0 o 1. Como en este caso cada uno de los genes estará formado por un único valor, el cromosoma completo que se genera por la concatenación de todos los genes del individuo, será una cadena binaria de longitud igual al número de genes.

**Cromosomas formados por genes enteros** Si los posibles valores de las características de los individuos son representables mediante un conjunto numerado de elementos, los genes podrían definirse mediante números enteros. Por tanto, los genes enteros emplearán el alfabeto de los números naturales:  $A \in \mathbb{N}$ . En este caso el valor que pueden tener los alelos se definirá como un determinado rango de valores dentro de los números enteros positivos.

Para poder emplear los mismos operadores genéticos que en el caso de los genes binarios, los valores enteros de los genes se van a representar en binario.

Es decir, los cromosomas estarán formados por genes enteros codificados en binario. De esta forma el rango de números naturales empleado fijará el número de cifras que serán necesarias para la codificación en binario de dichos valores.

El cromosoma completo será la cadena formada por la concatenación de dichos genes enteros codificados en binario, es decir, será una cadena binaria cuya longitud total será la suma de las longitudes de cada uno de los genes en binario.

Para codificar dichos genes será necesario emplear un código binario con el número suficiente de bits que permita representar el rango de valores enteros que puedan alcanzar dichos genes. Al seleccionar el número de bits, por lo general, se obtendrá un rango de valores representables mayor que el necesario. Esas combinaciones de bits sobrantes codificarán valores que estarán fuera del rango definido para la variable. Aunque para la población inicial se creen los códigos dentro del rango adecuado, durante el proceso de evolución podrán aparecer combinaciones de bits fuera del rango definido para el gen.

Una posible forma de resolver este problema será escalar los valores de tal manera que todas las combinaciones binarias existentes caigan siempre dentro del rango de valores enteros definidos. De esta forma habrá varias combinaciones de bits diferentes que representarán el mismo valor entero pero todos los valores que se puedan generar quedarán dentro del rango. Para realizar este escalado se tendrá en cuenta, que en la relación entre los valores enteros de los genes y los valores en decimal de los códigos correspondientes, se le ha de hacer corresponder al máximo valor entero del gen el máximo valor decimal representable en dicho código. El valor entero del gen podrá obtenerse mediante la expresión:

$$e = \text{parte\_entera} \left( \frac{d \cdot m}{2^n - 1} \right) \quad (6.1)$$

Donde:

e: valor entero del gen

d: valor decimal del código binario

m: máximo valor entero del gen

n: número de bits de la representación binaria

**Cromosomas formados por genes reales** Los valores de los genes pueden estar también representados mediante valores reales. En este caso el alfabeto empleado estará dentro de los números reales:  $A \in \mathfrak{R}$

El caso más sencillo de genes con valores reales será el que corresponde a emplear números reales con un número fijo de posiciones decimales. De esta forma cada gen podrá tomar valores dentro de un determinado rango de los números reales, donde la precisión vendrá dada al fijar el número de decimales empleados.

A estos genes reales se les realizará una transformación simple para poder aplicar a los cromosomas obtenidos los mismos operadores genéticos que a los cromosomas con genes binarios o enteros codificados en binario. Como se ha indicado que se emplearán números reales con un número fijo de decimales, fácilmente mediante un cambio de escala se pueden transformar en enteros y de ahí como en el caso de los genes enteros a su representación binaria.

Un aspecto importante en la codificación de cromosomas mediante código binario es el tipo de código empleado. Además del binario natural existen otras posibilidades de codificaciones en binario que pueden presentar otras ventajas a la hora de su aplicación a los algoritmos genéticos.

Para que exista una relación directa entre las variaciones producidas por los operadores del algoritmo genético y los correspondientes cambios en los valores representados es útil el empleo de códigos binarios en los que para pasar de cualquier combinación a la consecutiva no sea necesario producir grandes modificaciones en los bits como ocurre con el código Johnson, cuyo máximo número de valores representables para  $n$  bits es  $2 \cdot n$ , y el código Gray, cuyo máximo número de valores representables  $n$  bits es  $2^n$ .

**Tamaño de la población** El tamaño de la población es otro parámetro que afecta en gran medida a la hora de aplicar un algoritmo genético. Si se emplean poblaciones de tamaño muy reducido el algoritmo convergerá más rápidamente que si se emplean poblaciones de mayor tamaño. Es decir, si se tienen pocos individuos en unas pocas generaciones los cromosomas de todos ellos serán muy similares y la población dejará de evolucionar, llegando a una solución que no tiene por que ser la óptima.

Si se emplean poblaciones muy grandes se incrementa la probabilidad de encontrar un individuo óptimo pero también se incrementa el número de operaciones que se han de realizar para obtener una nueva generación y por tanto se incrementa el tiempo de convergencia hacia la solución. Ha de buscarse, por tanto, un equilibrio entre el tamaño de la población y el tiempo de convergencia del algoritmo.

En casos especiales cuando el proceso de evolución ha de ser muy rápido, como por ejemplo en algoritmos genéticos que han de trabajar en tiempo real, pueden emplearse micro poblaciones con un número de individuos muy reducido.

### 6.5.2. Evaluación de individuos

Una vez definidos los cromosomas, para cada una de las generaciones de individuos que se vayan obteniendo, se ha de descodificar la información contenida en los genotipos para obtener los fenotipos correspondientes.

A partir de dichos fenotipos se calculará la validez de cada individuo para resolver el problema. El nivel de adecuación de un individuo se medirá por medio de una función objetivo donde se definirán las necesidades para cumplir los objetivos. Es decir, a través de la función objetivo se transforma la información genética contenida en el cromosoma de cada individuo en un valor que indica la validez del individuo para resolver el problema.

La aplicación del algoritmo ha de hacer que aumente la validez de los individuos después de cada generación. Para ello será necesario tener una función que marque los objetivos a alcanzar, y por tanto maximizar o minimizar el valor de dicha función dependiendo de los criterios que se hayan tomado.

Por lo general los algoritmos genéticos se definen como una tarea de maximización de la aptitud del individuo por lo que los valores obtenidos de la función objetivo han de ser transformados para que los valores de aptitud obtenidos sean siempre positivos y con valores crecientes según aumente la validez del individuo.

## Función objetivo

La función objetivo determina el comportamiento de los individuos como solución al problema que se desea resolver. En esta función es en la que se establecen los criterios para la selección de individuos.

Los operadores de los algoritmos genéticos están definidos con criterios de maximización de los resultados de la función objetivo. En los casos en que se desee emplear otro criterio será necesario introducir otra función que modifique dichos valores para adaptarlos a los criterios de maximización de valores positivos para los que se fijan los algoritmos.

## Función de aptitud

Cuando lo que se desea es, por ejemplo, minimizar la función objetivo entonces a los valores más pequeños de dicha función se les debe asignar la mayor aptitud. Para ajustar dichos valores se utiliza la función de aptitud. La función de aptitud transforma los resultados obtenidos de la función objetivo en valores adecuados para realizar el proceso de maximización. Esta función ha de transformar la respuesta de la función objetivo en valores positivos que irán creciendo según aumenta la idoneidad del individuo como solución del problema planteado. Los algoritmos genéticos siempre tratarán de maximizar los resultados de la función de aptitud por lo que dicha aptitud se suele expresar como un valor relativo a la aptitud de la población total.

Algunas de las transformaciones más comunes realizadas por la función de aptitud sobre los valores resultantes de la función objetivo son las siguientes:

**Transformación en maximización con valores positivos crecientes:** Si la función objetivo proporciona valores negativos o si la optimización consiste en minimizar sus valores en vez de maximizar, será necesario previamente hacer una transformación lineal.

En el caso de querer realizar la minimización de la función objetivo, es necesario realizar la siguiente transformación lineal para adaptarlos a los criterios de maximización:

$$g(x_i) = F_{\text{máx}} - f(x_i) \quad (6.2)$$

$$F_{\text{máx}} = \text{máx}(f(x_i)) \quad i = 1, \dots, N_{\text{indiv}} \quad (6.3)$$

donde:

$g(x_i)$ : aptitud para el individuo  $i$

$f(x_i)$ : función objetivo para el individuo  $i$

$x_i$ : fenotipo del individuo  $i$

$F_{\text{max}}$ : máximo valor obtenido de la función objetivo

$N_{\text{indiv}}$ : número total de individuos

En el caso de maximización donde inicialmente los resultados de la función objetivo pueden dar valores tanto positivos como negativos, la transformación será:

$$g(x_i) = f(x_i) - F_{\text{mín}} \quad (6.4)$$

$$F_{\text{mín}} = \text{mín}(f(x_i)) \quad i = 1, \dots, N_{\text{indiv}} \quad (6.5)$$

donde:

$F_{\text{min}}$ : mínimo valor obtenido de la función objetivo

**Normalizado:** Otra posible transformación a aplicar puede ser el normalizado de los valores. Esta normalización se puede realizar mediante la siguiente expresión:

$$g(x_i) = \frac{f(x_i) - F_{\text{mín}}}{F_{\text{máx}} - F_{\text{mín}}} \quad (6.6)$$

**Valores relativos:** El siguiente paso consiste en obtener los valores de aptitud relativa a partir de la aptitud absoluta obtenida de las transformaciones anteriores.

$$g'(x_i) = \frac{g(x_i)}{\sum_{i=1}^{N_{\text{indiv}}} g(x_i)} \quad (6.7)$$

donde:

$g'(x_i)$ : aptitud relativa del individuo  $i$

$\sum_{i=1}^{N_{indiv}} g(x_i)$ : aptitud de la población completa.

Una vez que se ha definido la función  $g'(x)$  se evalúan los valores de dicha función para cada uno de los  $N_{indiv}$  individuos obteniéndose los valores de  $g'(x_i)$ ,  $i=1,.. N_{indiv}$ .

### 6.5.3. Selección de Individuos

Una vez definidos los valores de aptitud de cada individuo, transformando el valor obtenido de la función objetivo en el valor de aptitud relativa correspondiente, el siguiente paso es la toma de muestras en sí como paso inicial a la creación de una nueva generación. En esta fase se hace una selección probabilística de los individuos para la reproducción basado en la aptitud.

Una posible forma de selección sería tomar los individuos más aptos. De esta forma el número de individuos seleccionado para la reproducción será proporcional a la aptitud.

El problema ocurre si existe mucha desviación en la aptitud entre los individuos de las primeras generaciones. En este caso existirá una diferencia muy marcada entre los individuos mejor y peor adaptados inicialmente lo que puede llevar a una convergencia prematura hacia una solución que no tiene por qué ser la óptima. En el caso contrario en que exista poca desviación en la aptitud, no se marcará una clara diferencia de aptitud entre los individuos mejor y peor adaptados, con lo que no existirá una tendencia de la convergencia hacia los individuos más aptos.

Una posible solución a este problema es limitar el máximo número de descendientes que se pueden obtener a partir de un individuo. En vez de realizar una selección según su valor de aptitud, puede realizarse una selección basada en la posición que ocupan los individuos de la población una vez que han sido ordenados por aptitud, a este método se le denomina selección según el rango. A continuación se presentan ambos métodos.

**Selección por aptitud:**

A partir del comportamiento de los individuos que viene dado por la función objetivo, se genera un valor de aptitud que se utiliza en el proceso de selección para encontrar a los individuos más aptos. Es decir, el operador de selección elegirá los individuos de forma aleatoria dentro de la población, pero no todos los individuos tendrán la misma probabilidad de ser seleccionados.

Esto es, los individuos tendrán asignada una probabilidad de ser seleccionados para pasar a la siguiente fase del algoritmo, que será proporcional a la aptitud relativa que presentan respecto del resto de la población. De esta forma el proceso de selección establece el número de veces que se selecciona un determinado individuo para la reproducción.

En este caso la probabilidad de selección coincide directamente con el valor de la aptitud relativa que venía dada por la expresión (6.7).

$$s(x_i) = g'(x_i) \tag{6.8}$$

Como se ha indicado anteriormente este método puede producir una convergencia prematura hacia los individuos mejor adaptados en las primeras generaciones. Mediante este método el número de descendiente será prácticamente proporcional a la aptitud obtenida, por tanto, en las primeras generaciones, debido al alto valor de la probabilidad que tendrán los individuos mejor adaptados frente al resto, sus descendientes dominarán la población, no teniendo por qué ser exactamente los que correspondan a un máximo absoluto de la función.

**Selección por rango:**

Existen otros métodos de selección que previenen de esta convergencia prematura como es el caso de la selección por rango. En este método la probabilidad de selección se realiza de forma más uniforme y no se ve afectada por las transformaciones realizadas sobre los resultados de la función objetivo.

El rango de los individuos vendrá dado por la posición que ocupan al ser ordenados de menor a mayor aptitud. Para realizar una selección con norma-

lización lineal por el rango, puede aplicarse la siguiente expresión:

$$s_i = \frac{r_i}{\sum_{j=1}^{N_{indiv}} r_j} = \frac{r_i}{\frac{N_{indiv}(N_{indiv}+1)}{2}} \quad (6.9)$$

donde:

$r_i$ : rango del individuo  $i$

De esta forma la probabilidad de selección de los individuos mejor adaptados se reduce y en cambio aumenta aquella de los peor adaptados.

Otra modificación sobre este método para evitar esta convergencia prematura pueden ser el fijar un mínimo del valor de probabilidad de selección. De esta forma todos aquellos individuos que queden por debajo del mínimo se les asignará dicho valor mínimo, y así aumentará su probabilidad de selección.

También puede conseguirse este efecto limitando el valor máximo de probabilidad alcanzable. De esta forma todos aquellos individuos que queden por encima de este valor se les asignará ese valor máximo y de esta forma se reducirá así su probabilidad de selección.

Existen muchos otros criterios de selección aplicables como por ejemplo los planteados en las referencias [23, 58].

### Operadores de selección:

Los operadores de selección realizan la selección aleatoria de individuos, basándose en las probabilidades de selección obtenidas, para generar los progenitores de la nueva generación. A continuación se señalan los métodos más comunes empleados.

**Método de selección de la ruleta:** En este método la probabilidad de selección se representa gráficamente mediante un círculo dividido en diferentes sectores circulares. El método consiste en asignar un sector circular a cada uno de los individuos de tal forma que todos los individuos juntos completen el área del círculo. El tamaño del sector circular que corresponde a cada individuo se determina en función de su aptitud relativa y representa la probabilidad de selección de dicho individuo. La selección se realiza por medio de valores aleatorios dentro del rango definido por todos los individuos.

En este círculo o ruleta el total de los  $360^{\circ}$  se obtiene de la suma de los diferentes sectores de probabilidad de cada uno de los individuos. Por tanto la forma de realizar la selección de los individuos será mediante la generación de números aleatorios que correspondan con posiciones angulares dentro de esta ruleta. Aquellos individuos pertenecientes a sectores de mayor superficie tendrán mayor probabilidad de ser elegidos.

Dentro de este método pueden emplearse las siguientes variantes:

1. Selección con reemplazamiento: En este caso los individuos seleccionados vuelven a formar parte del conjunto seleccionable, es decir, el tamaño de los segmentos y la probabilidad de selección permanecen constantes durante todo el proceso de selección. De esta forma podría darse el hipotético caso de que todos los individuos seleccionados fueran el mismo.
2. Selección sin reemplazamiento: En este caso según se van seleccionando individuos se van redimensionando los segmentos, reduciendo el tamaño del sector del que ya ha sido seleccionado el individuo.

Para aplicar el método de selección de la ruleta con reemplazamiento se calcula la probabilidad de selección acumulada  $u_i$  para cada individuo  $i$ :

$$u_i = \sum_{k=1}^i s_k \quad (6.10)$$

Como la suma de todas las probabilidades de selección relativas de todos los individuos debe ser uno, entonces se generará un número aleatorio  $x$  comprendido entre 0 y 1 y se seleccionará al individuo  $i$  tal que dicho valor aleatorio caiga dentro de su probabilidad acumulada, esto es, que verifique:

$$u_{i-1} < x < u_i \quad (6.11)$$

Repitiendo esta operación tantas veces como individuos se deseen seleccionar se obtendrán los individuos que deben pasar a la siguiente fase. Al hacer la selección de esta forma se aplica la ley de supervivencia de los más aptos, ya que la probabilidad de ser seleccionado de un individuo mejor adaptado es mayor que la de uno peor adaptado.

El método de la ruleta permite también la supervivencia de algún individuo poco apto al ser un proceso de selección aleatoria. De esta forma se incluirán individuos que puedan tener características interesantes aunque no tengan niveles de aptitud muy elevados. Esta es una ventaja de utilizar el método aleatorio de la ruleta frente al método más directo que sería tomar los individuos mejor adaptados de esta generación. Si se seleccionan siempre a los individuos mejor adaptados se reduce la posibilidad de explorar otras regiones de las variables y las soluciones estarían excesivamente condicionadas por la calidad de la población inicial.

**Método de muestreo estocástico universal:** Consiste en un algoritmo de muestreo de un solo paso. En vez de emplear un único puntero de selección como se hace en los métodos de selección de la ruleta, el muestreo aleatorio universal utiliza  $N$  punteros homogéneamente espaciados, donde  $N$  es el número de selecciones que se desea realizar. Para llevar a cabo el muestreo se mezcla a la población aleatoriamente y se genera un único valor aleatorio llamado “puntero  $p$ ” en el rango  $[0 M/N]$  donde:

$M$ : suma de las probabilidades de selección esperadas para todos los individuos

$N$  : número de selecciones a realizar

La selección de los  $N$  individuos se realiza generando los  $N$  punteros siguientes:  $\{p, p + 1, p + 2, \dots, p + N - 1\}$  y seleccionando los individuos cuyas aptitudes ocupan las posiciones de los punteros:

$$\frac{M}{N} \cdot \{p, p + 1, p + 2, \dots, p + N - 1\} \quad (6.12)$$

### **Elitismo:**

A la hora de aplicar el operador de selección otra posible modificación será añadir un componente de elitismo.

El elitismo consiste en añadir sistemáticamente en la población de la nueva generación que se está creando los individuos más aptos de la generación anterior.

Una de las características de los operadores de selección es que como se realiza una selección aleatoria de los individuos pueden ir perdiéndose aquellos que van estando mejor adaptados.

Al aplicar el elitismo se consigue que además del conjunto de individuos obtenido por la selección aleatoria se incluya también la selección fija de los individuos mejor adaptados, con lo que además de ir explorando nuevas zonas se garantiza que los mejores individuos que van apareciendo no van a desaparecer en la siguiente generación.

Aplicando el elitismo el número total de individuos seleccionados estará formado por el número fijado para el operador de selección más el número fijado por el elitismo de individuos mejor adaptados para pasar a la siguiente generación.

#### 6.5.4. Cruzamiento

Después de realizar la selección de individuos, el siguiente paso consistirá en obtener a partir de ellos los descendientes correspondientes.

El operador de cruzamiento generará nuevos individuos con nuevos cromosomas tomando parte de la información genética de los cromosomas de los progenitores. La forma usual de generar los descendientes es mediante el intercambio de la información genética entre los progenitores. El cruzamiento no se realizará sobre todos los miembros de una población sino que se aplicará a un determinado número de pares de individuos definido mediante una tasa de cruzamiento  $t_c$ .

Se indican a continuación diferentes formas de funcionamiento de los operadores de cruzamiento según su complejidad.

