



UNIVERSIDAD NACIONAL
AUTÓNOMA DE
MÉXICO

UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

**PROGRAMA DE MAESTRÍA Y DOCTORADO EN
INGENIERÍA**

**DETECCIÓN Y FILTRADO DE ESTRUCTURAS DE BAJO
CONTRASTE EN IMÁGENES DE ULTRASONIDO**

T E S I S

QUE PARA OBTENER EL GRADO DE:

MAESTRO EN INGENIERÍA

ELÉCTRICA – PROCESAMIENTO DIGITAL DE SEÑALES

P R E S E N T A :

LORENA PAOLA VARGAS QUINTERO

TUTOR:

DR. BORIS ESCALANTE RAMÍREZ

2012

JURADO ASIGNADO:

Presidente: DR. FERNANDO ARÁMBULA COSÍO

Secretario: DRA. LUCIA MEDINA GÓMEZ

Vocal: DR. BORIS ESCALANTE RAMÍREZ

1^{er}. Suplente: DR. PABLO ROBERTO PEREZ ALCÁZAR

2^{do}. Suplente: DRA. MARÍA ELENA MARTÍNEZ PÉREZ

Lugar o lugares donde se realizó la tesis:

Laboratorio Avanzado de Procesamiento de Imágenes, Edificio de Posgrado en Ingeniería, 2^{do} Piso, Departamento de Procesamiento de Señales.

TUTOR DE TESIS:

Dr. BORIS ESCALANTE RAMÍREZ

FIRMA

AGRADECIMIENTOS

A **DIOS** por darme entendimiento y sabiduría permitiéndonos superar cada uno de los obstáculos presentados en la ejecución del proyecto y de la vida.

Al Dr. Boris Escalante Ramírez, quien tuvo la amabilidad de guiarme y marcarme las pautas cuando fue necesario para llevar a cabo este proyecto. Además de recibirme en su laboratorio sin dudar, ayudándome y apoyándome cada vez que lo necesite.

Al Dr. Fernando Arámbula, a la Dra. Lucia Medina, a la Dr. María Elena Martínez y al Dr. Pablo Pérez por sus comentarios y sugerencias en el trabajo, y quienes siempre estuvieron dispuestos a brindarme su colaboración.

A la Universidad Nacional Autónoma de México y al Posgrado de Ingeniería por haber contribuido en mi formación académica a través de la excelente planta docente.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por el apoyo económico durante mis estudios de maestría.

A mis compañeros de laboratorio con los que comparto mi actividad académica, y quienes me hacen más agradables la labor cotidiana.

A mis familiares en especial a mi mamá, mi papá y mi hermana por su respaldo permanente y por enseñarme en cada momento de la vida a ser una mejor persona.

A Leiner, Juan Martín, Carol, Madeleine, Erik, quienes siempre me han brindado su amistad incondicional.

A todas aquellas personas que de una u otra forma contribuyeron en el proceso para la elaboración de esta investigación y que haya olvidado mencionar.

Gracias a todos,

INDICE GENERAL

	pág.
RESUMEN	1
1 INTRODUCCIÓN	3
1.1 Antecedentes	3
1.2 Objetivos	8
1.3 Información General de la Tesis	8
2 IMÁGENES DE ULTRASONIDO	10
2.1 Fundamentos generales del ultrasonido	11
2.2 Sistemas de imagenología ultrasónica	15
2.2.1 Modo A	16
2.2.2 Modo M	16
2.2.3 Modo B	17
2.2.4 Ultrasonido Compuesto	19
2.3 Aplicaciones Clínicas de Ultrasonido	20
2.3.1 Ginecología y Obstetricia	21
2.3.2 Imagen de la Mama	21
2.3.3 Estructura del Musculo Esquelético	23
2.3.4 Ecocardiografía	23

3 DETECCIÓN Y FILTRADO	25
3.1 Detección	25
3.1.1 El Modelo para el Criterio de Decisión	26
3.1.2 Teoría de detección de señales y Prueba de Hipótesis	27
3.1.3 Modelos de observadores para la detección en imágenes de ultrasonido	28
3.1.3.1 <i>Observador ideal Bayesiano</i>	28
3.1.3.2 <i>Señales Estadísticamente Conocidas</i>	29
3.1.3.3 <i>Observador Hotelling</i>	30
3.1.3.4 <i>Modelos Non prewhitening (NPWMF)</i>	31
3.1.3.5 <i>El observador Humano</i>	31
3.2 Filtrado	32
3.2.1 Filtro de Mediana	32
3.2.2 El filtro SRAD	33
3.2.3 El filtro de Frost	34
3.2.4 Filtro de Lee	35
3.2.5 Filtro de Kuan	35
3.2.6 Filtrado usando Transformada Wavelet	35
3.2.6.1 <i>Técnicas shrinkage</i>	36
3.2.6.1.1 <i>Umbral Duro</i>	36
3.2.6.1.2 <i>Umbral Suave</i>	37
3.2.6.2 <i>Estimación de parámetros para la Umbralización</i>	38

4 ALGORITMOS DE DETECCIÓN Y FILTRADO PROPUESTOS PARA ESTRUCTURAS DE BAJO CONTRASTE EN IMÁGENES DE ULTRASONIDO	40
4.1 Creación de un Banco de Datos de Imágenes de Ultrasonido de Estructuras de Bajo Contraste	40
4.1.1 Generación de imágenes utilizando el programa FIELD II	40
4.1.2 Generación de imágenes usando el algoritmo propuesto por Pizurica	41
4.1.3 Imágenes de fantasmas (<i>Phantom</i>) reales	42
4.2 Algoritmos de detección	44
4.2.1 Análisis estadístico con distribución de Rayleigh	44
4.2.2 Análisis estadístico con distribución Gaussiana	49
4.2.3 Análisis estadístico correlacionado	50
4.2.3.1 <i>Distribución Gaussiana Correlacionada</i>	50
4.3 Algoritmos de Filtrado	51
4.3.1 Método Bayesiano usando la Transformada Wavelet	53
4.3.1.1 <i>Parámetros del Speckle en la Imagen de Ultrasonido</i>	53
4.3.1.2 <i>Descripción de la Transformada Wavelet Discreta para Representación Multiresolución</i>	54
4.3.1.3 <i>Desarrollo del Algoritmo Bayesiano</i>	58
4.3.1.4 <i>Cálculo para estimar $\hat{f}(y_t)$</i>	61
4.3.1.5 <i>Técnica de Mejoramiento Propuesta - Ganancia Adaptiva Local Exponencial GALE</i>	62
4.3.2 Transformada Hermite para Filtrado en imágenes de Ultrasonido	63
4.3.2.1 <i>Definición de la Transformada de Hermite</i>	63