**Operador de cruzamiento de punto único:** El operador de cruzamiento más simple es el de punto único. En este operador dados dos individuos progenitores seleccionados aleatoriamente se dividen sus cromosomas en dos subcadenas partir de una determinada posición y se intercambiar dichas subcadenas entre los dos individuos, generándose de esta forma dos descendientes.

El punto de cruzamiento se obtiene generando un número aleatorio entre 1

y el tamaño del cromosoma menos 1.

Este operador se aplica sobre la población generada por el operador de selección, pero no sobre todos sus individuos. Para definir que individuos se van a emplear para el cruzamiento se emplea un parámetro llamado tasa de cruzamiento  $t_c$ . El valor de este parámetro puede variar entre 0 y 1. Cuanto mayor sea su valor mayor será el número de individuos a los que se aplique el operador de cruzamiento.

Para cada uno de los individuos se genera un valor entre 0 y 1 y se compara con la tasa de cruzamiento, si dicho valor está por debajo de la tasa se empleará el individuo para el cruzamiento, y si el valor supera la tasa se desechará. Este proceso se realiza sobre todos los individuos de la población obteniéndose un subconjunto de ellos a los que se les aplicará el operador. El tamaño del subconjunto será aproximadamente:

$$N_c \approx N_{indiv} \cdot t_c \quad (6.13)$$

donde:

$N_c$ : número de individuos para realizar cruzamiento

$t_c$ : tasa de cruzamiento

El valor de  $N_c$  debe ser par ya que se emplean dos progenitores para cada cruzamiento. Si no es par se puede eliminar uno de los individuos seleccionados o añadir uno más al conjunto.

### **Operador de cruzamiento de dos puntos:**

En este operador se fijan dos puntos de cruzamiento con lo que se dividen los cromosomas de los progenitores en tres subcadenas. Intercambiando el contenido de dichas subcadenas entre los dos individuos se generan los dos descendientes.

Los puntos de cruzamiento se obtienen generando dos números aleatorios diferentes entre 1 y el tamaño del cromosoma menos 1.

**Cruzamiento múltiple:**

En el cruzamiento múltiple se seleccionan  $K$  puntos de cruzamiento dentro de la longitud total del cromosoma:

$$k_i \in \{ 1, 2, \dots, L - 1 \} \quad (6.14)$$

donde:

$L$ : longitud del cromosoma

$k_i$ : punto de cruzamiento  $i$

Las posiciones de cruzamiento se seleccionan aleatoriamente, ordenadas y sin repeticiones. Una vez seleccionadas dichas posiciones se intercalan los bits entre puntos de cruzamiento sucesivos de los genes de los padres de tal forma que se generan dos nuevos descendientes.

La utilidad del cruzamiento multipunto radica en que normalmente no tiene porqué coincidir en posiciones consecutivas de los cromosomas de los padres la información que hace más apto a dicho individuo. De esta forma se favorece la exploración de nuevas zonas del espacio de búsqueda en vez de favorecer una convergencia demasiado rápida hacia los primeros individuos más aptos obtenidos, haciendo la búsqueda más robusta.

**Cruzamiento uniforme:**

El cruzamiento uniforme es la generalización de los métodos de cruzamiento anteriores haciendo que cualquier punto del cromosoma pueda ser un punto de cruzamiento. Para ello se utiliza una máscara de cruzamiento de la misma longitud que el cromosoma. Esta máscara contiene ceros y unos de forma aleatoria, de tal forma que el valor de cada bit de la máscara define cuál de los dos padres es el que cede su información genética a su descendiente. Se generan igualmente dos descendientes, considerando para el primero que un cero corresponde a utilizar la parte de cromosoma del primer progenitor y un uno del segundo progenitor, y para el segundo descendiente se realiza a la inversa.

Con este método se producen más rupturas de los cromosomas de los progenitores con lo que se produce un efecto muy diferente a los anteriores.

Para cualquiera de los métodos indicados puede ocurrir que coincida que se crucen dos individuos con los mismos cromosomas, con lo que los descendientes serán idénticos a los progenitores.

### 6.5.5. Mutación

La mutación consiste en alterar aleatoriamente parte de la información genética que contiene el cromosoma.

El fin de la mutación es garantizar que la probabilidad de búsqueda sea siempre mayor que cero. El operador de mutación asegura que se realizará la exploración de nuevas regiones, tratando de garantizar que cualquier punto del espacio de búsqueda pueda ser alcanzado, con lo que se tendrá menos probabilidad de que la solución se quede atascada en un valor óptimo local en vez del valor óptimo global. También sirve para prevenir de la pérdida prematura de alguna información genética interesante que puedan tener los individuos menos aptos.

El operador de mutación se aplica sobre una pequeña parte de la población. Suele ser habitual que se aplique entre un uno por ciento y un uno por mil del total de los alelos que forman la población completa, ya que si se toma un valor grande se tiende a convertir el algoritmo genético en un algoritmo de búsqueda aleatoria ya que destruye los cromosomas generados.

El número de individuos afectados por la mutación se indica mediante la llamada tasa de mutación  $t_m$ . El valor de este parámetro se va a definir dentro del rango  $[0,1]$ , especificándose de esta forma la tasa de mutación en tanto por uno. Cuanto mayor sea este valor, mayor será el número de individuos a los que se aplicará el operador de mutación.

El método más común de aplicación de la mutación en un cromosoma binario consiste en invertir el valor de un determinado bit, siendo éste seleccionado de forma aleatoria.

Algunas de las variaciones aplicables al operador de mutación pueden ser las siguientes:

1. Desviar la mutación hacia los individuos con menor aptitud. De esta forma se aumenta el espacio de búsqueda sin el inconveniente que pudiera

ser el perder los individuos mejor adaptados.

2. Parametrizar la mutación de tal forma que en vez de emplear un valor constante durante todo el proceso, la tasa de mutación disminuya según va convergiendo la población.

El valor de la tasa de mutación afecta de forma importante en la convergencia del algoritmo y debe ser ajustado para cada problema a su valor adecuado.

Estos operadores pueden clasificarse en operadores de mutación uniforme o de mutación no uniforme dependiendo de los bits a los que afecte.

### **Operador de mutación uniforme:**

El operador de mutación uniforme será aquel que se aplica con igual probabilidad a cualquiera de los bits que forman el cromosoma.

El número de individuos que se ven afectados por la mutación va a depender de la tasa de mutación  $t_m$  fijada. El número de alelos modificados serán  $1000 \cdot t_m$  alelos por cada 1000. Por tanto el número de alelos que se verán afectados por la mutación suponiendo que todos los genes son del mismo tamaño será:

$$n = N_{indiv} \cdot N_{genes} \cdot N_{bits} \cdot t_m \quad (6.15)$$

donde:

$N_{genes}$ : número de genes de cada cromosoma

$N_{bits}$ : número de bits por gen

$t_m$ : tasa de mutación

La selección de los alelos que se van a modificar se hará de forma aleatoria sobre toda la población.

Anteriormente se ha dicho que el método más común de producir la mutación en los cromosomas binarios es mediante la inversión del valor del alelo afectado. Otra posible forma de aplicar la mutación puede ser la de generar aleatoriamente un 0 o un 1 para cada uno de los casos y sustituir por él el valor del alelo. De esta forma se obtiene una tasa de cruzamiento mitad que por el otro procedimiento.

### **Operador de mutación no uniforme de Michalewicz:**

Otro tipo de operador de mutación empleado en los cromosomas binarios es el operador de mutación no uniforme de Michalewicz [58]. En este caso el operador no funciona de la misma forma durante todo el proceso sino que va variando su actuación según van pasando las generaciones y el sistema se acerca a la solución final. Va tratando de mejorar lo más posible la capacidad de ajuste fino en la búsqueda final de los individuos más adecuados cuando ya se está muy próximo a la solución final, con lo que se aumenta la precisión del método.

La forma de funcionamiento de este operador se basa en conseguir que los cambios producidos por la mutación cuando el proceso va llegando a la solución final no provoquen variaciones grandes del individuo. Es decir, ir reduciendo el efecto de la mutación según van pasando generaciones. En un cromosoma representado en código binario natural un cambio del valor de un bit en la parte izquierda del gen, en los bits de mayor peso, produce una gran variación del valor representado mientras que si se produce el cambio en los bits de la parte derecha, bits de menor peso, la variación será muy pequeña. Este proceso puede verse afectado por el tipo de código binario empleado en la codificación.

Por tanto para controlar los cambios que produce el operador de mutación en un cromosoma las modificaciones se orientan hacia unos alelos determinados según sea la etapa en la que esté el proceso.

Para ello se van modificando las probabilidades de mutación con el número de generaciones. La probabilidad de variación de cualquier alelo es la misma para cualquier alelo en la primera generación, pero según va aumentando el número de generación va disminuyendo gradualmente la probabilidad de mutación de los alelos de mayor peso hasta llegar a afectar únicamente a los alelos de menor peso. De esta forma los cambios que se producen en las últimas generaciones apenas modifican el valor de los cromosomas.

### **6.5.6. Reinserción**

A lo largo de las diversas etapas y debido a la aplicación de los diferentes operadores se va generando una nueva población de individuos. El tamaño de la

nueva población generada por lo general no va a coincidir con el de partida de la población. A la diferencia existente entre en número de individuos obtenidos en una determinada generación y la anterior se le denomina hueco generacional.

Por tanto una vez obtenida la nueva generación de individuos descendientes, estos pueden sustituir totalmente a la generación anterior o simplemente reemplazar a los individuos a partir de los cuales fueron obtenidos.

### **Reinserción sin reemplazamiento generacional:**

En este caso los  $N_d$  individuos descendientes, que se obtienen de la combinación de cromosomas de los  $N_d$  individuos progenitores, sustituyen directa y únicamente a sus progenitores.

En esta nueva generación convivirán los  $N_d$  nuevos individuos con los  $N_{indiv} - N_d$  individuos restantes que no se emplearon para el proceso de creación de la nueva generación. Es decir, convive parte de la generación anterior con la actual.

Otra forma de inserción de individuos nuevos en una población podría ser que los descendientes, en vez de sustituir a su progenitores, sustituyan a aquellos que presentan una aptitud menor en la generación de los progenitores. De esta manera se puede incrementar la velocidad de convergencia del algoritmo. Esto sería una estrategia de elitismo puesto que los individuos más aptos sobrevivirán probabilísticamente en las sucesivas generaciones.

Otro método de reinserción podría ser también el de reemplazar los individuos más antiguos.

### **Reinserción con reemplazamiento generacional:**

En este caso, después del cruzamiento la nueva generación de descendientes sustituye totalmente a la generación de progenitores.

Para que la nueva generación de descendientes reemplace totalmente a la generación de progenitores es necesario que la nueva generación tenga el mismo número de individuos que la anterior.

Para ello a partir de los  $N_c$  progenitores seleccionados, mediante combinación de los mismos, se han de generar  $N_d$  descendientes tal que:

$$N_d = N_{indiv} \quad (6.16)$$

donde:

$N_d$ : número de descendientes

$N_{indiv}$ : número total de individuos

Por los mismos motivos que el caso anterior también pueden aparecer individuos idénticos a la generación anterior si coincide que se cruzan dos progenitores con los mismos cromosomas.

En cualquier caso el valor de la tasa de cruzamiento afecta de forma importante en la convergencia del algoritmo y debe ser ajustado para cada problema a un valor adecuado.

### 6.5.7. Terminación

Como los algoritmos genéticos son un método de búsqueda aleatoria, es difícil especificar formalmente un criterio de convergencia.

Después de obtener cada nueva población mediante la aplicación de los operadores, se calculará la aptitud de los individuos de la nueva población.

Dependiendo del problema que se esté tratando la velocidad de mejora de la aptitud general de la población entre generaciones sucesivas puede ser muy diferente y por tanto no se puede fijar un criterio general para todos los casos.

Uno de los criterios para parar el proceso suele ser el fijar para cada caso concreto a analizar un número máximo de generaciones, y llegado a ese punto comprobar si alguno de los individuos cumple las especificaciones de aptitud. En caso de no cumplirlas se comenzará una nueva búsqueda.

Finalmente entre la población solución se buscará el individuo más idóneo. Es decir la solución final no es única, sino que está formada por el conjunto de soluciones que son cada uno de los individuos de la generación solución. Es ya labor del usuario el seleccionar cual puede ser el más indicado.

Además de los operadores básicos que se han analizado existen multitud de operadores avanzados tales como los de dominancia, diploidismo, segregación, translocación, inversión, eliminación, etc. que pueden encontrarse por ejemplo en [31, 27] y que permiten mejorar y perfeccionar los algoritmos.

## 6.6. Fundamento teórico de los algoritmos genéticos: Teorema de los Esquemas

Los fundamentos teóricos de los algoritmos genéticos se basan en la representación de la información mediante cadenas de bits. Dentro de estas cadenas de bits se definen los denominados esquemas [31] que forman la base para la generación de combinaciones de bits que potencialmente pueden mejorar a los actuales. Los esquemas son plantillas que permiten buscar similitudes entre diferentes cromosomas. De esta forma los cromosomas dejan de ser únicamente cadenas de bits para intentar extraer de ellos aquella información que haga a determinados cromosomas presentar mayor aptitud. Es decir, se intentan buscar patrones de bits contenidos en ciertas cadenas que hacen a éstas más aptas como solución del problema. Los esquemas son plantillas de bits que se construyen mediante el empleo de tres símbolos: “0”, “1” y “\*”. El símbolo “\*” corresponde a una situación “no importa”, es decir, el bit que ocupa dicha posición no importa que sea “0” o “1”. Es decir, si existen  $k$  símbolos “no importa” en un esquema, existirán  $2^k$  (las posibles combinaciones de dichos símbolos) cadenas que se ajustan a dicho esquema.

Como características que definen a los esquemas se presentan el orden y la longitud del esquema.

El orden del esquema  $E$ ,  $\text{orden}(E)$ , se define como el número de posiciones que presenta con valor fijo, es decir, el número de posiciones que no contienen el símbolo “no importa”. O lo que es lo mismo el número total menos el de símbolos “no importa”. El orden se emplea para calcular la probabilidad de supervivencia del esquema debido a la aplicación de operadores de mutación.

La longitud del esquema  $E$ ,  $\text{longitud}(E)$ , se define como la máxima distancia existente entre posiciones fijas. Indica la compactación de la información contenida en el esquema y se emplea para calcular las probabilidades de supervivencia del esquema debido a la aplicación de los operadores de cruzamiento.

Para estos esquemas se puede analizar los efectos que tienen los diferentes operadores genéticos. Según [27] estos efectos serán los siguientes:

El efecto del operador de reproducción sobre el esquema  $E$  hará que este

esquema se reproduzca con la misma probabilidad que el criterio de selección de individuos empleado. Es decir, si se ha empleado la expresión (6.7) para obtener la probabilidad de selección de un individuo entonces, se esperará la misma probabilidad de selección para un esquema E. Por tanto la probabilidad de selección del esquema E vendrá dada por:

$$p_s = \frac{g(E)}{\sum_{i=1}^{N_{indiv}} g(x_i)} \quad (6.17)$$

donde:

$g(E)$ : aptitud absoluta del esquema E

$x_i$  : cromosoma del individuo  $i$

$N_{indiv}$ : número total de individuos

$\sum_{i=1}^{N_{indiv}} g(x_i)$ : aptitud de la población completa.

Es decir, un determinado esquema se reproducirá en la misma proporción que la aptitud relativa del esquema respecto a toda la población, de tal forma que si la aptitud del esquema está por encima de la media tenderá a aumentar en número de este esquema en la población y si está por debajo de la media tenderá a desaparecer.

El efecto del operador de cruzamiento sobre el esquema E permitirá explorar nuevos esquemas ya que genera porciones del esquema inicial. Como los esquemas sobrevivirán al cruzamiento cuando el punto de cruzamiento caiga fuera de la longitud del esquema, la probabilidad de supervivencia para el operador de cruzamiento de punto único será:

$$p_c \geq 1 - t_c \frac{longitud(E)}{L - 1} \quad (6.18)$$

donde:

$t_c$  : tasa de cruzamiento

L: longitud del cromosoma

Es decir, la probabilidad de supervivencia de un esquema está relacionada con la longitud del esquema de la forma que, si el esquema es relativamente corto su probabilidad de supervivencia aumenta, y si es relativamente largo su probabilidad de supervivencia disminuye.

El efecto del operador de mutación sobre un esquema E puede producir la modificación de dicho esquema. Conociendo que la probabilidad de mutación de un alelo cualquiera viene dada por la tasa de mutación  $t_m$  empleada, la tasa de supervivencia será  $(1 - t_m)$ . Como la probabilidad de mutación es independiente para cada uno de los alelos, la probabilidad de mutación de un esquema será el producto de las probabilidades de mutación de las posiciones fijas. Siendo el número de posiciones fijas  $orden(E)$ , entonces la probabilidad de supervivencia del esquema E debido al operador de mutación será:

$$p_m = (1 - t_m)^{orden(E)} \quad (6.19)$$

donde:

$t_m$  : tasa de mutación

En el caso de tasas de mutación pequeñas puede aproximarse por:

$$p_m = 1 - orden(E) \cdot t_m \quad (6.20)$$

Es decir, la probabilidad de supervivencia de un esquema está relacionada con el orden del esquema de la forma que, si es de bajo orden su probabilidad de supervivencia aumenta, y si alto orden su probabilidad de supervivencia disminuye.

Por tanto, la probabilidad para los esquemas en la combinación de operadores, suponiendo independencia de los operadores, puede obtenerse del producto de las probabilidades individuales para cada uno de los operadores.

El número de esquemas E en la generación  $t$ ,  $num(E,t)$ , seleccionados para la siguiente generación será:

$$num(E, t+1) = num(E, t) \frac{g(E)}{\sum_{i=1}^{N_{indiv}} g(x_i)} \left( 1 - t_c \frac{longitud(E)}{l - 1} \right) (1 - orden(E) \cdot t_m) \quad (6.21)$$

Que puede aproximarse como:

$$num(E, t+1) = num(E, t) \frac{g(E)}{\sum_{i=1}^{N_{indiv}} g(x_i)} \left( 1 - t_c \frac{longitud(E)}{l-1} - orden(E) \cdot t_m \right) \quad (6.22)$$

Por tanto, combinando los tres operadores, un esquema tendrá mayores probabilidades de sobrevivir si es de bajo orden, de pequeña longitud y con aptitud por encima de la media. O lo que es lo mismo, “el número de esquemas cortos, de bajo orden y de aptitud por encima de la media crece exponencialmente con el número de generaciones”. A esta conclusión se la conoce como el “Teorema fundamental de los algoritmos genéticos” o el “Teorema de los esquemas”.

## 6.7. Localización de esquinas empleando algoritmos genéticos.

En este capítulo se plantea encontrar una solución al problema de localizar y situar esquinas, para su aplicación en la planificación de trayectorias para la navegación autónoma de un robot mediante la programación de un algoritmo genético. Cuando el robot se encuentra próximo a una esquina, con el eco recibido de un par de sensores emisor-receptor mediante la técnica pulso-eco, se busca poder estimar la posición relativa de dicha esquina respecto al sensor emisor.

Es decir, se pretende desarrollar un método en el que, a través de un único eco tomado en una posición estática, extrayendo información de los subecos de dicha señal se pueda discernir la posición relativa de una esquina, facilitando información sobre la distancia a la que se encuentra dicha esquina y su posición angular respecto al sensor emisor. Se ha analizado el caso de las esquinas cuadradas por ser éstas las más comunes.

Como se ha indicado en la introducción al capítulo, el modelado de la respuesta ultrasónica planteado en el capítulo 5 no es directamente aplicable en estos casos, sino que se pretende realizar el proceso inverso. Ante la dificultad de un tratamiento matemático para dicho caso, se aborda el problema apoyándose

en la herramienta de optimización que son los algoritmos genéticos.

En primer lugar se analiza el eco de partida para extraer de él los diferentes subecos de que está formado y que corresponderán a los rebotes sobre las diferentes superficies de que está formada la esquina. Según los casos, como se ha visto en la parte experimental del modelado de la señal recibida desde una esquina, el eco puede estar formado por un total de cinco subecos que pueden ser apreciables en la respuesta de forma independiente o aparecer solapados. De los ecos que queden claramente identificables, a partir de la información del máximo, conociendo la respuesta transitoria del sensor, se estima la posición de inicio y de fin. Este cálculo se hace a partir del tiempo de máximo de los subecos, porque en muchos de los casos dichos subecos aparecerán solapados y esto imposibilitará la obtención directa de los tiempos de vuelo.

Con los valores de tiempo de inicio de cada uno de estos subecos se puede hacer una primera aproximación de las distancias a la que se encuentran los puntos de contacto con la esquina. Esta información nos permite generar una población inicial de individuos que no sea totalmente aleatoria, sino que esté ya orientada a la zona donde mayor probabilidad hay de que se encuentre la solución. Así mismo se va a añadir otro conjunto de individuos totalmente aleatorios para no perder la capacidad de generalización del algoritmo genético.

El cromosoma de cada individuo estará formado por la concatenación de tres genes de valores enteros que codifican, para la vista en planta de la escena, la coordenada  $x$  e  $y$  del punto de confluencia de la esquina, en milímetros, y el ángulo que forma una de las paredes de la esquina con el eje  $x$ , en décimas de grado. Se han seleccionado dichas unidades porque permiten ser codificadas mediante enteros para las dimensiones reales con que se va a trabajar en la navegación autónoma.

Se programa un algoritmo genético básico que incluye un operador de cruzamiento de punto único con una tasa de cruzamiento del 50 %, un operador de mutación con una tasa de mutación de 1 %, y un operador de elitismo que incluye sistemáticamente cinco copias del individuo mejor adaptado de la generación de progenitores. Estos parámetros han sido seleccionados para permitir una rápida evolución del algoritmo de tal forma que pueda emplearse en tareas de navegación en tiempo real.

La función objetivo a minimizar utiliza las áreas en que ha sido dividido el eco incógnita. Dicha función objetivo tiene en cuenta la suma ponderada de las áreas no solapadas entre el eco incógnita y el eco solución. El criterio de ponderación ha sido la amplitud máxima de los subecos del eco incógnita  $A_i$ , calculados inicialmente.

Para ello se divide este área en tantas zonas como marque el número de subecos que tiene el eco incógnita y se pondera cada zona de subeco inversamente a la amplitud de dicho subeco:

$$Obj = \sum_{z_i} \left[ \frac{1}{A_i} abs(env_{incog}(z_i) - env_{soluc}(z_i)) \right] \quad (6.23)$$

donde :

$z_i$ : zona de que está formado el eco

$A_i$ : amplitudes máximas de cada zona. Los  $A_i$  correspondientes a zonas sin subeco se considerarán de valor unitario.

Se incluyen a continuación dos ejemplos reales para ejemplificar el método.

## 6.8. Ensayo 1 para la localización de esquinas.

En la figuras 6.1 y 6.2 se muestra una vista en planta y el eco incógnita correspondiente a un primer caso en que el emisor se encuentra en las coordenadas (0,0) y la confluencia de las dos paredes de la esquina en las coordenadas (0.5,-0.05) metros con un ángulo de inclinación de la pared de  $50^{\circ}$  respecto al eje  $x$  y formando la esquina un ángulo recto.

En primer lugar se analiza el eco de partida para extraer de él los diferentes subecos de que está formado y que corresponderán a los rebotes sobre las diferentes superficies de que está formada la esquina. En este caso en el eco se pueden diferenciar claramente tres subecos. De estos tres subecos, a partir de la información del máximo, conociendo la respuesta transitoria del sensor, se estima la posición de inicio y de fin de cada uno de ellos, para determinar las diferentes zonas del eco. Este cálculo se hace a partir del tiempo de máximo de los subecos, porque en muchos de los casos dichos subecos aparecen solapados y esto dificulta la obtención directa de los tiempos de vuelo.

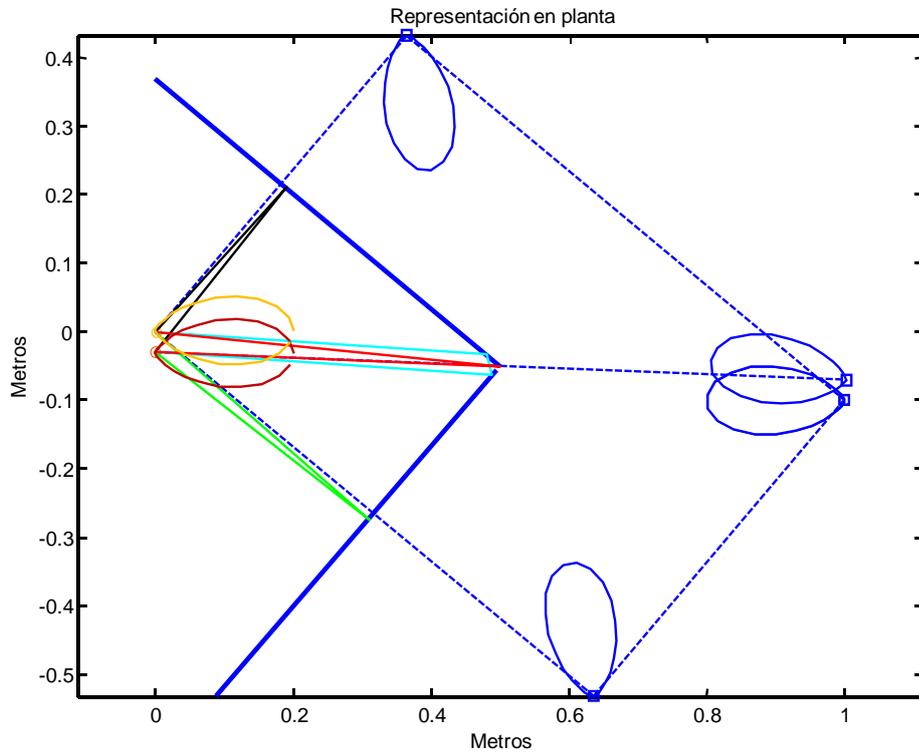


Figura 6.1: Situación en planta de la esquina respecto al par emisor-receptor

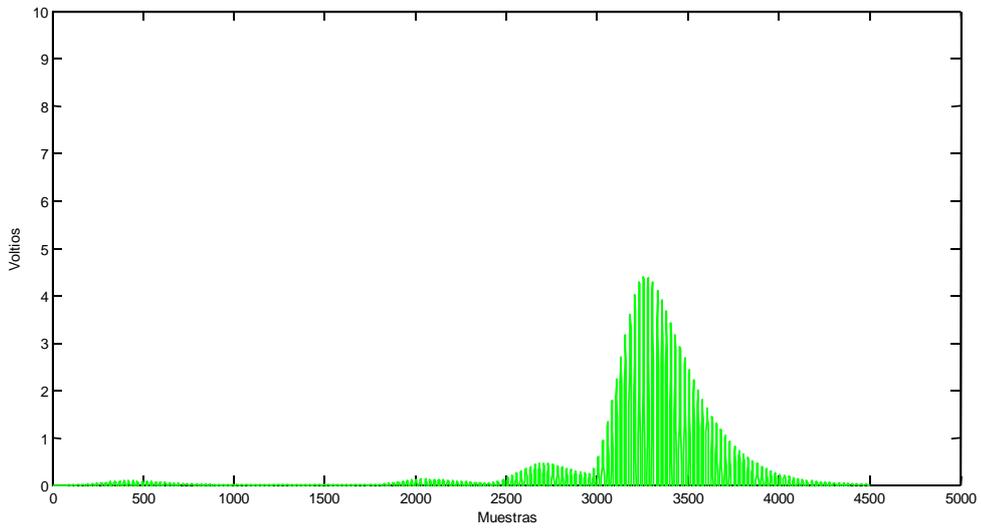


Figura 6.2: Eco incógnita a analizar.

Puede verse en la figura 6.3 los valores de tiempo de inicio, representado

por las líneas verticales azules, y de tiempo de máximo, representado por las líneas verticales verdes, calculados para cada zona del eco. En este caso el eco está dividido en cinco zonas:

$z_0 = [m_0, m_1]$ : zona de recepción directa entre emisor y receptor

$z_1 = [m_1, m_2]$ : zona de primer subeco

$z_2 = [m_2, m_3]$ : zona de segundo subeco

$z_3 = [m_3, m_4]$ : zona de tercer subeco

$z_4 = [m_4, m_5]$ : zona de fin de eco

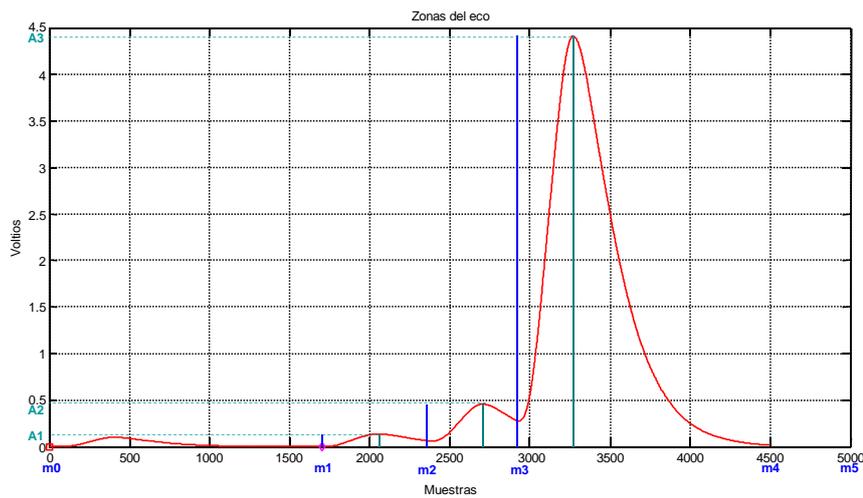


Figura 6.3: Análisis de las zonas del eco incógnita

Se muestra en la tabla 6.1 los valores numéricos obtenidos para el ejemplo mostrado en la figura 6.3.

	Subeco 1	Subeco 2	Subeco 3
Muestras Tiempo De Vuelo	1705	2354	2918
Muestras Tiempo De Máximo	2061	2710	3274
Valor Máximo en Voltios	0.1326	0.4545	4.4120

Tabla 6.1: Resultados del análisis del eco incógnita

Con los valores de tiempo de inicio de cada uno de estos subecos se puede aproximar la distancia a la que se encuentran las tres posibles superficies, pero sin conocer su posición. Esta información nos permite reducir los posibles puntos de contacto del eco con las tres superficies a los situados en tres circunferencias centradas en el emisor y con radio aproximado de la mitad de la distancia obtenida a partir del tiempo de comienzo de cada eco.

En la figura 6.4 puede verse para este ejemplo los tres arcos de circunferencia en los que aproximadamente estarían los puntos de contacto con la esquina. Partiendo de estas distancias se genera la población inicial de individuos semialeatoria, considerando que las coordenadas de la esquina pueden estar en cualquiera de estas tres semicircunferencias. En la figura 6.4 se muestran las coordenadas  $x$  e  $y$  de un ejemplo de población inicial formada por cuarenta individuos. En rojo aparecen treinta individuos pseudoaleatorios, de los cuales diez han sido seleccionados aleatoriamente a la distancia  $d_1$  desde el sensor, otros diez a la distancia a  $d_2$ , otros diez a la a distancia  $d_3$ , y en azul otros diez individuos totalmente aleatorios.

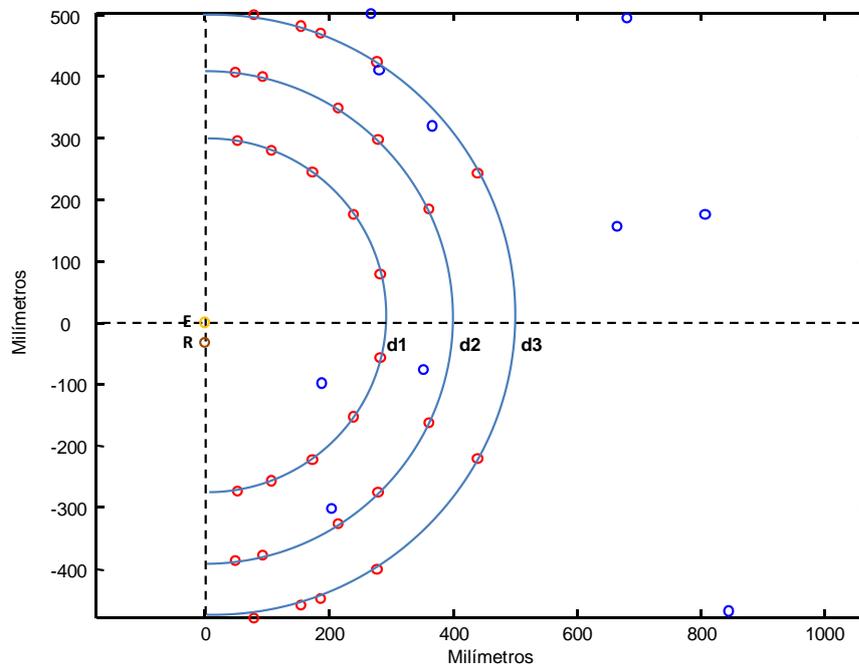


Figura 6.4: Generación semialeatoria de individuos

Se ha incluido una parte de la población de individuos totalmente aleatorios para ampliar el espacio de búsqueda en el caso de que del análisis preliminar del eco no se puedan obtener adecuadamente los subecos, como por ejemplo el caso en que quedarán muy solapados y no se pudiesen distinguir los máximos.

La función objetivo a minimizar utilizada ha sido indicada en la expresión 6.23. Donde los  $A_i$  corresponden en este caso a los valores de la amplitud máxima de los subecos del eco incógnita  $A_1$ ,  $A_2$  y  $A_3$ , calculados inicialmente y que pueden verse en la tabla 6.1 y en la figura 6.3.

A continuación, en la figura 6.5 se muestra la población de cuarenta ecos finales resultantes después de un proceso de evolución de veinte generaciones.

De estas cuarenta soluciones se muestra en la figura 6.6 la que presenta el menor valor de la función objetivo y que corresponde con una esquina situada en las coordenadas (0.502, -0.044) respecto del emisor y con una inclinación de  $50.6^\circ$ . Se muestra en azul el eco incógnita a analizar, en verde la mejor solución encontrada por el algoritmo genético y en rojo la representación de la función objetivo que se ha tratado de minimizar para encontrar la mejor solución.

En la figura 6.7 se muestra la representación en planta del individuo aceptado como mejor solución entre las cuarenta soluciones encontradas.

La evolución de los valores mínimos de la función objetivo a lo largo de las veinte generaciones puede observarse en la figura 6.8. Si se continuara su evolución se podría alcanzar una aproximación aún mejor pero a costa de incrementar el tiempo de cálculo. Dado que la precisión de medida de los sensores empleados está por encima de la precisión de la respuesta encontrada por el algoritmo genético un incremento en el número de generaciones del algoritmo no aportaría ninguna mejora. Incluso reduciendo el número de generaciones aún más se seguiría obteniendo una aproximación aceptable.

La tabla 6.2 muestra para el mejor individuo de cada generación, el valor de la función objetivo, las coordenadas obtenidas y el error de dichas coordenadas respecto al eco incógnita. En dicha tabla las coordenadas se indican en metros y los ángulos en grados. Puede observarse que a partir de la generación número trece los resultados tienen un error que está ya por debajo de la precisión que permiten los sensores de ultrasonidos empleados, como lo que no habría sido necesario dejar evolucionar el algoritmo durante tantas generaciones.

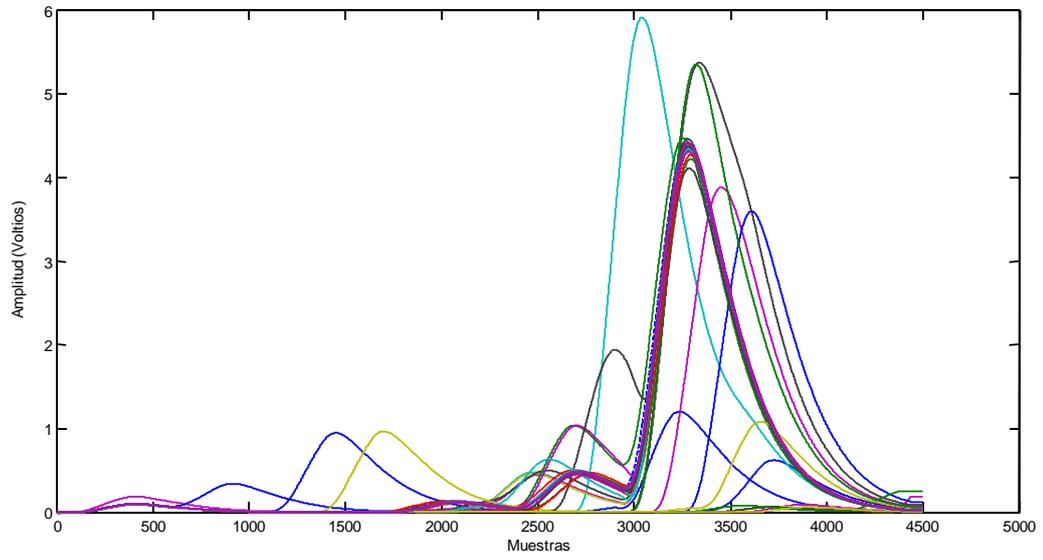


Figura 6.5: Población final

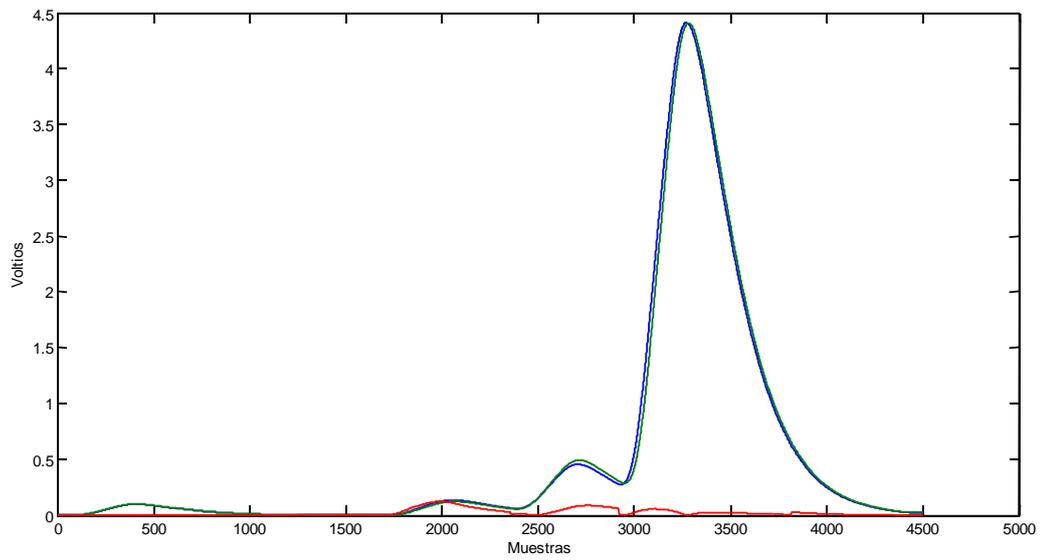


Figura 6.6: Comparativa del eco incógnita con la solución encontrada.