4.3.2.2 <i>Umbral de clasificación para cada pixel usando la Transformada de Hermite</i>	64
5 RESULTADOS	66
5.1 Filtrado	68
5.1.1 Resultados del algoritmo de filtrado Bayesiano basado en wavelet	68
5.1.2 Resultados usando el algoritmo de filtrado basado en Hermite	72
5.1.3 Evaluación cuantitativa de los filtros implementados.	75
5.2 Resultados de los algoritmos de detección	80
6. CONCLUSIONES	91
A. Método Bayesiano con Ganancia Adaptiva Local Exponencial GALE usando diferentes Familias Wavelet	94
REFERENCIAS	97

INDICE DE FIGURAS

Figura 1. El principio de las imágenes de ultrasonido.....	11
Figura 2. Ondas longitudinales.....	12
Figura 3. a. Fenómeno de Dispersión, b. Dispersión con estructuras muy cercanas, c. Fenómeno de dispersión cuando las estructuras están muy separadas, d. Imagen de ultrasonido con áreas de alta y baja intensidad debido al fenómeno de dispersión.	13
Figura 4. Diagrama de un haz de ultrasonido clínico.	15
Figura 5. Escáner modo A para medir el espesor de la cornea. Un haz de ultrasonido de alta frecuencia es utilizado.....	16
Figura 6. Adquisición en modo M, a. El transductor es localizado para escanear el corazón, b. Imagen de ultrasonido modo M.....	17
Figura 7. Esquema del arreglo de elementos piezoeléctricos en un ultrasonido modo B	18
Figura 8. Imagen modo B de la vesícula biliar que muestra la presencia de pólipos	18
Figura 9. Imagen tridimensional de un feto de 12 semanas.....	19
Figura 10. Bifurcación, a. adquirida usando ultrasonido convencional, modo B, b. adquirida usando ultrasonido modo compuesto con nueve orientaciones diferentes.	20

Figura 11. Imágenes de ultrasonido modo B, a. en dos dimensiones de un feto de 19 semanas, b. cerebro fetal y c. imagen fetal en tres dimensiones usando arreglos en dos dimensiones.	21
Figura 12. Imágenes de ultrasonido de la Mama, a. Fibroadenoma, b. Masa en la mama.....	22
Figura 13. Escáner compuesto, a. un tendón de la mano. b. Lesión en el hombro.....	23
Figura 14. Ecocardiografía, a. Regurgitación mitral causada por lesión a la válvula después de un ataque cardiaco. b. Se puede apreciar la orejuela de la aurícula izquierda (LAA), la aurícula izquierda (LA) y el ventrículo izquierdo (LV).....	24
Figura 15. Función de umbral duro aplicada a las sub-bandas de detalles en cada nivel de descomposición	37
Figura 16. Función de umbralización suave aplicada a las sub-bandas de detalles en cada nivel de descomposición	38
Figura 17. Fantasma (<i>Phantom</i>) usado para simulación	41
Figura 18. Imágenes reales con frecuencia de transmisión a. 15 MHz, b. 21 MHz, c. 30 MHz y d. 40 MHz.....	43
Figura 19. Estructuras con diferentes contrastes, a. 0.2652, b. 0.2457, c. 0.1796.....	45
Figura 20. Diagrama de bloques del filtrado de imágenes de ultrasonido usando técnicas multiresolución.....	52
Figura 21. Implementación de la Transformada wavelet Discreta en 2-D.	56

Figura 22. Secuencia para el análisis de resultados.66

Figura 23. Imagen de ultrasonido con estructura a) Simulada [83] b) Real67

Figura 24. Imagen a. de Ultrasonido real inicial. La región encerrada por la circunferencia amarilla corresponde a la estructura, b. filtrada usando Umbralización suave, c. filtrada usando Bayesiano Multiresolución con $L = 4$ y coiflet1, d. filtrada utilizando bayesiano con Ganancia Adaptiva Local Exponencial GALE con $L = 4$ y coiflet1, e. filtrada con el algoritmo propuesto por Pizurica et al. [33], f. filtrada con Wiener y g. filtrada con Lee [80].70

Figura 25. Imagen a. de Ultrasonido simulada con estructura sin procesar donde la región encerrada por la circunferencia amarilla corresponde a la estructura, b. Filtrada usando Umbralización suave, c. Filtrada usando Bayesiano Multiresolución con $L = 4$ y coiflet1, d. Bayesiano con Ganancia Adaptiva Local Exponencial GALE con $L = 4$ y coiflet1, e. Algoritmo propuesto por Pizurica et al., f. Filtrada con Wiener y g. Filtrada con Lee [80].71

Figura 26. Imagen a. de ultrasonido real inicial con estructura. La estructura se encuentra ubicada en la circunferencia amarilla, b. Filtrada usando Umbralización suave, c. Filtrada usando Hermite, d. Algoritmo propuesto por Pizurica et al. [33], e. Filtrada con Wiener y f. Filtrada con Lee [80].73

Figura 27. Imagen a. de ultrasonido simulada inicial con estructura. La circunferencia marca la ubicación de la estructura, b. Filtrada usando Umbralización suave, c. Filtrada usando Hermite, d. Algoritmo propuesto por Pizurica et al. [33], e. Filtrada con Wiener y f. Filtrada con Lee [80].74

Figura 28. Comparación cualitativa y cuantitativa con la imagen con speckle simulado usada en la literatura para validar algoritmos de filtrado para imágenes de ultrasonido ($\sigma = 0.4$ y

SNR = 7.8231dB). a. Imagen Original (Imagen tomada del trabajo de Pizurica[33]), b. Imagen con Speckle Simulado (Imagen tomada de [33]), c. Filtro de Lee [80], d. Wiener, e. Umbralización Suave, f. Algoritmo propuesto por Pizurica [33], g. Bayesiano, h. Hermite y i. Bayesiano con Ganancia Adaptiva Local Exponencial GALE.77

Figura 29. Comparación cualitativa y cuantitativa con la imagen con speckle simulado usada en la literatura para validar algoritmos de filtrado para imágenes de ultrasonido ($\sigma = 0.9$ y SNR = 4.28 dB). a. Imagen Original [33], b. Speckle Simulado [33], c. Filtro de Lee [80], d. Wiener, e. Umbralización Suave, f. Algoritmo propuesto por Pizurica [33], g. Bayesiano, h. Hermite y i. Bayesiano con Ganancia Adaptiva Local Exponencial GALE.78

Figura 30. a. Imagen original con estructura y el histograma en azul, b. Imagen filtrada usando el método Bayesiano y el histograma en azul, c. Imagen filtrada usando el método Bayesiano con Ganancia Adaptiva Local Exponencial GALE y el histograma en azul.....81

Figura 31. a. Imagen de ultrasonido del fondo sin estructura y el histograma en azul, b. Imagen filtrada usando el método Bayesiano y el histograma en azul, c. Imagen filtrada usando el método Bayesiano con Ganancia Adaptiva Local Exponencial GALE y el histograma en azul.....82

Figura 32. Curva ROC para evaluar el desempeño de la detección en imágenes de ultrasonido reales.83

Figura 33. Curva ROC para evaluar el desempeño de la detección de imágenes simuladas.....86

Figura 34. Evaluación de una estructura de 5mm de diámetro con diferentes contrastes.88

Figura 35. SNR para evaluar el desempeño de detección en imágenes de ultrasonido simuladas con estructuras de 2mm (línea roja) y 5mm (línea verde).....88

Figura 36. Imágenes de la figura 34 filtradas con Hermite.89

Figura 37. SNR para evaluar el desempeño de detección en imágenes de ultrasonido simuladas y filtradas usando Hermite con estructuras de 2mm (línea en color rojo) y 5mm (línea en color verde).....90

Figura A1. Imagen a. de Ultrasonido sin procesar, b. filtrada usando Haar L=2 (L representa los niveles de descomposición), c. filtrada usando daubechies2 con L = 2, d. filtrada usando daubechies2 con L = 4, e. filtrada usando coiflet1 con L = 2, f. filtrada usando coiflet1 con L = 4, g. filtrada utilizando symlet2 con L = 2, h. filtrada utilizando symlet2 con L = 4, i. filtrada utilizando biorthogonal2.2 con L = 2 y j. filtrada utilizando biorthogonal2.2 con L = 2.....95

INDICE DE TABLAS

Tabla 1. Criterio de decisión.....	27
Tabla 2. Especificaciones de las imágenes reales.	42
Tabla 3. Resultados cuantitativos de los filtros aplicados en la imagen con speckle simulado con $\sigma = 0.4$	79
Tabla 4. Resultados cuantitativos de los filtros aplicados en la imagen con speckle simulado con $\sigma = 0.9$	79
Tabla 5. Área bajo la curva correspondiente a la figura 32.	85
Tabla 6. Area bajo la curva de la figura 33.	87

RESUMEN

En este trabajo se tiene como propósito el desarrollo de un método de detección de estructuras de bajo contraste en imágenes de ultrasonido, haciendo uso de técnicas de filtrado para mejorar la calidad de la imagen y por ende la detección. Los patrones de *speckle* hacen difícil realizar el análisis en este tipo de imágenes, por tal razón para la supresión de *speckle* y mejoramiento de la imagen se utilizan algoritmos basados en técnicas multiresolución. La transformada wavelet y Hermite constituyen una alternativa para efectuar esta tarea de filtrado. Estas técnicas trabajan considerando el *speckle* como una variable aleatoria que tiene una distribución de Rayleigh. Para el método utilizando transformada Wavelet, la clasificación de los píxeles a niveles de sub-banda se realiza usando un estimador Bayesiano. Los parámetros del estimador son calculados a través de un método de ajuste derivado del primer y segundo momento estadístico. El método de Hermite calcula una máscara para encontrar los píxeles que corresponden a *speckle* o a partes significantes en la imagen. En este proyecto se considera un modelo de detección binario (estructura presente y ausente) que depende del tamaño y el contraste de la estructura y del *speckle* en las imágenes. El algoritmo implementado puede ser útil en la detección automática de quistes y tumores en imágenes de ultrasonido de mama. Adicionalmente, se presenta una comparación cuantitativa y cualitativa de los métodos de filtrado desarrollados con otras aproximaciones publicadas que han sido aplicadas sobre imágenes de ultrasonido. Se estudiaron dos casos para los algoritmos de detección, en el primero se asume que cada imagen de ultrasonido es una realización de un proceso estocástico que muestra una distribución de Rayleigh, y en el segundo caso, las imágenes poseen una distribución Gaussiana como resultado de la suma de múltiples procesos aleatorios en los sistemas de ultrasonido. La validación del sistema de filtrado y detección se ha hecho usando imágenes simuladas y reales.

Los resultados obtenidos para el proceso de detección han sido analizados a través la curva ROC. El área bajo la curva obtenida para las imágenes de ultrasonido reales de fantasmas con *speckle* fue de 0.9159, para imágenes filtradas con el método Bayesiano fue de 0.9172, para las imágenes filtradas con Hermite fue de 0.9266 y para imágenes filtradas con el método Bayesiano con ganancia adaptiva local exponencial GALE fue de 0.9535. En el caso de las imágenes simuladas, el área bajo la curva obtenida para imágenes simuladas sin procesar fue de 0.3144, para imágenes filtradas con el método Bayesiano fue de 0.781, para las imágenes filtradas con Hermite fue de 0.9153 y para las imágenes filtradas con el método Bayesiano con ganancia adaptiva local exponencial GALE fue de 0.9380.

CAPITULO 1

INTRODUCCIÓN

En este trabajo de tesis se lleva a cabo el estudio de las imágenes de ultrasonido a través de un modelo matemático de detección y el análisis de algunos filtros de reducción de *speckle*, el cual es un patrón característico en este tipo de imágenes. En el desarrollo de la investigación se han utilizado imágenes sintéticas y reales de ultrasonido, útiles para validar los métodos de filtrado y detección. En este capítulo se exponen los antecedentes que se han analizado y que han sido base en esta investigación. De igual forma, se presentan los objetivos y la secuencia que se ha llevado a cabo en esta tesis.

1.1 Antecedentes

Las imágenes de ultrasonido son utilizadas en una amplia gama de aplicaciones clínicas. Son empleadas para una etapa primaria de revisión médica y a su vez para procedimientos de diagnóstico. Uno de los principales métodos de formación de estas imágenes esto basado en la transmisión de señales de ultrasonido de alta frecuencia hacia el cuerpo, seguido de un proceso de recepción, procesamiento y visualización de parámetros de los ecos. Aunque existen otras modalidades como es el ultrasonido por transmisión. Su importancia en medicina es debida principalmente a tres características: 1) es una modalidad que trabaja en tiempo real, 2) no utiliza radiación ionizante y 3) es de bajo costo.