6. Localización de esquinas mediante algoritmos genéticos.

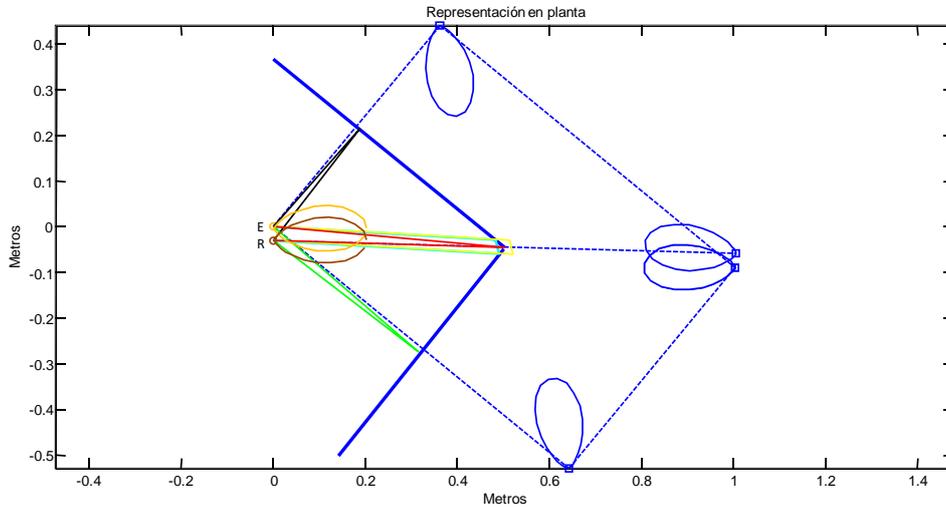


Figura 6.7: Representación en planta de la solución

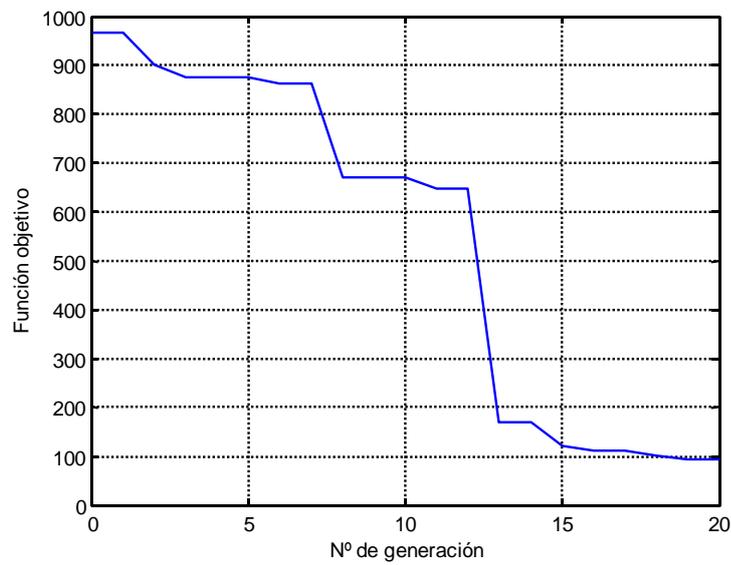


Figura 6.8: Evolución de la función objetivo

Generación	Coord x	Coord y	Ángulo	F. Obj	Error x	Error y	Error ang
0	0.172	0.233	49.800	965.505	0.3280	-0.2830	0.2000
1	0.172	0.233	49.800	965.505	0.3280	-0.2830	0.2000
2	0.439	0.229	14.500	899.153	0.0610	-0.2790	35.5000
3	0.439	0.229	14.600	875.433	0.0610	-0.2790	35.4000
4	0.439	0.229	14.600	875.433	0.0610	-0.2790	35.4000
5	0.439	0.229	14.600	875.433	0.0610	-0.2790	35.4000
6	0.439	0.228	14.600	861.687	0.0610	-0.2780	35.4000
7	0.439	0.228	14.600	861.687	0.0610	-0.2780	35.4000
8	0.503	-0.045	34.600	671.343	-0.0030	-0.0050	15.4000
9	0.503	-0.045	34.600	671.343	-0.0030	-0.0050	15.4000
10	0.503	-0.045	34.600	671.343	-0.0030	-0.0050	15.4000
11	0.503	-0.041	34.600	647.170	-0.0030	-0.0090	15.4000
12	0.503	-0.041	34.600	647.170	-0.0030	-0.0090	15.4000
13	0.503	-0.043	49.600	169.244	-0.0030	-0.0070	0.4000
14	0.503	-0.043	49.600	169.244	-0.0030	-0.0070	0.4000
15	0.503	-0.043	50.600	122.349	-0.0030	-0.0070	-0.6000
16	0.503	-0.043	50.200	111.509	-0.0030	-0.0070	-0.2000
17	0.503	-0.043	50.200	111.509	-0.0030	-0.0070	-0.2000
18	0.502	-0.043	50.600	102.530	-0.0020	-0.0070	-0.6000
19	0.502	-0.044	50.600	94.107	-0.0020	-0.0060	-0.6000
20	0.502	-0.044	50.600	94.107	-0.0020	-0.0060	-0.6000

Tabla 6.2: Coordenadas y errores del mejor individuo de cada generación

## 6.9. Ensayo 2 para la localización de esquinas.

En las figuras 6.9 y 6.10 se muestra una vista en planta y el eco incógnita correspondiente a un segundo caso en que el emisor se encuentra en las coordenadas (0,0) y la confluencia de las dos paredes de la esquina en las coordenadas (0.49,-0.19) metros con un ángulo de inclinación de la pared de  $33^\circ$  respecto al eje  $x$  y formando la esquina un ángulo recto.

En primer lugar se analiza el eco de partida para extraer de él los diferentes subecos que componen la señal recibida y que corresponderán a los rebotes sobre las diferentes superficies que conforman la esquina. Como puede verse en la figura 6.10 en el eco incógnita únicamente se pueden distinguir dos subecos,

a diferencia del eco tratado en el ejemplo anterior que estaba formado por tres subecos claramente diferenciables. De estos dos subecos, a partir de la información del máximo, conociendo la respuesta transitoria del sensor, se estima la posición de inicio y de fin de cada uno de ellos. Este cálculo, aunque en este caso los dos ecos no están nada solapados, se hace a partir del tiempo de máximo de los subecos, para usar el mismo criterio de cálculo válido para todos los casos.

Puede verse en la figura 6.11 los valores de tiempo de inicio, representado por las líneas verticales azules, y de tiempo de máximo, representado por las líneas verticales verdes, calculados para cada zona del eco. En este caso el eco está dividido en cuatro zonas:

$z_0 = [m_0, m_1]$ : zona de recepción directa entre emisor y receptor

$z_1 = [m_1, m_2]$ : zona de primer subeco

$z_2 = [m_2, m_3]$ : zona de segundo subeco

$z_3 = [m_3, m_4]$ : zona de fin de eco

Se muestra en la tabla 6.3 los valores numéricos obtenidos para el ejemplo mostrado en la figura 6.3.

Con los valores de tiempo de vuelo de estos dos subecos se calcula la distancia a la que se encuentran dos posibles superficies, pero sin conocer su posición. Esta información nos permite reducir los posibles puntos de contacto del eco a dos circunferencias centradas en el emisor y con radio aproximado de la mitad de la distancia obtenida a partir del tiempo de comienzo de cada eco.

En la figura 6.12 puede verse los dos arcos de circunferencia en los que aproximadamente estarían los puntos de contacto. Partiendo de estas distancias se genera la población inicial de individuos semialetoria. En la figura 6.12 se muestran las coordenadas  $x$  e  $y$  de la población inicial formada por treinta individuos. En rojo aparecen treinta individuos pseudoaleatorios, de los cuales diez han sido seleccionados aleatoriamente a la distancia  $d_1$  desde el sensor, otros diez a la distancia a  $d_2$ , y en azul otros diez individuos totalmente aleatorios.

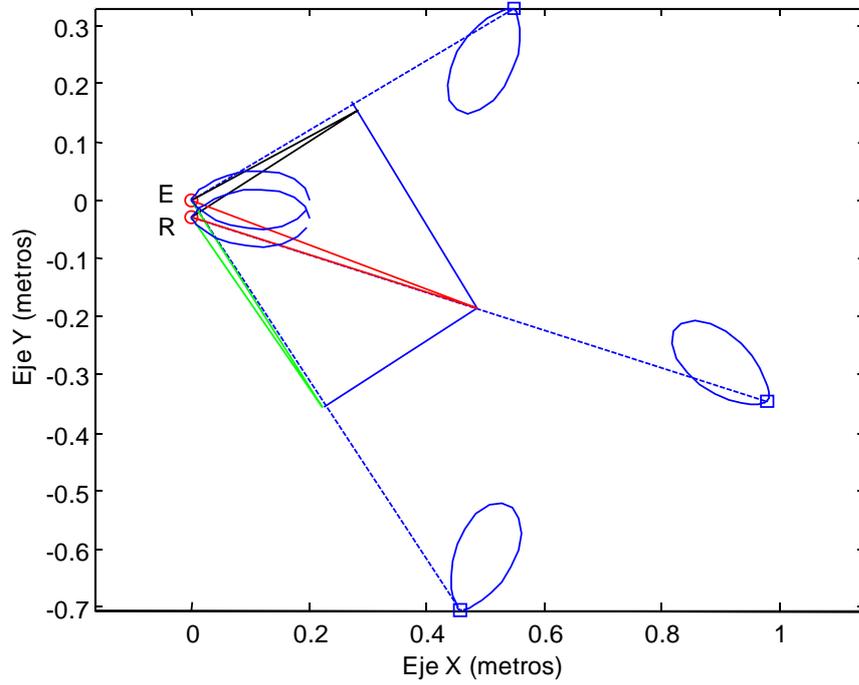


Figura 6.9: Situación en planta de la esquina incógnita

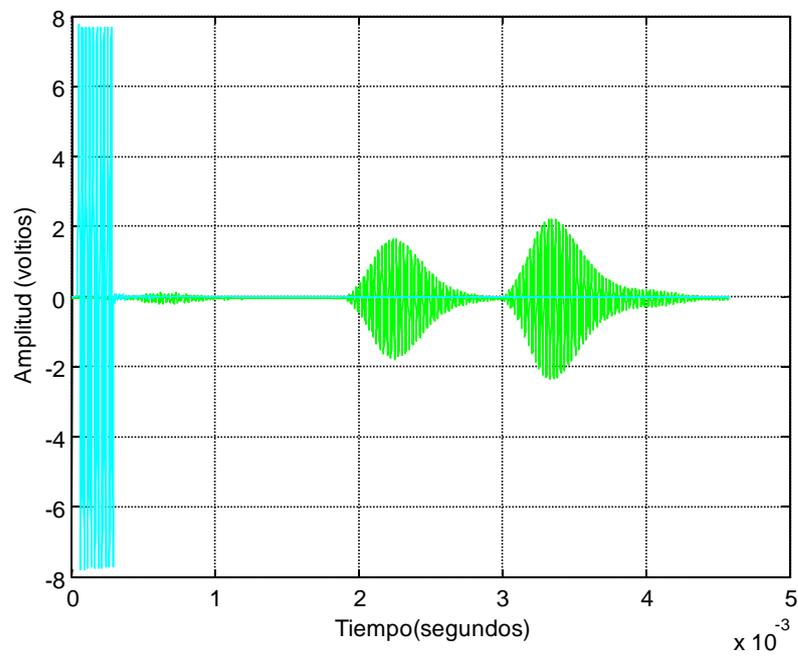


Figura 6.10: Eco incógnita

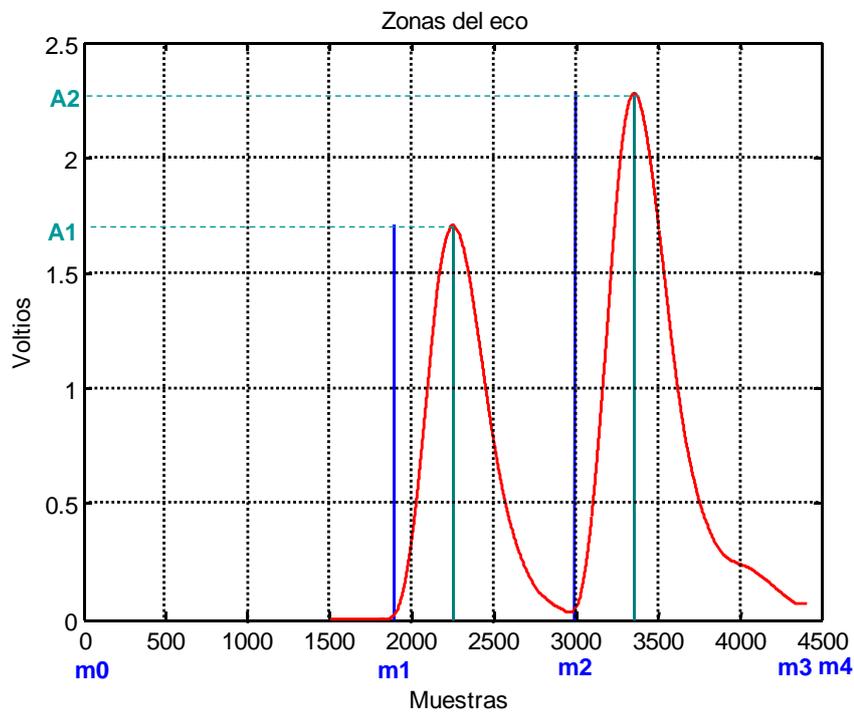


Figura 6.11: Análisis de las zonas del eco incógnita

	Subeco 1	Subeco 2
Muestras Tiempo De Vuelo	1892	2992
Muestras Tiempo De Máximo	2248	3348
Valor Máximo en Voltios	1.7105	2.2833

Tabla 6.3: Resultados del análisis del eco incógnita

Igualmente que en el ejemplo anterior se ha incluido una parte de la población de individuos totalmente aleatorios para ampliar el espacio de búsqueda.

La función objetivo a minimizar utilizada igualmente ha sido la expresión 6.23 donde ahora las amplitudes máximas corresponde a los valores  $A_1$  y  $A_2$  que se muestran en la tabla 6.3 y en la figura 6.11.

A continuación, en la figura 6.13 se muestra la población de los treinta ecos resultantes después de un proceso de evolución de veinte generaciones.

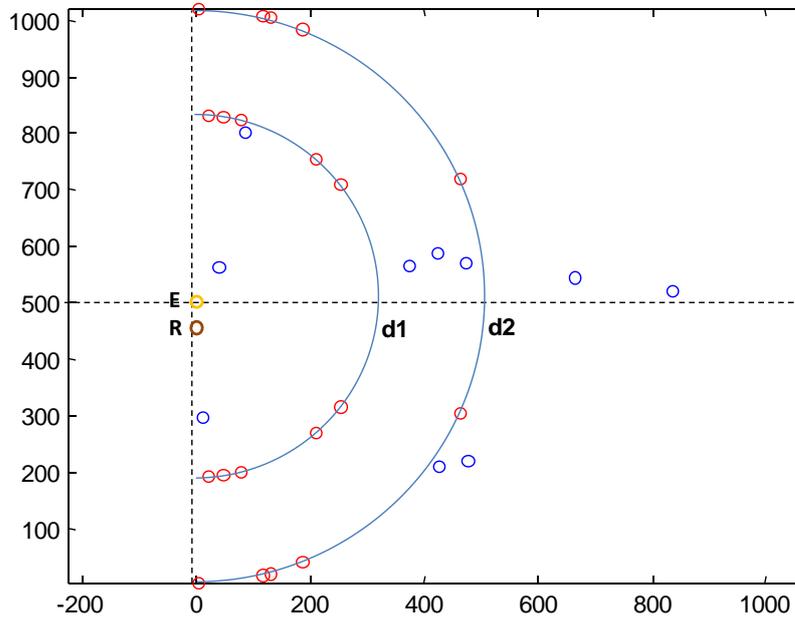


Figura 6.12: Generación semialeatoria de individuos

De estas treinta soluciones se muestra en la figura 6.14 la que presenta el menor valor de la función objetivo y que corresponde con una esquina situada en las coordenadas  $(0.476, -0.196)$  respecto del emisor y con una inclinación de  $30.2^\circ$ . Se muestra en azul el eco incógnita a analizar, en verde la mejor solución encontrada por el algoritmo genético y en rojo la representación de la función objetivo que se ha tratado de minimizar para encontrar la mejor solución.

En la figura 6.7 puede verse la representación en planta del individuo aceptado como mejor solución entre las treinta soluciones encontradas.

La evolución de los valores mínimos de la función objetivo a lo largo de las veinte generaciones se muestra en la figura 6.16. Puede observarse en este caso que a partir de la generación número dieciséis se ha estancado la evolución. Esto puede ser debido a una convergencia prematura hacia una solución que destacaba mucho de la media en generaciones previas, pero sin ser óptima.

Se incluye a continuación la tabla 6.2 que muestra para el mejor individuo de cada generación, el valor de la función objetivo, las coordenadas obtenidas y el error de dichas coordenadas respecto al eco incógnita. En dicha tabla las coordenadas se indican en metros y los ángulos en grados.