Generalmente, las aplicaciones más comunes del ultrasonido son el diagnóstico en fetos y en ginecología para investigar sospecha de quistes en ovarios o tumores malignos. El ultrasonido en tareas de diagnóstico es empleado para la detección de lesiones de bajo contraste en tejidos suaves como el hígado, el bazo y el riñón. Análogamente puede ser

utilizado en otros tipos de tejidos como la mama y el abdomen para detectar la presencia de quistes o tumores. Estas imágenes son leídas por radiólogos quienes caracterizan el tejido como normal o anormal, basado en la detección de una lesión en un área de la imagen.

La precisión en el diagnóstico para detectar la presencia o ausencia de lesión depende de varios factores tales como tamaño y contraste la lesión dentro de la imagen de ultrasonido. En una imagen con alto contraste y con dimensiones de la lesión bastante grandes, la lesión se puede detectar con mayor facilidad.

En las imágenes de ultrasonido se puede percibir una fluctuación espacial, conocida como patrones de *speckle*, la cual se debe a los ecos generados por la dispersión de la señal al atravesar las heterogeneidades de los tejidos. Las características del *speckle* en una imagen particular dependen de varios factores, entre los que se pueden mencionar la frecuencia de onda del ultrasonido, la apertura del transductor y su posición. Un transductor con una resolución pequeña dará como resultado un tamaño de *speckle* pequeño, y viceversa. Los patrones de *speckle* tienden a degradar la resolución y el contraste de las imágenes; sin embargo, en ocasiones contienen información de interés sobre la estructura interna del tejido [1].

La detección de lesiones, tal como tumores, es muy común en imágenes de ultrasonido. En la actualidad existen diversas técnicas que nos permiten resolver este problema, pero mucha de ellas difieren en la eficiencia, rapidez y optimización de los procesos. En la detección se busca un alto grado de certeza, por lo que es muy importante tener en cuenta las características de este tipo de imágenes. Entre estas se encuentran la resolución espacial, la resolución de contraste y el ruido, lo que convierte este proceso en una tarea compleja que dificulta un buen diagnóstico médico.

Muchos métodos han sido desarrollados para el diagnóstico de imágenes por ultrasonido, los cuales –permiten ayudar a los médicos en la evaluación de diferentes clases de anomalías. Por consiguiente, todas las técnicas han sido un valioso avance en aplicaciones vinculadas con la medición automática de órganos en fetos o problemas de ginecología [2-4]. Sin embargo, la desventaja del *speckle* en imágenes de ultrasonido podría llevar a los médicos a interpretar con dificultad algunas enfermedades [5]. De la misma forma, el contraste limitado de las imágenes de ultrasonido puede causar algunos problemas en la diferenciación entre los tejidos normales y las lesiones [6]. Igualmente, si los niveles de gris en la ecografía son muy pequeños, resulta difícil distinguir con claridad el objeto y el fondo.

Las imágenes de ultrasonido, para el caso del diagnóstico de cáncer de mama, son una técnica complementaria a la mamografía [7]. La ecografía muestra un valor único para diferenciar tumores benignos de los malignos en estudios clínicos [8,9]. Sin embargo, las imágenes de ultrasonido modo B poseen una buena sensibilidad pero poca especificidad en el diagnóstico de tumores malignos debido a la información insuficiente que presentan este tipo de imágenes [10].

Harrison Barrett [18 - 20] en sus investigaciones trabajó en la evaluación objetiva de la calidad de imagen y el desempeño del observador Ideal. Estos trabajos dan un tratamiento riguroso al observador ideal y ofrecen algunos métodos de análisis convenientes para evaluar los sistemas de detección en imágenes de ultrasonido.

Muchas técnicas usadas para el análisis de imágenes de ultrasonido en tareas de detección están basadas en modelos estadísticos [11-14]. Smith y Wagner [15-17] desarrollaron un modelo estadístico para analizar la textura de las imágenes de ultrasonido, el cual se basa en el análisis que hace Goodman para modelar los patrones de *speckle* en la óptica coherente [22]. Las técnicas de detección desarrolladas por Smith y Wagner [15-17] son analizadas a través del estudio de contraste/detalle (Contraste vs

diámetro de la estructura) en imágenes de ultrasonido en presencia de *speckle*; este proceso se hace basado en el análisis estocástico de la señal y el ruido.

Insana y Hall [21], aparte de reforzar la interpretación de la teoría de Smith-Wagner, desarrollaron experimentos con observadores humanos, para medir que tan bien estos observadores detectan lesiones de bajo contraste en imágenes de modo B en comparación con el observador ideal. Para ello simularon un gran conjunto de imágenes de ultrasonido con lesión y sin lesión, y posteriormente, evaluaron el desempeño y eficiencia de observadores humanos. Clarkson y Barrett [23] proponen un observador ideal para una serie de tareas de detección binaria, en la cual se determina si está presente o ausente un tumor, considerando varios modelos de ruido con distribución Gaussiana, distribución exponencial y distribución de Poisson. Estos modelos de ruido conducen a la misma función de probabilidad y, por tanto, la misma estadística para el observador ideal.

Por otra parte, la naturaleza no invasiva, el bajo costo y la portabilidad hacen que el ultrasonido sea una atractiva herramienta para el diagnóstico médico. Sin embargo, presenta algunas limitaciones tales como la calidad, la cual es degradada por el efecto del *speckle*, dificultando la interpretación visual en este tipo de imágenes.

Un número de filtros en el dominio espacial han sido desarrollados para la reducción del *speckle* [24-26]. Yu y Acton[26] desarrollaron un filtro anisotrópico (SRAD) para suprimir el *speckle*, sin embargo sólo enfatiza en los bordes en lugar de mejorar la visualización. Loizou et al. y Pattichis et al. [24,25] implementaron seis filtros para resolver este problema basado en la difusión anisotrópica y la estadística local de los píxeles.

Los métodos de filtrado basados en multiresolución usando la transformada wavelet descomponen la información de la imagen en escala-espacio. Estas pueden ser clasificadas en dos categorías: 1) Métodos de Filtrado homomórfico y 2) Técnicas de filtrado no

homomórfico. En las primeras, el filtrado wavelet se aplica sobre la transformación logarítmica de la imagen de ultrasonido y posteriormente se retorna al espacio original de la imagen a través de una operación exponencial [27-32]. En el filtrado no homomórfico, los procesos se realizan sobre la imagen original [33,34].

Todas las técnicas de filtrado homomórfico son computacionalmente muy costosas debido a la adición de operaciones logarítmicas y exponenciales. Hay pocos métodos publicados en la literatura de filtros no homomórficos. Entre los más destacados se tiene el propuesto por Pizurica et al.[33], el cual es un método en el dominio Wavelet que se basa en el conocimiento de las características significativas de la imagen en las diferentes escalas para la clasificación de los coeficientes, logrando un mejoramiento en la calidad de la imagen. Recientemente, Yue et al. y Croitoru et al.[35] desarrollaron un método de difusión basado en wavelet para supresión de ruido y mejoramiento de bordes en imágenes de ultrasonido, el cual es computacionalmente muy costoso.

En este trabajo se realiza el filtrado usando un método basado en Hermite [85, 86, 92] y un método bayesiano de contraste Adaptativo [27, 31]. Se comparan los resultados obtenidos por los métodos implementados con los métodos expuestos en la literatura. Estas técnicas han demostrado ser eficientes para reducir el *speckle* mientras preservan algunas características como los bordes.

Finalmente, el objetivo principal de este trabajo es la implementación de un algoritmo de detección aplicado a imágenes de ultrasonido de bajo contraste, el cual se ha validado en imágenes originales y a sus versiones filtradas. En este trabajo se hace la evaluación de la regla de decisión cuando la imagen muestra una distribución de Rayleigh [15-17, 92] y una distribución Gaussiana [47-50, 92].

1.2 Objetivos

- Desarrollar un método de detección para estructuras de bajo contraste en imágenes de ultrasonido.
- Aplicar técnicas de filtrado para mejoramiento de las imágenes de ultrasonido.
- Evaluar el comportamiento del sistema de detección en imágenes de ultrasonido filtradas.
- Realizar pruebas y analizar el criterio de decisión del sistema para imágenes filtradas y sin filtrar.

1.3 Información General de la Tesis

El reporte de investigación ha sido dividido en los siguientes capítulos:

En el capítulo 2 se explican los conceptos básicos de las imágenes de ultrasonido y la importancia que tiene en la realización de diagnósticos médicos.

En el capítulo 3 se analizan las diferentes técnicas de filtrado para remover los patrones de *speckle* y los parámetros estadísticos utilizados para evaluar la calidad de la imagen de ultrasonido. Así mismo, detalla los modelos de detección de estructuras de bajo contraste en imágenes de ultrasonido teniendo en cuenta la función de densidad probabilística.

En el capítulo 4 se realiza una descripción de los métodos de filtrado y detección implementados para el trabajo de tesis.

En el capítulo 5 muestra los resultados de los algoritmos implementados, comparaciones y evaluaciones cuantitativas tanto para filtrado como para detección.

Finalmente, en el capítulo 6 se presentan las conclusiones y los logros alcanzados en el trabajo.

CAPITULO 2

IMÁGENES DE ULTRASONIDO

En este capítulo se describirá de forma general los principios fundamentales del ultrasonido, útiles para entender el proceso de formación de las imágenes. Asimismo, se detallarán algunas características importantes que se deben tener en cuenta para el diagnóstico clínico.

La modalidad de imagenología médica por ultrasonido es usada en muchas aplicaciones de diagnóstico como pueden ser en obstetricia, ginecología, en estudios de la mama, entre otros. Tal como se mencionó anteriormente, la base de su operatividad es la transmisión de ondas de ultrasonido de alta frecuencia dentro del cuerpo, seguido por la adquisición y procesamiento de los ecos al pasar por estructuras y tejidos. Las imágenes de ultrasonido típicamente muestran una imagen que es típicamente una sección transversal del tejido bajo investigación. El ultrasonido es una técnica útil principalmente para tejido suave dado que la metodología de ultrasonido no suministra imágenes valiosas a través de huesos o cuerpos de gas tal como el intestino y el pulmón [39].

Sus ventajas con respecto a otros tipos de imagenología son debidas a tres características importantes:

- ✓ Es una modalidad en tiempo real. En las imágenes de ultrasonido se puede visualizar el movimiento de órganos en tiempo real.
- ✓ No utiliza radiación ionizante. Esto quiere decir que son esencialmente libre de riesgo para el paciente.

- ✓ Son de bajo costo con respecto a las otras modalidades de imagenología médica como son las tomografías y resonancia magnética, donde los sistemas son muy costosos y no tan portables.

Las imágenes por ultrasonido, sólo se puede obtener una resolución espacial de unos milímetros, lo cual puede resultar muy limitado para algunas partes del cuerpo.

2.1 Fundamentos generales del ultrasonido

En la generación de imágenes de ultrasonido se mide el tiempo transcurrido entre la emisión de un pulso de sonido y la recepción de su eco. En la figura 1 se ilustra un esquema general del principio básico de la formación de las imágenes de ultrasonido.

El sonido emitido o reflejado por un objeto en movimiento sufre un cambio en la frecuencia. Esto se conoce como el efecto Doppler. El Doppler en imágenes de ultrasonido permite realizar mediciones de los movimientos mecánicos del cuerpo. Entre los ejemplos más comunes se encuentran: el flujo sanguíneo en las venas y las arterias, y los movimientos de las válvulas y los músculos dentro del corazón [39].




Figura 1. El principio de las imágenes de ultrasonido. Un pulso de ultrasonido, emitido desde un transductor piezoeléctrico, ingresa en el cuerpo y es parcialmente reflejado

desde diferentes tejidos. Estas ondas reflejadas son detectadas por el receptor (Imagen tomada de Guy C. [41], p. 269).

En las ondas de ultrasonido la dirección de la vibración de las partículas y la propagación de las ondas es la misma, lo que significa que el ultrasonido puede ser considerado como una onda longitudinal. Esto sucede cuando el tejido no es fluido o gas.

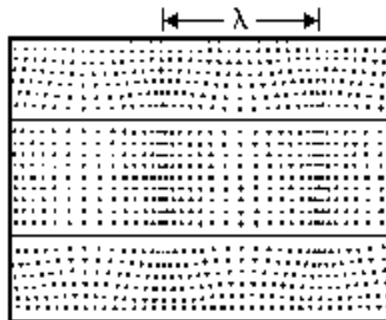


Figura 2. Ondas longitudinales

(Imagen tomada de <http://www.inchem.org/documents/ehc/ehc/ehc22.htm>).

Cuando el haz de ultrasonido pasa a través del cuerpo se encuentra con tejidos de diferentes propiedades acústicas. Cuando una onda de ultrasonido llega a la frontera de dos tejidos con diferente impedancia acústica, pueden ocurrir los fenómenos de reflexión, refracción, dispersión, absorción y atenuación. Los detalles de los principios físicos y matemáticos de los fenómenos de reflexión y refracción de las ondas de ultrasonido pueden ser revisados en [39-43].