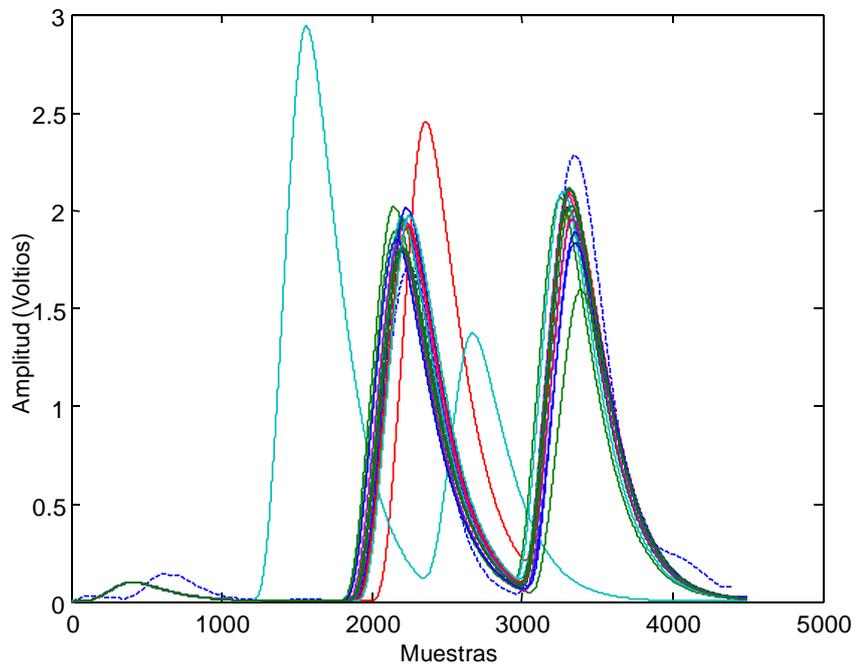


Figura 6.13: Población final

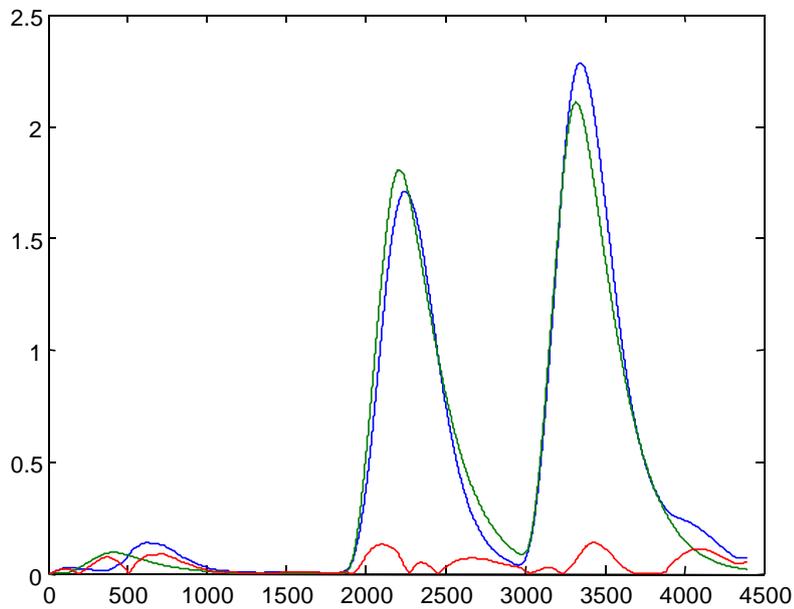


Figura 6.14: Comparativa del eco incógnita con la solución encontrada

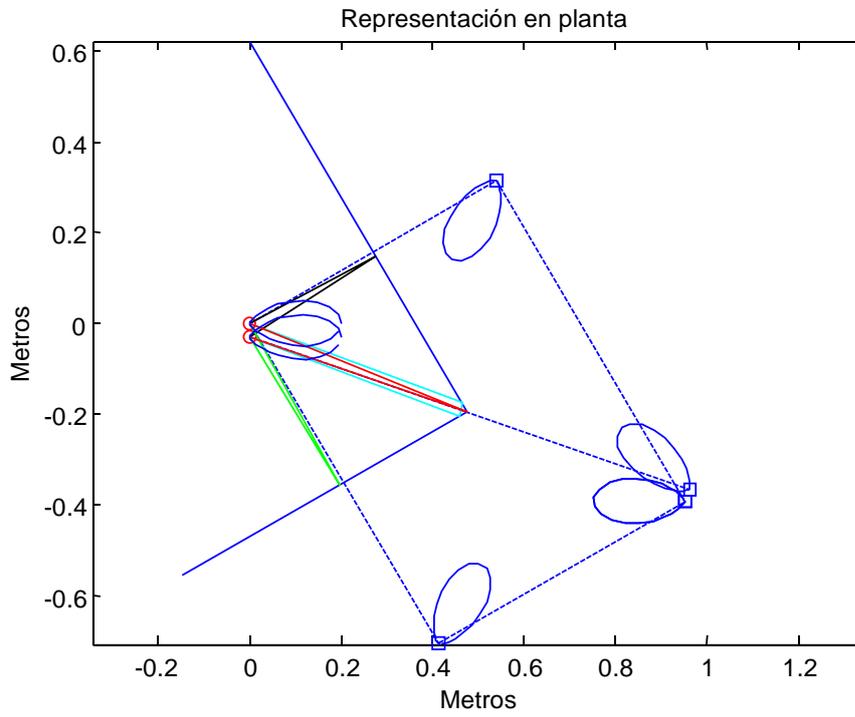


Figura 6.15: Vista en planta de la solución

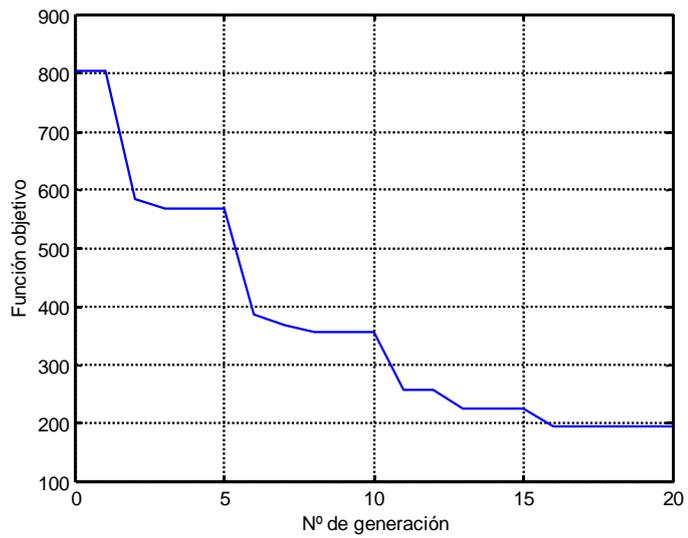


Figura 6.16: Evolución de la función objetivo

Gción	Coor x	Coor y	Ángulo	F. Obj	Error x	Error y	Error ang
0	0.464	0.208	28.700	804.570	0.026	-0.398	4.3
1	0.464	0.208	28.700	804.570	0.026	-0.398	4.3
2	0.464	0.192	28.700	583.482	0.026	-0.382	4.3
3	0.464	0.208	31.900	566.753	0.026	-0.398	1.1
4	0.464	0.208	31.900	566.753	0.026	-0.398	1.1
5	0.464	0.208	31.900	566.753	0.026	-0.398	1.1
6	0.464	-0.208	29.400	386.517	0.026	0.018	3.6
7	0.464	-0.208	28.700	367.392	0.026	0.018	4.3
8	0.466	-0.208	29.400	354.763	0.024	0.018	3.6
9	0.466	-0.208	29.400	354.763	0.024	0.018	3.6
10	0.466	-0.208	29.400	354.763	0.024	0.018	3.6
11	0.472	-0.200	29.400	256.684	0.018	0.010	3.6
12	0.472	-0.200	29.400	256.684	0.018	0.010	3.6
13	0.476	-0.196	29.400	223.523	0.014	0.006	3.6
14	0.476	-0.196	29.400	223.523	0.014	0.006	3.6
15	0.476	-0.196	29.400	223.523	0.014	0.006	3.6
16	0.476	-0.196	30.200	193.210	0.014	0.006	2.8
17	0.476	-0.196	30.200	193.210	0.014	0.006	2.8
18	0.476	-0.196	30.200	193.210	0.014	0.006	2.8
19	0.476	-0.196	30.200	193.210	0.014	0.006	2.8
20	0.476	-0.196	30.200	193.210	0.014	0.006	2.8

Tabla 6.4: Coordenadas y errores del mejor individuo de cada generación

## 6.10. Resumen y conclusiones

Se este capítulo se ha propuesto un método de identificación y localización de esquinas que sirve de apoyo a la generación de trayectorias para robótica móvil.

Para ello se ha empleado el modelo de reflexión de ecos sobre superficies cóncavas desarrollado en el capítulo 5 en el que se propuso una solución programada para la propagación de señales 5.3 tanto para la onda incidente como para la onda reflejada teniendo en cuenta el efecto de la forma transitoria del eco dependiente del número de pulsos de la señal de excitación, la dinámica del sensor, así como el efecto de los patrones de radiación de los sensores. También

se propuso en dicho capítulo una solución programada para las reflexiones que se producen sobre superficies tales como paredes planas y esquinas. El modelo final que engloba todo el problema de forma conjunta resulta complejo y no aparece formulado por una expresión matemática única, sino que su programación conlleva múltiples llamadas a diferentes funciones.

En este capítulo se ha planteado realizar la secuencia inversa del proceso. Es decir, en vez de obtener el eco que corresponde a una determinada situación entre el par de sensores emisor-receptor y la esquina insonificada, lo que se busca es capturar un eco y de ahí ser capaces de estimar la posición respecto al elemento sensor en que se encuentra la esquina.

Se ha propuesto como método de resolución del problema la aplicación de algoritmos genéticos ya que permiten encontrar soluciones en aquellos problemas que no están formulados matemáticamente. Así, mediante un proceso iterativo de búsqueda el algoritmo genético programado es capaz de encontrar una solución adecuada con una precisión razonable.

El algoritmo genético programado ha sido enfocado a su uso en aplicaciones en tiempo real, reduciendo lo más posible la carga computacional para poder plantear su aplicación directa en la generación de trayectorias por un robot móvil durante su movimiento. Así los operadores genéticos empleados han sido seleccionados y parametrizados para trabajar con pequeñas poblaciones de individuos y obtener resultados en un número reducido de generaciones. Esto conlleva que las soluciones no van a ser tan óptimas como sería deseable pero que conociendo las precisiones que se obtienen cuando se trabaja con la información proveniente de señales ultrasónicas están dentro de un margen aceptable.

Se ha probado su funcionamiento mediante ejemplos, pudiéndose comprobar que genera soluciones con un margen de error aceptable.

Este modelo que aquí se ha aplicado a las esquinas en ángulo recto, por ser las más comunes, sirve igualmente para cualquier otro tipo de esquinas, ya que el desarrollo contemplado en el capítulo 5 permite tener en cuenta cualquier disposición y forma de los dos planos que forman la esquina.



# Capítulo 7

## Contribuciones y trabajos futuros.

### 7.1. Principales aportaciones y futuras líneas de investigación.

Las principales aportaciones de este trabajo de tesis son las siguientes:

- Se han propuesto y diseñado diferentes estructuras sensoriales adaptadas al reconocimiento y clasificación de objetos en diferentes tipos de aplicaciones industriales y se han implementado junto con las etapas de adaptación de señal y control necesarias para realizar la toma automatizada de datos desde el PC.
- Se han propuesto y evaluado diferentes configuraciones de redes neuronales comprobando su comportamiento como clasificadores de patrones en tareas de reconocimiento de formas y la orientación de piezas basado en la información aportada por las características extraídas desde la envolvente del eco.
- Se han propuesto y evaluado diferentes sistemas difusos comprobando su funcionamiento como métodos de mejora de la reconstrucción tridimensional de objetos obtenida a partir de las señales ultrasónicas.

- Se ha caracterizado la respuesta temporal de los sensores de ultrasonidos de baja frecuencia que trabajan mediante la técnica pulso-eco y se ha llegado a obtener un modelo del transitorio del eco.
- Para el estudio de las esquinas se ha diseñado e implementado una estructura sensorial, para una configuración formada por un emisor y dos receptores, que permite el ajuste automático de la separación entre los sensores, así como la orientación y la separación de la estructura sensorial respecto de la esquina. Y se ha programado su control para poder ser manejado desde Matlab y sincronizar su movimiento con la captura de datos.
- Se ha propuesto y programado un modelo de transmisión de las ondas ultrasónicas en el aire que permite simular la respuesta recibida en los sensores receptores ante pulsos de excitación en el sensor emisor.
- Se ha propuesto y programado un modelo de la reflexión de los ultrasonidos para paredes y esquinas cóncavas enfocado a poder calcular la respuesta recibida en un sensor ante situaciones que se pueden dar en la navegación autónoma de robots en entornos cerrados estructurados.
- Se ha programado un algoritmo genético para la localización de esquinas en navegación autónoma basándose en los modelos de transmisión y reflexión anteriormente propuestos.

Entre los trabajos futuros a seguir desarrollando cabe señalar:

- Ampliar el estudio del trabajo desarrollado con la programación de la respuesta en entornos estructurados para que sea aplicable a otros escenarios más complejos.
- Ampliar el estudio del trabajo desarrollado sobre la detección de esquinas mediante algoritmos genéticos para que sea aplicable a otros escenarios más complejos.
- Implantar el sistema de detección de esquinas embarcado en un robot móvil para realizar la validación final del procedimiento.

- Utilizando la experiencia del grupo en visión por computador, fusionar la información tridimensional de baja resolución que aportan los ultrasonidos a la imagen bidimensional de alta resolución que aporta la visión para mejorar la reconstrucción del entorno.
- Cabe señalar que se ha empezado ya a desarrollar un método de mejora de la reconstrucción tridimensional basada en sensores de ultrasonidos de baja frecuencia empleando la descomposición del eco en subecos y las características de cada uno de ellos. En el siguiente apartado se muestran los trabajos iniciales ya realizados.
- Ampliar la metodología de la reconstrucción tridimensional basada en subecos para que sea aplicable a escenas más complejas.
- Emplear técnicas fuzzy para implementar las reglas de mejora en la reconstrucción basada en subecos, y de esa forma poder manejar la incertidumbre que presentan las señales.

## 7.2. Primeros trabajos en las futuras líneas de investigación. Reconstrucción tridimensional de imágenes ultrasónicas basada en la descomposición en subecos.

### 7.2.1. Introducción

Después del estudio sobre la transmisión de las señales de ultrasonidos y el análisis y modelado realizados en los capítulos 4 y 5 se pretende ahora aplicar dichos análisis a la reconstrucción tridimensional de imágenes ultrasónicas.

Por tanto, en este apartado se va plantear un método de mejora de la reconstrucción tridimensional de objetos obtenida a partir de los ecos ultrasónicos, analizando para ello la información contenida en el eco en mayor profundidad, en vez de emplear únicamente el tiempo de vuelo como método de cálculo de la distancia al objeto.

Una vez analizada la propagación de las señales ultrasónicas en el capítulo 5, se ha visto que el eco ultrasónico que se recibe de insonificar un determinado objeto no está formado por una única señal proveniente de un único punto, sino que está formada por todos los posibles rebotes de las superficies que se encuentren en su campo de visión.

Este campo de visión puede ser estrecho, como ocurre cuando se emplean sensores de alta frecuencia, donde el lóbulo principal del patrón de radiación abarca un rango angular muy reducido como puede verse por ejemplo en el patrón de radiación mostrado en la figura 1.5, y permite enfocar una pequeña superficie del objeto. Pero el empleo de sensores de alta frecuencia conlleva el inconveniente de que el rango de distancias a las que se puede trabajar también es muy reducido, ya que las señales de alta frecuencia se atenúan rápidamente con la distancia, como se deduce de la expresión 1.5 de la amplitud de la presión emitida por un sensor emisor.

En este trabajo, para tener un margen más amplio de distancias de utilización se han empleado sensores que trabajan a baja frecuencia. El inconveniente asociado será un lóbulo de radiación mucho más ancho, como puede verse en

el ejemplo de patrón de radiación de la figura 1.2, y por tanto una visión ultrasónica con un único sensor de un entorno muy amplio.

Esto que en principio se plantea como un desventaja tiene también su parte beneficiosa, ya que desde otro punto de vista, permite, con único sensor, abarcar una zona muy amplia en la detección de objetos.

Se plantea por tanto en este apartado, utilizando sensores con un lóbulo de radiación ancho, encontrar una forma de estrecharlo mediante el procesamiento de dicha señal. Es decir, conseguir estrechar la visión de los sensores para quedarse exclusivamente con la información de la zona que queremos visualizar, desechando la información del resto.

Se va a realizar una toma de ecos homogénea, en forma de barrido, mediante un array de sensores, sobre toda la zona del objeto a reconstruir y se analizarán diferentes parámetros extraídos de dichos ecos, intentando encontrar para cada uno de estos parámetros las ventajas que aportan a la reconstrucción así como también sus inconvenientes. Con esta selección de parámetros se pretende mejorar la reconstrucción tridimensional de objetos basada en ultrasonidos.

### **7.2.2. Equipamiento y hardware desarrollado para la experimentación.**

Para la toma de datos se ha preparado un recinto acotado (ver figura 7.1) formado por un superficie plana sobre la que se van a situar los objetos a reconstruir. La toma de datos se ha realizado empleado un par de sensores de ultrasonidos emisor-receptor SensComp 40LT16/40LR16 (ver tabla 1.2) montados sobre un brazo robotizado Fanuc Robot LR Mate 200iC que nos permitirá automatizar el posicionamiento de los sensores sobre el objeto en las direcciones  $x$ ,  $y$  y  $z$ . Los sensores se encuentran alojados en un array de 3x3 según se muestra en la figura 7.2 estando el sensor emisor en el centro del array y ocho sensores receptores rodeándolo, lo que permite seleccionar en cada caso la disposición física entre emisor y receptor que mejor convenga.

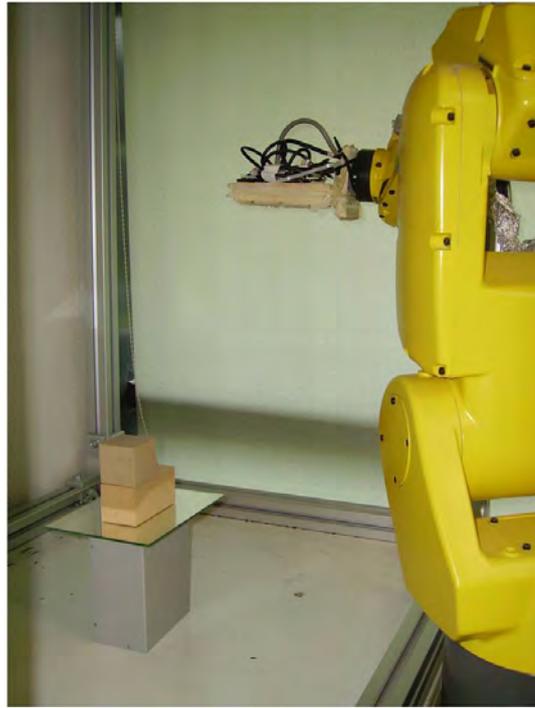


Figura 7.1: Disposición física del equipamiento.



Figura 7.2: Array de sensores

Se ha programado dicho robot para realizar barridos sobre el objeto en las direcciones  $x$  e  $y$ , manteniendo constante la distancia  $z$ , de tal forma que se obtenga una matriz de ecos correspondiente a una malla de  $n \times m$  posiciones según se muestra en la figura 7.3, donde  $n$  es la resolución en el eje  $x$  y  $m$  es la resolución en el eje  $y$ . De esta forma el incremento de paso en los ejes  $x$  e

$y$ , así como la distancia de los sensores al objeto es ajustable en función de dimensiones, en vez de ser fija como sería el caso de haber realizado un array estático de sensores que cubriera la zona de trabajo.