La **dispersión** o **esparcimiento** ocurre si el haz de ultrasonido choca con una estructura que es aproximadamente del mismo tamaño o menor que la longitud de onda del ultrasonido. En este caso la onda se dispersa en todas las direcciones. La dependencia angular y la magnitud del haz dispersado dependerán de la forma, tamaño y propiedades físicas y acústicas del objeto. Cuando el tamaño de la estructura es pequeño comparado

con la longitud de onda, la dispersión es relativamente uniforme en dirección con más energía que se dispersa hacia el transductor que lejos de este [39-41].

Si las estructuras están muy cercanas unas de otras, como se muestra en la figura 3b, los patrones de dispersión son adicionados constructivamente. Si las estructuras están relativamente muy separadas, como se visualiza en la figura 3c, entonces el patrón resultante es una combinación de interferencias constructivas y destructivas conocidas como *speckle* [39].




Figura 3. a. Fenómeno de Dispersión, b. Dispersión con estructuras muy cercanas, c. Fenómeno de dispersión cuando las estructuras están muy separadas, d. Imagen de ultrasonido con áreas de alta y baja intensidad debido al fenómeno de dispersión (Imagen tomada de Nadine Barrie Smith [39], p. 153).

El *speckle* puede ser clasificado en varias clases, según el número de dispersores por celda de resolución, la distribución espacial y las características del sistema de imagenología. En la literatura se han propuesto cuatro modelos con las siguientes características [94]:

- ✓ **Speckle completamente formado.** Se produce cuando el número efectivo de dispersores en la celda de resolución es grande. Aquí no se tienen componentes deterministas y la envolvente se modela como una distribución Rayleigh [94].
- ✓ **Speckle completamente resuelto.** El número efectivo de dispersores sigue siendo grande. La superficie de dispersión muestra una periodicidad que se refleja en una componente determinista que dará lugar a una estructura clara en la imagen. Corresponde a una reflexión especular. La envolvente se va a modelar como una distribución Rice la cual es una generalización de la distribución de Rayleigh [94].
- ✓ **Speckle parcialmente formado.** El número efectivo de dispersores ya no se puede considerar grande. No tenemos componentes deterministas pero la aproximación Rayleigh no es adecuada. la envolvente se va a comportar como una distribución K [94].
- ✓ **Speckle parcialmente resuelto.** El número efectivo de dispersores es pequeño y tenemos componente determinista, la envolvente sigue la distribución K [94].

En la transmisión de un haz de ultrasonido a través de un medio heterogéneo tal como el tejido blando, la intensidad sufre del fenómeno de **atenuación** debido a una serie de mecanismos entre los que se incluyen la divergencia del haz, dispersión, absorción, reflexión y difracción. Este fenómeno Cada tipo de estructura tiene un coeficiente de atenuación característico. La cantidad de intensidad transmitida es de tipo exponencial.

Para los ultrasonidos se establece un coeficiente de atenuación que varía con las propiedades del medio y con la frecuencia misma de la onda [40,42]. La cantidad de energía absorbida durante la propagación de la onda depende de la distancia recorrida, la viscosidad del tejido y la frecuencia.

2.2 Sistemas de imagenología ultrasónica

Los materiales más comunes para generar y detectar las ondas de ultrasonido son los piezoeléctricos. En general, un transductor usa un arreglo de elementos piezoeléctricos y son usados para transmitir una serie de pulsos de ultrasonido y para detectar el retorno de los ecos. El éxito de un sistema de ultrasonido depende de la calidad de este componente. Estos transductores incluyen un cristal piezoeléctrico hecho de materiales como zirconato titanate de plomo (PZT) entre un par de electrodos. Por lo general, un pequeño voltaje es aplicado al cristal lo que provoca que resuene produciendo ondas de sonido. El cristal también detecta ondas de sonido y produce una señal eléctrica [39].

En algunas aplicaciones de imagenología médica, un pulso normal tiene aproximadamente $1\mu\text{s}$ de duración con una frecuencia de 5MHz. Los pulsos deben ser separados por 1ms, resultando en una repetición de pulso de 1000 Hz. Ellos viajan a través del tejido suave a una velocidad aproximada de 1540 m/s, aunque esto depende siempre del tejido. En la figura 4 se puede observar el proceso descrito previamente [39].

Hay tres modos de operación de ultrasonido aplicado a la evaluación de estructuras anatómicas: el modo A, el modo M y el modo B, los cuales serán descritos a continuación. Dependiendo de la aplicación clínica es el modo a utilizar [40-43].

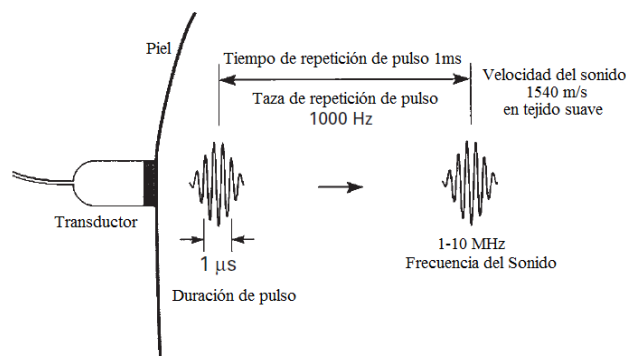


Figura 4. Diagrama de un haz de ultrasonido clínico. (Imagen tomada de Wolbarst, 1993, p. 408.)

2.2.1 Modo A

Un escáner modo A adquiere señal unidimensional, la cual muestra las variaciones en la intensidad del eco retornado como una gráfica simple que mide las variaciones de amplitud con respecto al tiempo. Por ser unidimensional, la información anatómica que proporciona es limitada. Una de las aplicaciones más importantes en modo A es la paquimetría corneal, donde se mide el espesor del tejido corneal o grosor de la cornea ya que es una técnica no invasiva [39]. Un ejemplo de un ultrasonido en modo A se muestra en la figura 5.




Figura 5. Escáner modo A para medir el espesor de la cornea. Un haz de ultrasonido de alta frecuencia es utilizado (Imagen tomada de Nadine Barrie Smith [39], p. 175).

2.2.2 Modo M

El escaneo en modo M adquiere continuamente una serie de líneas en modo A y las muestra como una función del tiempo. El brillo de la señal modo M mostrada representa la amplitud de los ecos retornados. Las líneas son observadas con un incremento de base de tiempo en el eje horizontal, tal como se aprecia en la figura 6.




Figura 6. Adquisición en modo M (Imagen tomada de Nadine Barrie Smith [39], p. 176), a. El transductor es localizado para escanear el corazón, b. Imagen de ultrasonido modo M.

Varios cientos de líneas pueden ser adquiridas por segundo, además es posible visualizar en tiempo real los movimientos. El modo M es usado comúnmente para obtener imágenes cardíacas [39-43].

2.2.3 Modo B

El ultrasonido en modo B es el más usado para tareas de diagnóstico. Este tipo de ultrasonido produce una imagen en dos dimensiones de una sección transversal o una rebanada de la estructura anatómica mediante el barrido del haz en repetidas ocasiones hacia delante y hacia atrás en el cuerpo del paciente. Cada barrido se utiliza para formar una sola línea vertical de la imagen en modo B que comprende una serie de puntos brillantes. El brillo de los puntos es determinado por la intensidad de los ecos reflejados.

El barrido se consigue ya sea mecánicamente, utilizando la oscilación o rotación del transductor, o electrónicamente, mediante el uso de una matriz de elementos piezoeléctricos en lugar de un solo cristal, y retrasando individualmente cada pulso de voltaje de cada elemento. En la figura 7 se hace una descripción del esquema previamente

mencionado. Como se observa, después que todos los ecos se han producido a lo largo de la dirección del haz, ésta se cambia electrónicamente mediante la introducción de retardos de tiempo en los elementos piezoeléctricos del transductor para luego adquirir la línea de datos es adquirida [39].

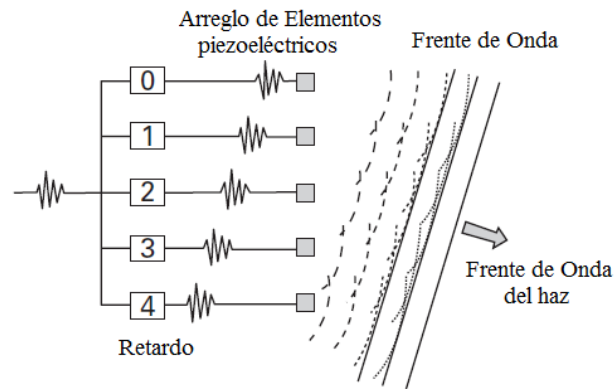


Figura 7. Esquema del arreglo de elementos piezoeléctricos en un ultrasonido modo B (Imagen tomada de Geoff Dougherty [40], p. 95).

Al hacer el barrido, las líneas típicamente están conformadas entre 128 y 256 puntos y son utilizadas para construir una imagen como se muestra en la figura 8.



Figura 8. Imagen modo B de la vesícula biliar que muestra la presencia de pólipos (Imagen tomada de Geoff Dougherty [40], p. 95).

El tiempo requerido para adquirir los ecos a lo largo de una sola línea es del orden de 100 ms, por lo que una sola imagen puede adquirirse en decenas de milisegundos. Asimismo, al tener continuos barridos del haz permite que la imagen se actualice en tiempo real.

Las imágenes en tres dimensiones se obtienen adicionando filas de elementos piezoeléctricos lo cual permite tener una matriz de transductores con la que se realiza el escaneo. Si se adiciona un gran número de filas comparable al número de elementos de cada fila, entonces la geometría del arreglo piezoeléctrico es en dos dimensiones y el barrido da una imagen en tres dimensiones [39], tal como se ilustra en figura 9.



Figura 9. Imagen tridimensional de un feto de 12 semanas (Imagen tomada de Geoff Dougherty [40], p. 96).

2.2.4 Ultrasonido Compuesto

En esta modalidad se adquiere una imagen de ultrasonido desde múltiples ángulos y luego se combinan las imágenes. Los múltiples ángulos se consiguen con un arreglo de fase con diferentes esquemas de formación de haz. La mayor ventaja del ultrasonido de modo compuesto es que reduce el nivel de *speckle* en la imagen. Debido al patrón de interferencia constructiva y destructiva del ángulo del haz de incidencia, cada imagen por

separado tiene una contribución diferente de *speckle*. Sin embargo, las características reales de la imagen están presentes en todas la vista. Como resultado de la combinación de las imágenes se produce una imagen compuesta con el ruido reducido [39, 40]. Un ejemplo de este tipo de imágenes se muestra en la figura 10.




Figura 10. Bifurcación (Imagen tomada de Nadine Barrie Smith [39], p. 177), a. adquirida usando ultrasonido convencional, modo B, b. adquirida usando ultrasonido modo compuesto con nueve orientaciones diferentes.

2.3 Aplicaciones Clínicas del Ultrasonido

El ultrasonido es ampliamente usado en radiología debido al costo relativamente bajo, la alta portabilidad y su naturaleza no invasiva. Los desarrollos recientes tales como ultrasonido de modo compuesto, imágenes armónicas y arreglos de dos dimensiones han incrementado la calidad y utilidad del ultrasonido. El ultrasonido es la única modalidad capaz de suministrar una muy alta velocidad de fotogramas en tiempo real. Esta modalidad no tiene casi contraindicaciones como en el caso de MRI, las cuales no pueden ser usadas sobre pacientes con muchos tipos de implantes. Además, es la única modalidad de imagenología que se usa para el seguimiento durante el embarazo [39].

2.3.1 Ginecología y Obstetricia

Algunos parámetros tales como el tamaño de la cabeza del feto, y la columna vertebral son generalmente medidos para evaluar la salud del feto. La amniocentesis es necesaria para detectar desordenes como el síndrome de Down, donde el ultrasonido se utiliza para ver la orientación de la aguja en este procedimiento.

El ultrasonido doppler se usa para medir los parámetros fetales cardiacos como puede ser la velocidad de la sangre. El ultrasonido en tres dimensiones suministra imágenes de alta resolución del desarrollo del feto. Sin embargo, estas imágenes tienden a ser mas para mostrar a la madre que para diagnóstico clínico. Ejemplos de la alta resolución espacial y un excelente contraste en las imágenes son mostrados en la figura 11.




Figura 11. Imágenes de ultrasonido modo B (Imagen tomada de Nadine Barrie Smith [39], p. 194), a. en dos dimensiones de un feto de 19 semanas, b. cerebro fetal y c. imagen fetal en tres dimensiones usando arreglos en dos dimensiones.

2.3.2 Imagen de la Mama

Las imágenes de ultrasonido son usadas para diferenciar entre lesiones solidas y quistes, y son útiles para evaluaciones de mujeres jóvenes con tejido mamario denso o embarazadas, ya que los rayos X no son eficaces o no son permitidos [39]. El Colegio Americano de Radiografía define cinco diferentes categorías de lesiones basadas en las medidas morfométricas y las características de la imagen. El ultrasonido de alta

frecuencia, entre 9 y 12 MHz, es usado para obtener un óptimo contraste en la imagen, así como para obtener una alta resolución axial y lateral. Un procedimiento estándar es el uso del ultrasonido modo B. Las lesiones de mama son generalmente hipoecoicas, apareciendo más oscuras que el tejido circundante.