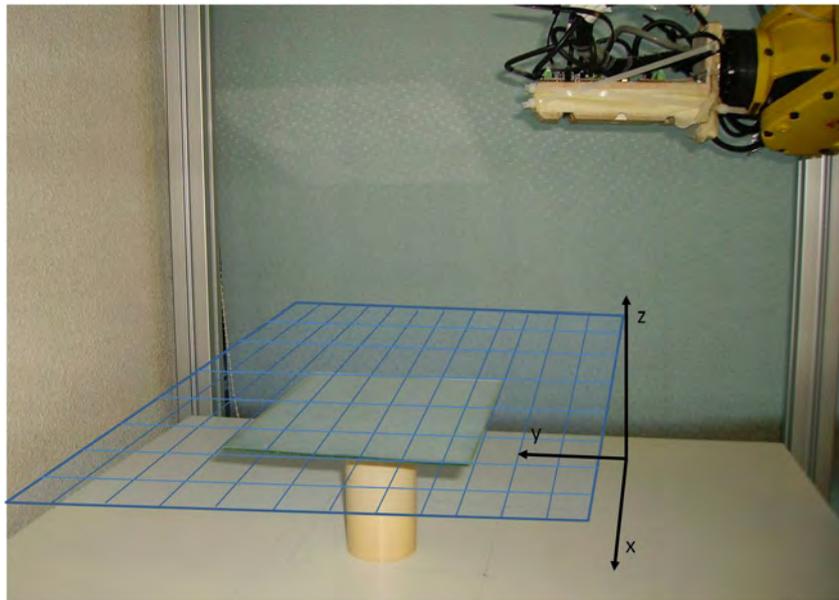


Figura 7.3: Montaje del experimento

Para la generación de la señal de excitación del sensor emisor y para la toma de los ecos provenientes del sensor receptor se ha empleado una tarjeta de adquisición de datos National Instrument modelo PCI-6115. Se ha programado la generación del pulso de excitación y la captura de los ecos sincronizando estas tareas con los movimientos del robot. Para ello se han empleado las entradas y salidas digitales del robot y las entradas y salidas digitales de la tarjeta de adquisición de datos. La señal de excitación generada mediante la tarjeta de adquisición de datos no posee los niveles de tensión y potencia necesarios para excitar al sensor (20 Vrms max.) por lo es necesario aumentar la potencia y nivel de tensión de dicha señal mediante una etapa de amplificación. En cuanto a las señales recibidas en los sensores receptores ocurre igualmente que la señal es de muy baja potencia, por lo que también se ha añadido una etapa amplificadora adecuada para mejorar el ratio señal-ruido y para mejorar la resolución en la conversión analógica-digital. También, como se ha planteado

una configuración de ocho sensores receptores seleccionables, se ha añadido una etapa de multiplexores analógicos que permita seleccionar la señal que recibe el canal de adquisición de datos de la tarjeta. Se muestra en la figura 7.4 las etapas de amplificación y multiplexado analógico que se han desarrollado y en la figura 7.5 un diagrama de bloques del sistema de emisión y recepción.

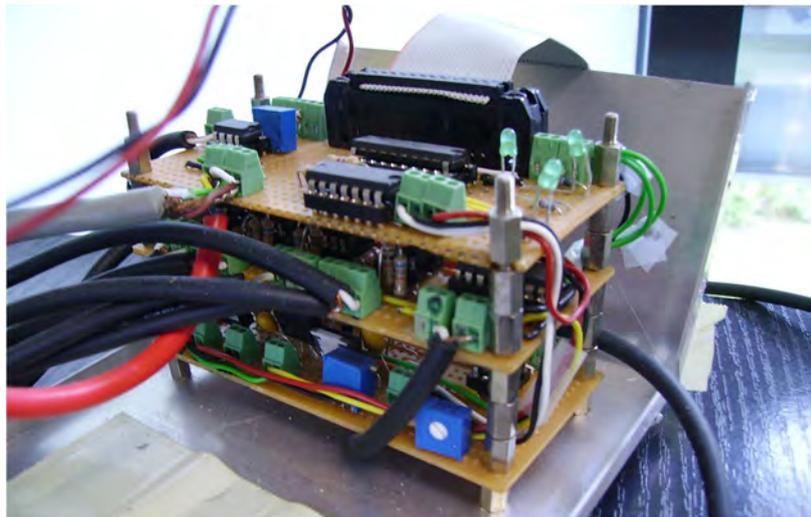


Figura 7.4: Etapas de amplificación utilizadas

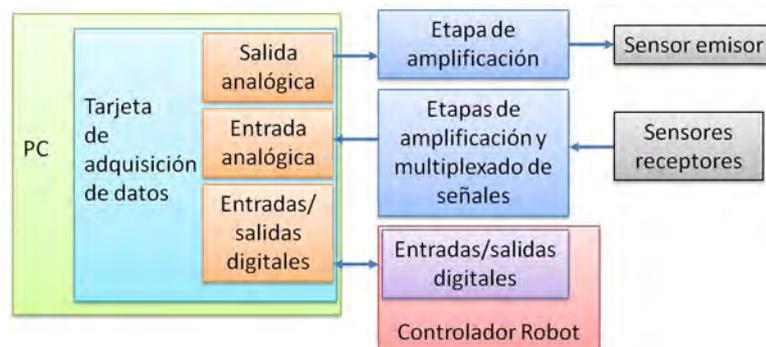


Figura 7.5: Diagrama de bloques de la emisión-recepción.

### 7.3. Extracción y análisis de características del eco.

El procesado inicial del eco será el mismo que se ha utilizado en los capítulos anteriores. Partiendo de cada eco capturado, como por ejemplo el mostrado en la figura 7.6 a), en primer lugar se calcula su envolvente empleando la expresión 1.15 para eliminar la portadora a 40 KHz.

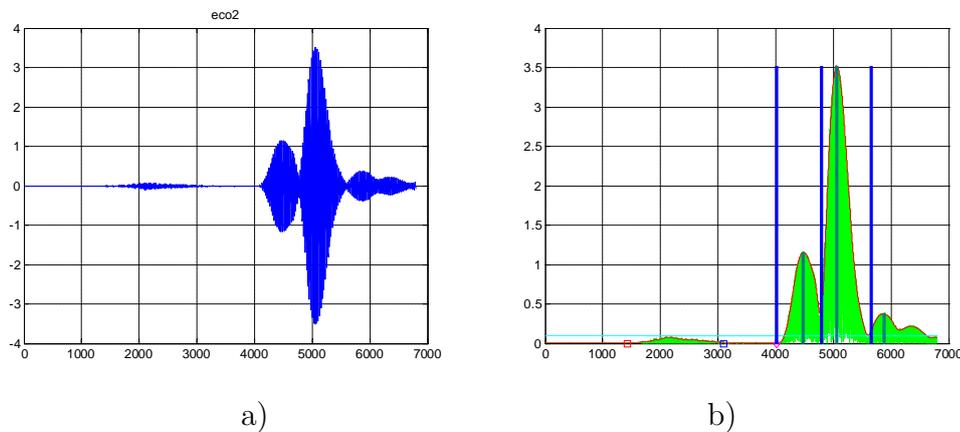


Figura 7.6: a) Muestra de eco y b) Envolvente y subecos

Seguidamente se procede a calcular los máximos y mínimos de la envolvente para así, identificar los diferentes subecos de que está formada la señal capturada.

Puede verse en la figura 7.6b) dicho eco rectificado, en verde, acompañado de su envolvente, en rojo y diferenciadas las zonas del eco, comenzando cada una de ellas en las líneas verticales azules y teniendo su máximo en las líneas verticales verdes. Puede observarse que el principio del segundo eco queda solapado con el final del primer eco. Esto quiere decir que no ha terminado el transitorio del primer eco cuando aparece el segundo debido a la proximidad en distancia de las dos superficies. Si se emplea el mínimo local que presenta la envolvente éste no reflejará el valor real del comienzo del eco. Se plantea por tanto realizar la misma modificación propuesta en el capítulo 6, es decir, tener en cuenta el tiempo del transitorio del eco analizado en el apartado 4.3. De esta forma se partirá de los tiempos obtenidos para los máximos de cada

eco y se corregirán los tiempos de comienzo de los subecos con el tiempo del transitorio del sensor empleado.

El empleo del tiempo de máximo corregido permite evitar que subecos recibidos debido a los lóbulos laterales del sensor, que tienen mucha menor potencia, sean considerados como más importantes al aparecer temporalmente por delante del que en realidad es el subeco principal.

En la figura 7.7 a) se muestra un eco en el que el eco principal se encuentra en primer lugar y solapado posteriormente en parte con un segundo eco, pero de tal forma que se distingue perfectamente la existencia de dos subecos diferentes, ya que la señal presenta un mínimo local entre ellos. Y En la figura 7.7 b) puede verse un caso de solapamiento de subecos donde un pequeño subeco secundario aparece por delante del eco principal. En este caso, sin hacer correcciones, el tiempo de vuelo quedaría definido por el eco secundario y enmascararía el tiempo de vuelo del eco principal.

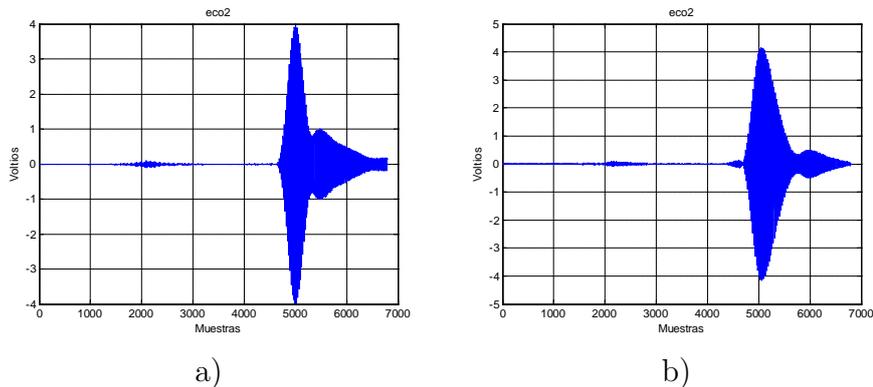


Figura 7.7: Eco a) sin solapamientos, b) con solapamiento en la zona del cálculo del tiempo de vuelo.

También puede verse en la figura 7.8 a) un caso en el que el subeco principal se solapa totalmente con el subeco anterior dando la sensación de un alargamiento en el transitorio de subida del subeco principal. Y en la figura 7.8b) se observa otro caso donde el subeco principal se solapan tanto con un subeco anterior, como con un subeco posterior alargando tanto el transitorio de subida como el de bajada. En cualquiera de los dos casos considerados el tiempo de vuelo real del eco principal es el mismo, pero debido a la influencia

del eco secundario la medida del tiempo de vuelo podría resultar falseada. En el caso de la figura 7.8b) la diferencia entre el comienzo del subeco secundario y el punto donde comenzaría el subeco principal está en el entorno de las 300 muestras. Como el periodo de muestreo empleado es de  $1\mu\text{s}$  corresponde con un tiempo de  $300\ \mu\text{s}$  que traducido en distancia recorrida por el eco sería:

$$e(\text{metros}) = \frac{1}{2} \cdot 300 \cdot 10^{-6} \cdot 340 = 0,051 \quad (7.1)$$

Es decir el objeto parecería estar  $5\text{cm}$  más próximo al sensor de lo que realmente está.

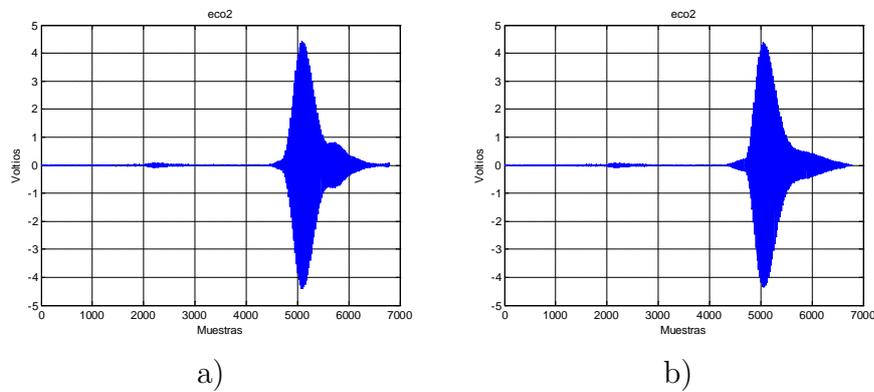


Figura 7.8: Solapamiento total del subeco principal con subeco secundario a) anterior, b) anterior y posterior.

También se ha observado que, debido a que los ecos ultrasónicos presentan bastante ruido debido a la aparición de perturbaciones, el cálculo del tiempo de vuelo aún empleando el método de correlación de señales puede no dar resultados correctos, por ejemplo porque la perturbación supere el nivel de correlación empleado. En cambio la información del tiempo transcurrido hasta el valor máximo es más estable a las perturbaciones debido a que la relación señal-ruido en ese punto es mayor. Eso si, conlleva tener que traducir dicho tiempo al tiempo de comienzo según la dinámica del sensor empleado, como se vio en el capítulo 4.

Otra ventaja del cálculo de los valores máximos de los subecos es que además el valor máximo discrimina automáticamente qué subeco (si hay varios componiendo la señal) es el dominante, ya que tomar el tiempo de vuelo del

primer eco hace que aunque este primer eco tenga una potencia muy débil se siga considerando como principal, cuando en muchos casos el segundo eco puede tener mucha mayor potencia e indicar que aunque se está viendo más lejos está más en la vertical del sensor, que es donde el patrón de radiación del sensor presenta mayor ganancia. Esta característica va a ser útil para reducir el campo de visión de los sensores que tienen un lóbulo de radiación muy ancho y por lo tanto son capaces de seguir viendo un determinado objeto aunque el sensor se encuentre ya alejado gracias a su capacidad de visión lateral.

Se van a seguir utilizando sensores de baja frecuencia intentando modificar vía software el campo de visión que vez de emplear sensores de más alta frecuencia que plantearían otra serie de inconvenientes como son un rango de distancias de trabajo menor. Además el tener capacidad de una mayor visión lateral puede tener sus ventajas ya que permite saber con bastante antelación la presencia de nuevos objetos que vayan apareciendo en la escena.

Se va a exponer este método de reducción del campo de visión tomando como ejemplo la reconstrucción de un espejo de dimensiones 200x150 mm situado a una altura de 100 mm del suelo como el que se muestra en la figura 7.3. Para ello se ha realizado un barrido sobre la pieza mediante el movimiento del array situado en la pinza del robot en las direcciones  $x$  e  $y$  mostradas en la figura, generando una malla de datos tal como se muestra superpuesta en la figura 7.3. Para la zona a cubrir con el barrido, de dimensiones 600 mm de largo por 700 mm de ancho, se han realizado capturas de los ecos cada 5 mm de desplazamiento tanto en el eje  $x$  como en el eje  $y$ , generándose una matriz bidimensional con todos los ecos. La distancia en el eje  $z$  permanece constante durante todo el barrido y ha de ser lo suficientemente distante de la pieza para que no se mezclen los segundos rebotes de las superficies más cercanas al array con los primeros rebotes de las superficies más lejanas.

En primer lugar se va a analizar la información aportada por el primer eco, que corresponderá a la detección del objeto más cercano al array. Como la toma de datos se realiza desde la parte superior del objeto, estando el sensor siempre situado a una distancia constante del suelo, estos tiempos son directamente traducibles mediante la expresión 1.1 en las distancias existentes entre el objeto y el sensor. Para su representación se han convertido estas distancias a valores

relativos desde el suelo, al que se le ha dado la coordenada  $z$  de valor 0. Se incluye en líneas negras las dimensiones reales de la superficie del espejo.

En primer lugar, para cada uno de los ecos, se ha calculado el tiempo de vuelo empleando la correlación cruzada con la señal de emisión y se ha realizado la reconstrucción del objeto, calculándose la matriz de distancias basándose en dicho tiempo de vuelo. Se muestra en la figura 7.9a) la forma del objeto reconstruido a partir de esta característica. En esta representación no se ve el cambio abrupto de altura que debería existir entre espejo y suelo.

En segundo lugar, se ha calculado el tiempo del mayor máximo presente en cada uno de los ecos y se ha calculado la matriz de distancias para la reconstrucción basándose en la corrección del tiempo de máximo a tiempo de inicio mediante el transitorio del eco como se muestra en la figura 7.9b). Puede observarse que los dos planos paralelos que definen la imagen se muestran más claros. También se observa que mientras el eco de la superficie superior sea mayor en amplitud, aunque ya lo esté viendo lateralmente, que el eco del suelo seguirá considerando que existe el plano superior, por lo que los objetos así reconstruidos parecerán tener unas dimensiones mayores a las reales. El incremento del área correspondiente a la superficie del espejo sigue siendo patente. Puede observarse incluso que por la zona correspondiente a los valores más grandes en valor absoluto del eje  $x$  ni siquiera llega a verse información del suelo.

Continuando con el análisis de la información aportada por el primer eco se analizan a continuación otros dos parámetros de dicho eco, como son el valor de amplitud máxima y la energía según se definió en el capítulo 1 en la expresión 1.18. Puede observarse, en su representación en la figura 7.10a) y b) como estas variables, salvo por cambio de escala aportan prácticamente la misma información. Puede verse cómo presentan valores máximos cuando claramente el sensor está únicamente viendo la superficie superior, y como presenta valores mínimos cuando únicamente está viendo el suelo. Estas variables sí que presentan un cambio más claro en los bordes del espejo, siendo más pronunciado en caso de las amplitudes máximas, figura 7.10 a).

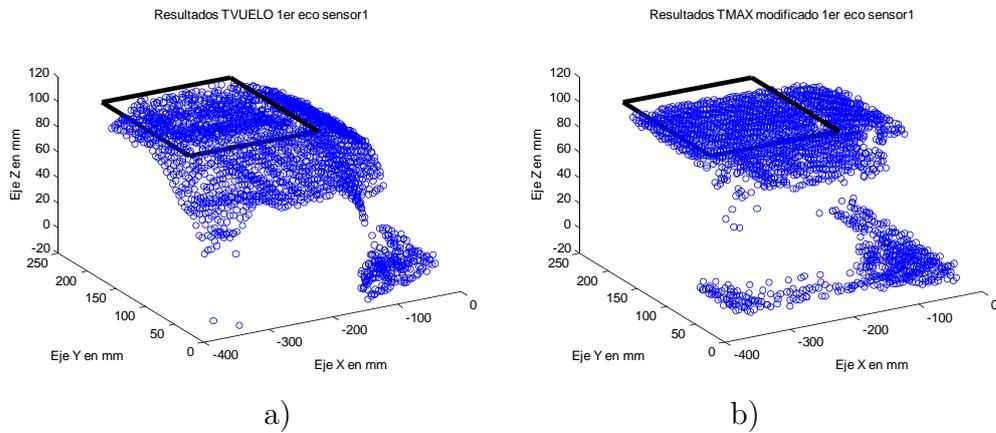


Figura 7.9: Reconstrucción a partir de a) tiempo de vuelo , b) tiempo de máximo del primer eco

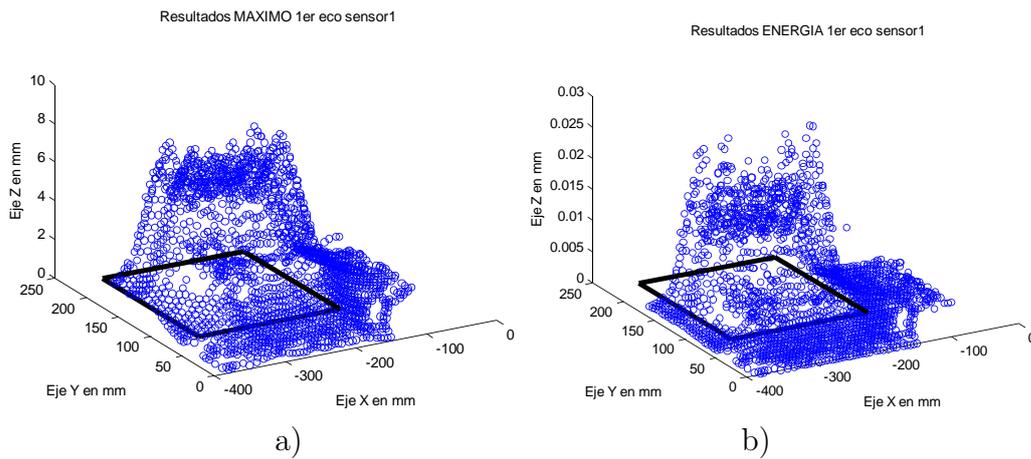


Figura 7.10: Representación de los valores de a) amplitudes máximas , b) energía del primer eco.

Para la mejora de la imagen se propone añadir información del segundo eco a la reconstrucción y para ello se toma ahora el segundo eco de la señal y se analizan las mismas variables, para intentar combinar la información de los dos ecos o decidir en cada punto cual de los dos ecos es más relevante. La presencia de un segundo eco aporta ya en principio que el sensor está viendo simultáneamente las dos superficies, suelo y espejo. Por tanto este no va a existir en todos los puntos del barrido sino sólo en aquellos en que se

produce la transición de la visualización de una superficie a otra. Pueden verse en las figuras 7.11a) y b) la representación gráfica para el segundo eco del tiempo de comienzo y tiempo de máximo, y en la figura 7.12a) y b) la máxima amplitud y energía. Así para la variable tiempo de comienzo del segundo eco, puede observarse en la figura 7.11 a) que para los valores de  $x$  más extremos y para los valores de  $y$  más pequeños este tiempo se traduce en distancias con coordenada  $z$  en torno a cero, lo cual corresponde al suelo. También en la parte central de la pieza no aparecen valores, es decir, no hay segundo eco, lo que quiere decir que no ve el suelo. Aparecen también en la gráfica una serie de puntos con coordenada  $z$  negativa, lo que se traduciría en que está viendo objetos mucho más lejos que el suelo, lo cual es imposible, esto es debido a que cuando no existe un segundo eco a la distancia del suelo, tomará como segundo eco el siguiente que aparezca en la señal, que corresponderá por ejemplo a segundos rebotes o a la visión de otros elementos del entorno como en nuestro caso la estructura que rodea la zona de experimentación. Estos efectos pueden eliminarse inicialmente analizando los ecos hasta los tiempos que corresponden por distancia a la recepción del suelo y descartando el resto de señal.

Con la información aportada por el tiempo de máximo, que se representa gráficamente en la figura 7.11b) ocurre lo mismo que en el primer eco, muestra una información más uniforme y marca mejor los límites entre ambas superficies, pero necesita la corrección de distancias de máximo a comienzo del eco. Puede verse claramente la representación de la superficie del suelo, y el hueco central donde no existe segundo eco ya que sólo está viendo la superficie del espejo.

Igualmente que para el primer eco, las variables de valor máximo y potencia del segundo eco, figura 7.12 aportan a diferentes escalas la misma información y van a permitir conocer la importancia que tiene este segundo eco respecto al primero en cada punto considerado, así cuando su amplitud relativa respecto al primer eco sea reducida nos dirá que ese eco no es el principal y a la inversa, cuando su valor relativo respecto al primer eco sea alto éste será el eco más importante en ese punto.

Una vez analizados por separado cada uno de los parámetros del eco se realiza ahora la reconstrucción 3D del objeto combinando la información de

dichos parámetros. En primer lugar, se muestra en la figura 7.13a) la reconstrucción basada en el tiempo de comienzo del eco ponderado por la amplitud de la señal, seleccionando siempre para el cálculo de la distancia el tiempo de comienzo de aquel subeco que presente mayor señal, independientemente de que sea el primero o el segundo. Comparando esta reconstrucción con la obtenida a partir del tiempo de vuelo, mostrada en la figura, 7.9a) , puede observarse que resulta más precisa aunque sigue mostrando en las zonas de transición entre las dos superficies variaciones importantes respecto a la situación real.

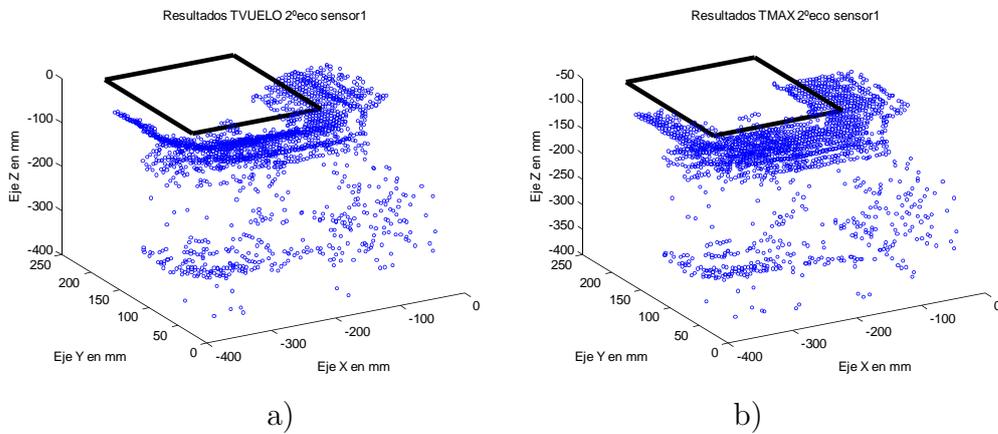


Figura 7.11: Representación de la distancia correspondiente a a) tiempo de comienzo b) tiempo de máximo del segundo eco.

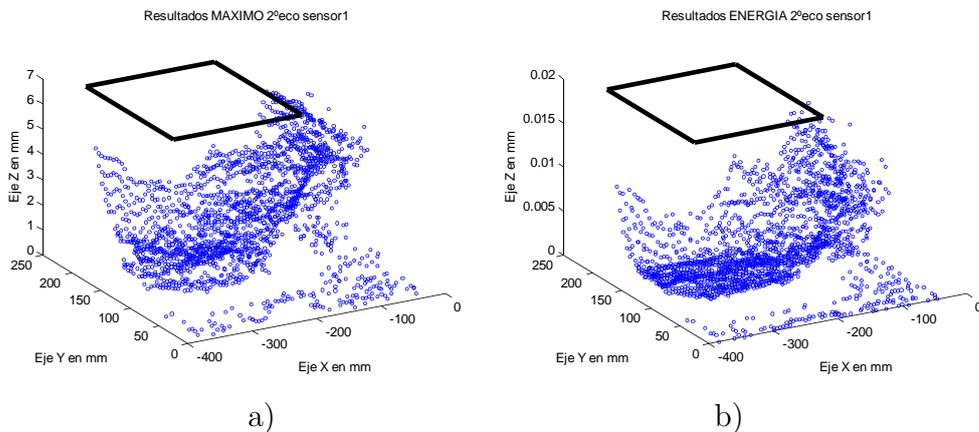


Figura 7.12: Valor de a) amplitudes máximas y b) energía del segundo eco

Otras combinación de parámetros que también aporta mejoras en la reconstrucción se muestra en la figura 7.13b) donde se ha empleado el producto del tiempo de vuelo del primer eco por la potencia del primer eco. En caso de existir la combinación de varias alturas en la pieza la solución sería una combinación lineal de cada tiempo de comienzo, o tiempo de máximo corregido, por su potencia.

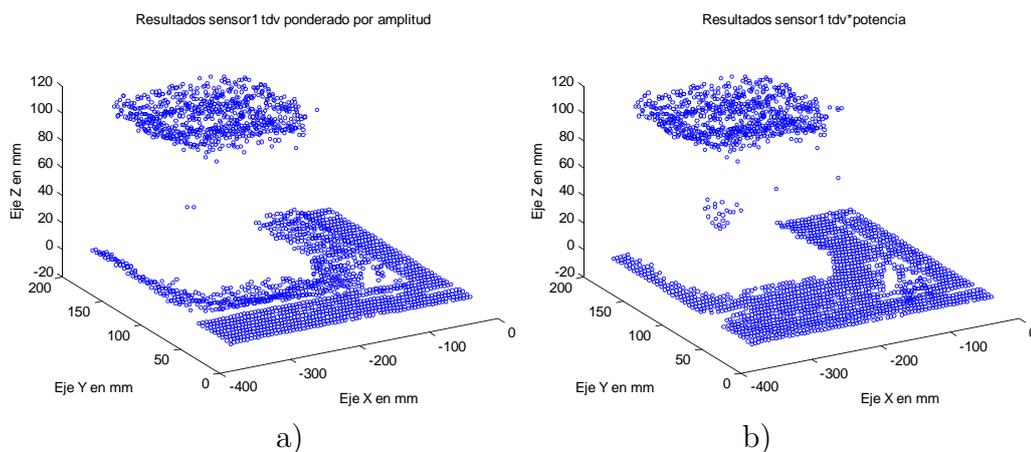


Figura 7.13: Reconstrucción basada en a) TDV ponderado por amplitud, b) TDV por potencia

El ejemplo anterior muestra las ventajas de emplear la información de los dos primeros subecos para escenas que presentan dos niveles a distancias claramente diferenciables. Se pretende ampliar ahora este estudio al caso de escenas que presenten más niveles de alturas diferenciadas. Para ello se va a tomar como objeto referencia para el análisis la composición mostrada en la figura 7.14 y se va a hacer un barrido a altura constante sobre la escena con un recorrido de 400 mm en el eje  $x$  y de 250 mm en el eje  $y$ , tomando datos cada 5 mm de desplazamiento tanto en la dirección del eje  $x$ , como del eje  $y$ . De esta forma una vez terminado el barrido se obtiene una matriz de 80 x 50 ecos.

En este caso la escena presenta cuatro niveles de distancias claramente diferenciables. Se va a comprobar si aportar la información de un tercer subeco es relevante para su reconstrucción. De esta forma va a realizarse una comparación entre la reconstrucción basada en un único eco, en los dos primeros ecos y en los tres primeros ecos.

Para el tratamiento de la imagen, para cada eco se ha localizado los tres primeros subecos y se ha calculado el tiempo de vuelo, tiempo de máximo y máxima amplitud de cada uno de ellos individualmente.

Se parte, como en el ejemplo anterior, de la reconstrucción 3D más simple, basada únicamente en el tiempo de vuelo del eco completo. Esta reconstrucción se muestra en la figura 7.15a) y presenta los mismos problemas que se indicaban en el ejemplo anterior, es decir, debido al ancho lóbulo de radiación de los sensores, el sensor receptor no deja, en ningún momento del barrido, de ver las superficies más próximas a él, aunque su visión sea ya muy lateral. De esta forma el objeto se empieza a detectar mucho antes de que el sensor se encuentra situado sobre él.

En el caso del tiempo de vuelo este cálculo también está afectado por el ruido que pueda tener la señal, por lo que hay que fijar un umbral mínimo para considerar que existe eco. Este umbral mínimo hace que ese tiempo difiera ante pequeñas variaciones de la señal o la aparición de ecos secundarios próximo de baja amplitud debido a los lóbulos secundarios del patrón de radiación.

Otra reconstrucción simple inicial sería la basada en el tiempo de máximo del eco completo que se muestra en la figura 7.15b) y. En este caso puede observarse alguna mejoría respecto al tiempo de vuelo pero presenta también grandes errores. La mejoría proviene de un calculo más exacto que facilita el tiempo transcurrido desde el envío de la señal de excitación al máximo de la señal en la recepción y el empleo siempre del eco de mayor potencia de la señal. La figura muestra la reconstrucción basada en el tiempo del máximo de la señal y corregido con la información del transitorio del sensor empleado.

Otra posible información a utilizar de la señal recibida es la amplitud del eco. Esta información es útil cuando la señal está formada por varios subecos, ya que esto indica que el sensor está visualizando simultáneamente varias superficies a diferentes distancias. En este caso sería útil poder identificar cuál de ellos contiene la información del rebote sobre el objeto que se encuentra más en la vertical del sensor. Se muestran a continuación en las figuras 7.16, 7.17 y 7.18 la vista en planta de los mapas de amplitud de los tres primeros ecos para la escena analizada en el ejemplo. Se muestra sólo su valor cuando existe el eco en cuestión.

Como en el ejemplo del espejo, se reconstruye en primer lugar la escena utilizando la información de los tiempos de comienzo de los dos primeros subecos seleccionados por la amplitud. Su resultado puede verse en la figura 7.19a). Puede observarse que dicha reconstrucción mejora mucho de la obtenida a partir exclusivamente del tiempo de vuelo, pero aún aparecen bastantes puntos con distancia errónea.

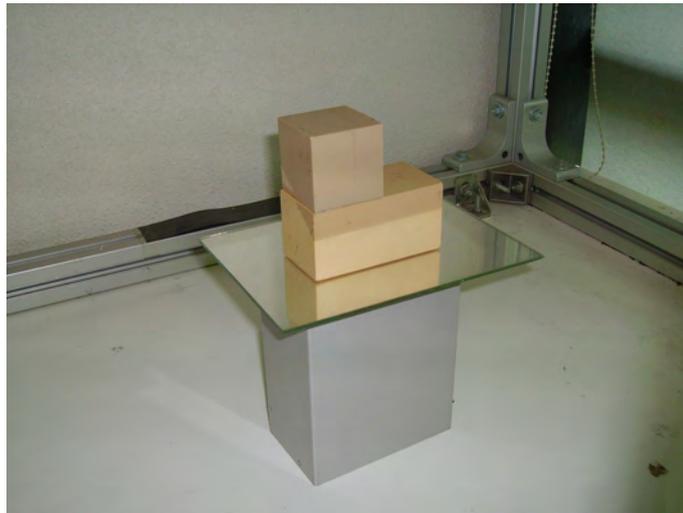


Figura 7.14: Escena utilizada para la reconstrucción

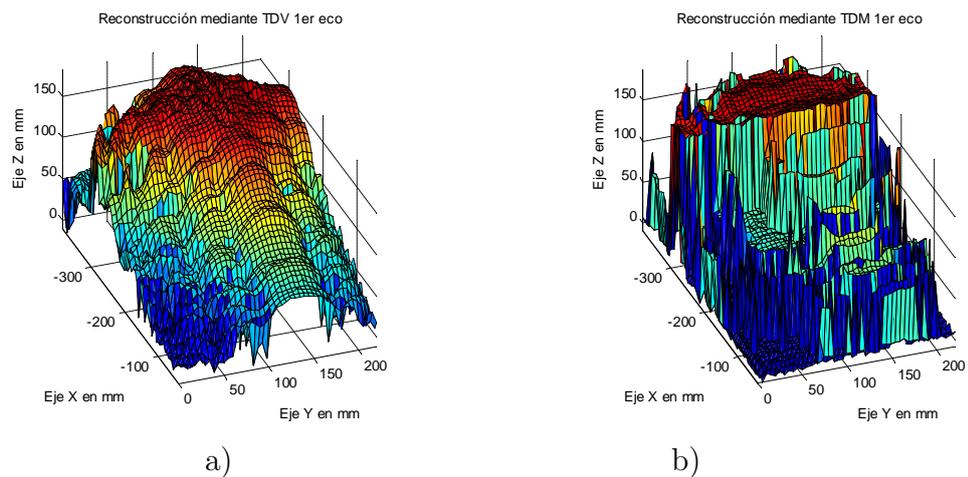


Figura 7.15: Reconstrucción 3D basada en la información de a) tiempo de vuelo b) tiempo de maximo corregido.

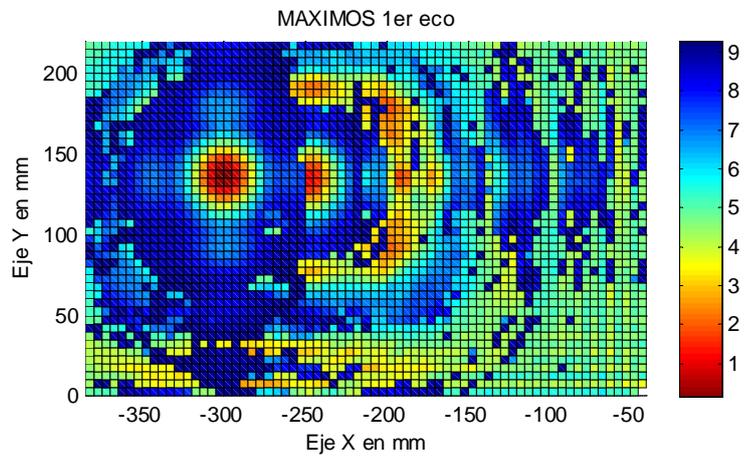


Figura 7.16: Valor máximo del primer eco

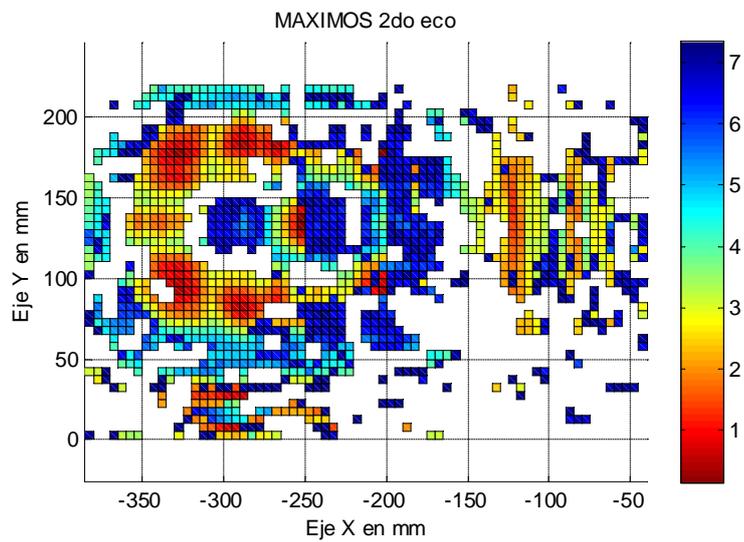


Figura 7.17: Valor máximo del segundo eco

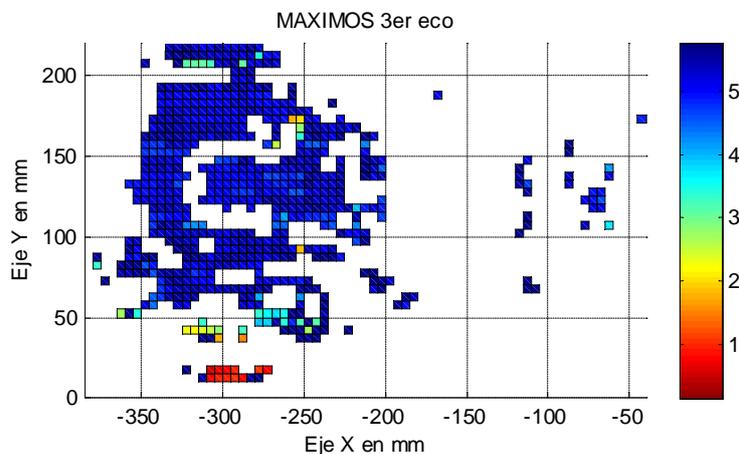


Figura 7.18: Valor máximo del tercer eco

Finalmente se plantea mejorar la reconstrucción empleando los tres primeros subecos con lo que se obtienen tres posibles distancias del sensor al objeto para cada posición. En cada punto se tomará la distancia del eco que presenta mayor señal, lo que corresponde con seleccionar el eco que ha sido recibido con el ángulo de incidencia más próximo a la normal a la superficie insonificada. A continuación en la figura 7.19b) se representa esta reconstrucción 3D basada en la información de los tres primeros ecos de la señal de recepción. En este caso también se obtuvo el tiempo de inicio de cada eco a partir del tiempo de máximo corregido mediante el transitorio del sensor utilizado. Al combinar la información del tiempo de inicio de cada uno de los ecos con la amplitud máxima que presentan da lugar a una reconstrucción mucho más real del objeto.

En este caso ampliar más el número de subecos a tener en cuenta en la reconstrucción parece no ser necesario, ya que en esta última reconstrucción obtenida no aparecen, para ningún punto, distancias falsas. Esto puede ser debido a que en ninguna de las posiciones de captura el sensor ve más de tres superficies simultáneamente. Si se incrementa la complejidad de la escena,

entonces sí que con el mismo criterio se podrían ir ampliando el número de ecos considerados.

Conclusiones:

En este apartado se ha planteado una nueva línea de trabajo basada en un método de mejora de la reconstrucción 3D para escenas simples formadas por superficies paralelas y con formas básicas. La reconstrucción directa basada en el tiempo de vuelo del eco produce reconstrucciones muy pobres en resolución cuando se emplean sensores de baja frecuencia debido a su ancho lóbulo de radiación.

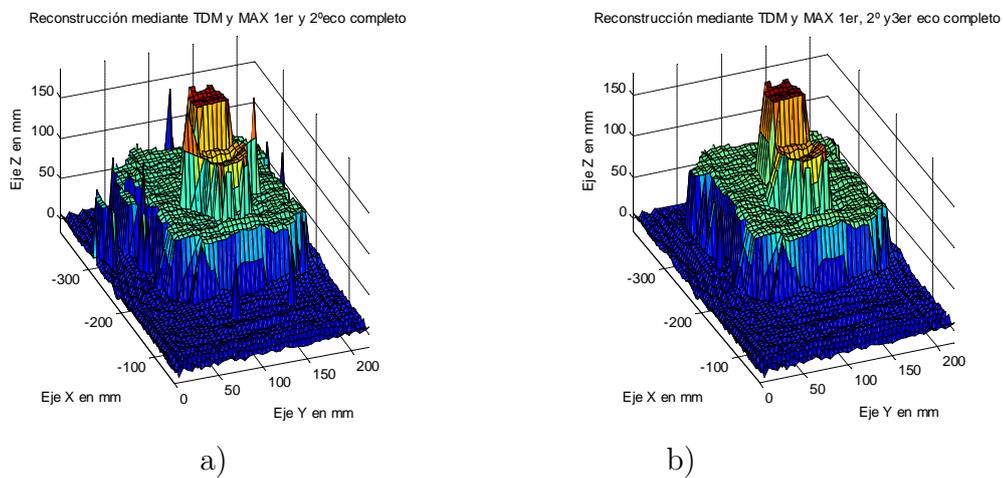


Figura 7.19: Reconstrucción 3D basada en la información de a) los dos primeros ecos, b) los tres primeros ecos

Con la idea de poder trabajar en reconstrucción tridimensional con sensores de baja frecuencia se plantea en este apartado un análisis de varios parámetros del eco que permitan mejorar la calidad de dichas reconstrucciones. Se ha comprobado cómo el análisis de los distintos subecos de que está formada la señal que recibe un sensor, permite mejorar en gran medida la calidad de la reconstrucción. El número de características a tener en cuenta dependerá de la complejidad de la escena a reconstruir, habiéndose comprobado su validez con escenas simples.

# Bibliografía

- [1] Acoustics- attenuation of sound during propagation outdoors-part 1: Calculation of the absorption of sound by the atmosphere, iso 9613-1, 1993.
- [2] Method for calculation of the absorption of sound by the atmosphere, ansi s1.26-1995, September 1995.
- [3] J. A. Anderson. A simple neural network generating an interactive memory. *Mathematical Biosciences*, 14:197–220, 1972.
- [4] W. W. Au. Comparison of sonar discrimination: dolphin and an artificial neural network. *J Acoust Soc Am.*, 95:2728–2735, 1994.
- [5] Birsel Ayruolu and Billur. Reliability measure assignment to sonar for robust target differentiation. *Pattern Recognition*, 35:1403–1419, 2002.
- [6] B. Barshan and B. Ayruolu. Performance comparison of four time-of-flight estimation methods for sonar signals. *Electronics Letters*, 34(16):1616 – 1617, aug 1998.
- [7] B. Barshan, B. Ayruolu, and S.W. Utete. Neural network-based target differentiation using sonar for robotics applications. *Robotics and Automation, IEEE Transactions on*, 16(4):435 –442, aug 2000.
- [8] B. Barshan and R. Kuc. Differentiating sonar reflections from corners and planes by employing an intelligent sensor. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(6):560 –569, June 1990.

- [9] Billur Barshan and Birsel Ayruolu. Fuzzy clustering and enumeration of targets type based on sonar returns. *Pattern Recognition*, 37:189–199, 2004.
- [10] Billur Barshan and Bir. Comparative analysis of different approaches to target differentiation and localization with sonar. *Pattern Recognition*, 36:1213–1231, 2003.
- [11] Deniz Baskent and Billur Barshan. Surface profile determination from multiple sonar data using morphological processing. *The International Journal of Robotics Research*, 18(8):788–808, 1999.
- [12] Gines Benet, Milagros Martinez, Francisco Blanes, Pascual Perez, and Jose E. Simo. Differentiating walls from corners using the amplitude of ultrasonic echoes. *Robotics and Autonomous Systems*, 50(1):13–25, 2005.
- [13] N. Betrouni, R. Lopes, N. Makni, A. S. Dewalle, M. Vermandel, and J. Rousseau. Volume quantification by fuzzy logic modelling in freehand ultrasound imaging. *ULTRASONICS*, 49 (8):646–652, 2009.
- [14] J.C. Bezdek. *Fuzzy Mathematics in Pattern Classification*. Applied Math. Center, Cornell University. PhD thesis, Applied Math. Center, Cornell University, Ithaca, 1973.
- [15] H. D. Block. The perceptron: A model for brain functioning. i. *Reviews of Modern Physics*, 34:123–135, 1962.
- [16] J. Borenstein and Y. Koren. Error eliminating rapid ultrasonic firing for mobile robot obstacle avoidance. *Robotics and Automation, IEEE Transactions on*, 11(1):132–138, February 1995.
- [17] O. Bozma and R. Kuc. Building a sonar map in a specular environment using a single mobile sensor. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 13(12):1260–1269, dec 1991.
- [18] M. Brudka and A. Pacut. Intelligent robot control using ultrasonic measurements. *Instrumentation and Measurement, IEEE Transactions on*, 51(3):454–459, jun 2002.

- [19] E. Caicedo. Sistema de identificación de objetos mediante sensores de ultrasonidos basado en un modelo paramétrico. Master's thesis, Tesis doctoral. Escuela Superior de Ingenieros Industriales. Universidad Politécnica de Madrid., 1995.
- [20] Benoit Caldairou, Nicolas Passat, Piotr A. Habas, Colin Studholme, and Francois Rousseau. A non-local fuzzy segmentation method: Application to brain mri. *PATTERN RECOGNITION*, 44 (9):1916–1927, 2011.
- [21] A. Carullo, F. Ferraris, S. Graziani, U. Grimaldi, and M. Parvis. Ultrasonic distance sensor improvement using a two-level neural-network. *Instrumentation and Measurement, IEEE Transactions on*, 45(2):677–682, apr 1996.
- [22] Sourabh Dash, Raghunathan Rengaswamy, and Venkat Venkatasubramanian. Fuzzy-logic based trend classification for fault diagnosis of chemical processes. *Computers and Chemical Engineering*, 27:347–362, 2003.
- [23] L. Davis. *Handbook of Genetic Algorithms*. 1991.
- [24] Dimiter Driankov, Hans Hellendoorn, and Michael Reinfrank. *An Introduction to Fuzzy Control*. Springer-Verlag, 1996.
- [25] Nicola Ivan Giannoccaro, Luigi Spedicato, and Carmelo di Castri. A new strategy for spatial reconstruction of orthogonal planes using a rotating array of ultrasonic sensors. *IEEE SENSORS JOURNAL*, 15 (5):1307–1316, 2012.
- [26] M. Gil, E.G. Sarabia, J.R. Llata, and J.P. Oria. Fuzzy c-means clustering for noise reduction, enhancement and reconstruction of 3-d ultrasonic images. In *7th International Conference on Emergin Technologies and Factory Automation*, 1997.
- [27] D. E. Goldberg. *Genetic Algorithms in Search, Optimizacion and Machine Learning*. Addison-Wesley Longman, 1989.

- [28] R. Gutierrez-Osuna, J.A. Janet, and R.C. Luo. Modeling of ultrasonic range sensors for localization of autonomous mobile robots. *Industrial Electronics, IEEE Transactions on*, 45(4):654 –662, aug 1998.
- [29] D. O. Hebb. *The Organization of the Behaviour*. JohnWiley & Sons, 1949.
- [30] Kaoru Hirota. *Industrial Applications of Fuzzy Technology*. Springer-Verlag, 1993.
- [31] J. H. Holland. *Adaptation in natural and artificial systems*. University of Michigan Press, 1975.
- [32] J.S.R. Jang, C.T. Sun, and E. Mizutani. *Neuro-Fuzzy and Soft Computing*. Prentice Hall, 1997.
- [33] Lawrence E. Kinsler, Austin R. Frey, Alan B. Coppens, and James V. Sanders. *Fundamentals of Acoustics*. Wiley, 4 edition, December 2000.
- [34] L. Kleeman. Fast and accurate sonar trackers using double pulse coding. In *Intelligent Robots and Systems, 1999. IROS '99. Proceedings. 1999 IEEE/RSJ International Conference on*, volume 2, pages 1185 –1190 vol.2, 1999.
- [35] T. Kohonen. Correlation matrix memories. *IEEE Transactions on Computers*, C-21:353–359, 1972.
- [36] R. Kuc. Pseudo-amplitude scan sonar maps. *Robotics and Automation, IEEE Transactions on*, 17(5):767 –770, October 2001.
- [37] R. Kuc. Forward model for sonar maps produced with the polaroid ranging module. *Robotics and Automation, IEEE Transactions on*, 19(2):358 –362, apr 2003.
- [38] Roman Kuc and M. W. Siegel. Physically based simulation model for acoustic sensor robot navigation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-9(6):766 –778, 1987.

- [39] K. Levenberg. A method for the solution of certain non-linear problems in least squares. *The quarterly of applied mathematics*, 2:164–168, 1944.
- [40] R. Lippmann. An introduction to computing with neural nets. *ASSP Magazine, IEEE*, 4(2):4–22, apr 1987.
- [41] J. R. Llata, E. G. Sarabia, and J. P. Oria. Fuzzy expert system with double knowledge base for ultrasonic classification. *Expert Systems with Applications*, 20(4):347–355, 2001.
- [42] J. R. Llata, E. G. Sarabia, and J. P. Oria. Three-dimensional robotic vision using ultrasonic sensors. *Journal of Intelligent and Robotic Systems*, 33:267–284, 2002. 10.1023/A:1015084304191.
- [43] J.R. Llata, E.G. Sarabia, J. Arce, and J.P. Oria. Probabilistic expert systems for shape recognition applied to ultrasonics techniques. In *Computational Intelligence in Robotics and Automation, 1997. CIRA '97., Proceedings., 1997 IEEE International Symposium on*, pages 158–163, July 1997.
- [44] J.R. Llata, E.G. Sarabia, J. Arce, and J.P. Oria. Aplicación de inteligencia artificial en sistemas automatizados de producción. *Revista Iberoamericana de Inteligencia Artificial*, 10:100–110, 2000.
- [45] J.R. Llata, E.G. Sarabia, M. Gil, and J.P. Oria. Fuzzy enhancement of three-dimensional ultrasonic images. In *3rd International Conference of Industrial Automation*, 1999.
- [46] J.R. Llata, E.G. Sarabia, and J.P. Oria. Shape recognition by ultrasonic sensor arrays in robotic applications. In *Proceedings of the 3rd Asian Conference on Robotics and Its Applications*, 1997.
- [47] J.R. Llata, E.G. Sarabia, and J.P. Oria. Short distance ultrasonic vision for mobile robots. In *IFAC Workshop on Intelligent Components for Vehicles ICV98*, 1998.

- [48] J.R. Llata, E.G. Sarabia, and J.P. Oria. Three dimensional ultrasonic vision of surfaces for robotics applications. In *3rd IFAC Symposium on Intelligent Autonomous Vehicles IAV98*, 1998.
- [49] J.R. Llata, E.G. Sarabia, and J.P. Oria. Pattern recognition with ultrasonic sensors: a neural networks evaluation. *Sensor Review*, Vol. 21 Iss: 1:45 – 51, 2001.
- [50] J.R. Llata, E.G. Sarabia, and J.P. Oria. Evaluation of expert systems for automatic shape recognition by ultrasound. *Journal of Intelligent Manufacturing*, 13:177–188, 2002.
- [51] Xiaowei Ma, Xiaoli Li, and Hong Qiao. Fuzzy neural network-based real-time self-reaction of mobile robot in unknown environments. *Mechatronics*, 11(8):1039 – 1052, 2001.
- [52] D. Marioli, C. Narduzzi, C. Offelli, D. Petri, E. Sardini, and A. Taroni. Digital time-of-flight measurement for ultrasonic sensors. *Instrumentation and Measurement, IEEE Transactions on*, 41(1):93 –97, feb 1992.
- [53] D. Marquardt. An algorithm for least-squares estimation of nonlinear parameters. *Journal of applied mathematics*, 11:431–441, 1963.
- [54] Milagros Martinez and Gines Benet. Wall-corner classification using sonar: A new approach based on geometric features. *Sensors*, 10(12):10683–10700, 2010.
- [55] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115–133, 1943.
- [56] C. K. Mechefske. Objective machinery fault diagnosis using fuzzy logic. *Mechanical Systems and Signal Processing*, 12:855–862, 1998.
- [57] Jerry M. Mendel. Uncertainty, fuzzy logic, and signal processing. *Signal Processing*, 80:913–933, 2000.
- [58] Z. Michalewicz. *Genetic Algorithms + Data Structures = Evolution Programs*. Springer-Verlag, 1996.

- [59] M. L. Minsky and S. A. Papert. *Perceptrons, Expanded Edition*. MIT Press, 1969.
- [60] Fernando Moita, Ana C. Lopes, and Urbano Nunes. A fast firing binaural system for ultrasonic pattern recognition. *J. Intell. Robotics Syst.*, 50(2):141–162, October 2007.
- [61] Achour N., Toumi R., and M’sirdi N.K. Building environment maps using neural networks. *International Journal of Robotics and Automation*, 19(2):275–289, 2004.
- [62] Jong-Hyun Park, Gerard G. Medioni, and Guee-Sang Lee. Text image restoration using adaptive fuzzy median based on 3d tensors and iterative voting. *JOURNAL OF INFORMATION SCIENCE AND ENGINEERING*, 26 (3):1029–1048, 2010.
- [63] Kevin M. Passino and Stephen Yurkovich. *Fuzzy Control*. Addison Wesley Longman,, 1998.
- [64] H. Peremans, K. Audenaert, and J.M. Van Campenhout. A high-resolution sensor based on tri-aural perception. *Robotics and Automation, IEEE Transactions on*, 9(1):36 –48, feb 1993.
- [65] H. Peremans, K. Audenaert, and J.M. Van Campenhout. A high-resolution sensor based on tri-aural perception. *Robotics and Automation, IEEE Transactions on*, 9(1):36 –48, February 1993.
- [66] H. L. Roitblat, W. W. L. Au, P. E. Nachtigall, R. Shizumura, and G. Moons. Sonar recognition of targets embedded in sediment. *Neural Networks*, 8:1263–1273, 1995.
- [67] F. Rosenblatt. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65:386–408, 1958.
- [68] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. *Parallel Distributed Processing*, volume 1, chapter Learning Internal Representations by Errors Propagation. 1988.

- [69] A.M. Sabatini and A. Rocchi. Sampled baseband correlators for in-air ultrasonic rangefinders. *Industrial Electronics, IEEE Transactions on*, 45(2):341–350, apr 1998.
- [70] F Samadzadegan, A Azizi, M Hahn, and C Lucas. Automatic 3d object recognition and reconstruction based on neuro-fuzzy modelling. *JOURNAL OF PHOTOGRAMMETRY AND REMOTE SENSING*, 59 (5):255–277, 2005.
- [71] E.G. Sarabia, J.R. Llata, J. Arce, and J.P. Oria. Neural networks applied to classification and fault detection using ultrasonics. In *Proceedings of the fourth International Conference on Engineering Applications of Neural Networks*, 1998.
- [72] E.G. Sarabia, J.R. Llata, J. Arce, and J.P. Oria. Reconocimiento ultrasónico de piezas mediante redes neuronales asociativas. In *XIX Jornadas de Automática*, 1998.
- [73] E.G. Sarabia, J.R. Llata, J. Arce, and J.P. Oria. Shape recognition and orientation detection for industrial applications using ultrasonic sensors. In *IEEE International Joint Symposia on Intelligence and Systems*, 1998.
- [74] E.G. Sarabia, J.R. Llata, M. Gil, and J.P. Oria. Realce mediante técnicas fuzzy de imágenes tridimensionales ultrasónicas. In *XIX Jornadas de Automática*, 1998.
- [75] E.G. Sarabia, J.R. Llata, C. Torre, S. Robla, and J.P. Oria. Application of neural nets in a robotic recognition process with data uncertainty. In *Ninth International Conference on Engineering Applications of Neural Networks, EANN05*, 2005.
- [76] E.G. Sarabia, J.R. Llata, C. Torre, S. Robla, and J.P. Oria. Pose recognition by using neural networks and ultrasounds for a robotic picking up application. In *Computational Intelligence for Measurement Systems and Applications, 2005. CIMSAA. 2005 IEEE International Conference on*, pages 128 – 133, july 2005.

- [77] Yen-Hao Tseng, Jenq-Neng Hwang, and F.H. Sheehan. Three-dimensional object representation and invariant recognition using continuous distance transform neural networks. *Neural Networks, IEEE Transactions on*, 8(1):141–147, jan 1997.
- [78] Annamaria R. Varkonyi-Koczy. Fuzzy logic supported corner detection. *JOURNAL OF INTELLIGENT & FUZZY SYSTEMS*, 19 (1):41–50, 2008.
- [79] Giuseppe Vicidomini, Partha Pratim Mondal, and Alberto Diaspro. Fuzzy logic and maximum a posteriori-based image restoration for confocal microscopy. *OPTICS LETTERS*, 31 (24):3582–3584, 2006.
- [80] L.X. Wang. *A Course in fuzzy Control Systems and Control*. Prentice Hall, 1997.
- [81] S. Watanabe and M. Yoneyama. An ultrasonic visual sensor for three-dimensional object recognition using neural networks. *Robotics and Automation, IEEE Transactions on*, 8(2):240–249, apr 1992.
- [82] B. Widrow and M. E. Hoff. Adaptive switching circuits. *IRE ESCON Convnetion Record*, 4:96–104, 1960.
- [83] H. C. Zhang and S. H. Huang. A fuzzy approach to process plan selection. *International Journal of Production Research*, 6:1265–1279, 1994.