Las imágenes compuestas y armónicas han sido recientemente utilizadas ya que reducen el patrón de *speckle* y los artefactos del eco interno. En muchos casos, tumores de mama sólidos están mejor delineados utilizando una imagen armónica. Sin embargo, debido a la alta frecuencia de los ecos retornados, el ultrasonido de modo B es usado preferiblemente para lesiones profundas. En la figura 12 se observan dos ejemplos de masas de mama detectados mediante ultrasonido.

En el diagnóstico radiológico, el escaneo en dos dimensiones, en tiempo real, es un método efectivo para obtener imágenes guiadas necesarias en la adquisición de la biopsia de una lesión, en la que se extrae una muestra de la lesión para hacerle el análisis bioquímico que determinará si el tumor es canceroso o no.




Figura 12. Imágenes de ultrasonido de la Mama (Imagen tomada de Nadine Barrie Smith [39], p. 195), a. Fibroadenoma, b. Masa en la mama.

2.3.3 Estructura del Musculo Esquelético

Las nuevas tecnologías de escaneo compuesto y armónico han hecho mejoras significativas en las imágenes de ultrasonido músculo-esquelético (MSK) [44]. En particular, el escaneo compuesto mejora la calidad de las imágenes del tendón y el nervio, ya que éstos se caracterizan por producir una gran cantidad de *speckle*. Algunas imágenes de ejemplo se muestran en la Figura 13. La detección de lesiones pequeñas también se mejoró significativamente por el escaneo compuesto. Las imágenes Doppler pueden detectar un flujo reducido en los vasos superficiales, lo cual es común en enfermedades como el reumatismo y otras inflamatorias. Las imágenes tridimensionales a menudo se utilizan para imágenes complicadas de articulaciones. Por último, la guía del ultrasonido se utiliza a menudo para procedimientos intervencionistas MSK en la que las agujas deben ser colocadas con exactitud dentro de una articulación en particular.




Figura 13. Escáner compuesto (Imagen tomada de Nadine Barrie Smith [39], p. 195), a. un tendón de la mano. b. Lesión en el hombro.

2.3.4 Ecocardiografía

Una imagen modo B del corazón es usada para determinar clínicamente parámetros relevantes tales como tamaño y función ventricular [45]. Aplicaciones en este tipo de imágenes nos indican los primeros signos de enfermedades cardiacas tales como dolor de pecho, embolias cardiacas e infartos, enfermedades en las válvulas y arritmias cardiacas.

Además de las mediciones morfométricas, los equipos de ecocardiografía utilizan imágenes Doppler para el análisis de los movimientos de la pared del ventrículo, como se muestra en la figura 14. La ecografía tridimensional es probable que desempeñe un papel cada vez más importante en la ecocardiografía porque podría medir cuantitativamente la fracción de eyección y la masa ventricular.




Figura 14. Ecocardiografía (Imagen tomada de Nadine Barrie Smith [39], p. 196), a. Regurgitación mitral causada por lesión a la válvula después de un ataque cardíaco. b. Se puede apreciar la orejuela de la aurícula izquierda (LAA), la aurícula izquierda (LA) y el ventrículo izquierdo (LV).

Los agentes de contraste de microburbujas pueden ser utilizados para opacar el ventrículo izquierdo y para medir la perfusión en el miocardio, aunque estos procedimientos no se realizan ampliamente. Como ocurre con muchas otras aplicaciones del ultrasonido, la ecocardiografía es una modalidad de bajo riesgo. Esta es la primera opción a usar cuando no se quiere tener grandes radiaciones asociadas. Puede ser utilizada en pacientes con marcapasos y desfibriladores, los cuales son incompatibles con MRI. Un ecocardiógrafo portable puede incorporar ultrasonido compuesto, imágenes en tres dimensiones, imágenes en modo M y sofisticados arreglos de fase [39].

CAPITULO 3

DETECCIÓN Y FILTRADO

En este capítulo se exponen algunos conceptos generales sobre la teoría de detección y filtrado enfocada a aplicaciones en imágenes de ultrasonido. Aquí se dan detalles técnicos y matemáticos sobre varios métodos comunes y conocidos en la literatura.

3.1 Detección

En esta sección se introducen los conceptos generales de la teoría de detección en un contexto de aplicaciones binarias donde se toman decisiones sobre la presencia o ausencia de una señal. Esta teoría es la base fundamental para el desarrollo de este proyecto y constituye una tarea muy común en imágenes médicas. La teoría de detección se utiliza para analizar datos procedentes de experimentos en los que la tarea es clasificar determinadas características que pueden ser generadas, ya sea por un proceso conocido (señal) o generadas por cambios (ruido). La teoría de detección ha sido adoptada de las aplicaciones de radar y ha sido extendida a otras clases de aplicaciones como es el caso de las imágenes médicas para la detección de lesiones.

El objetivo de la teoría de detección es estimar dos parámetros principales de los datos experimentales. El primer parámetro indica la intensidad de la señal (en relación al ruido), denotado por d . El segundo parámetro es la respuesta de decisión. La teoría de decisión de señales es usada en diferentes campos de investigación tales como la psicología (psicofísica y percepción), diagnóstico médico (para determinar si los síntomas coinciden con un diagnóstico conocido o si estos son irrelevantes) y para la decisión estadística (donde los datos indican que los experimentos tienen un efecto o no).

3.1.1 El Modelo para el Criterio de Decisión

La detección es un método usado para modelar el proceso de decisión de un sistema con respecto a diferentes clases. Cuando se trabaja con la teoría de detección se describe el desempeño en términos de éxitos y falsas alarmas, es decir, si una señal está presente y el observador identifica correctamente la señal es denominado éxito. En caso contrario, si la señal está ausente y el observador dice que la señal está presente, entonces es una falsa alarma.

En este proyecto se utiliza esta teoría de detección para determinar si existen estructuras en una imagen de ultrasonido. Estas estructuras tratan de simular la presencia de masas tumorales en imágenes de mamas, por lo que tienen algunas características específicas como tamaño, contraste y forma. Se ha mencionado previamente que el problema de las imágenes de ultrasonido se debe a los patrones de *speckle*, los cuales son considerados como un tipo de ruido que dificultan las tareas de diagnóstico. En el análisis de los datos para las tareas de detección se consideran a las imágenes de ultrasonido como procesos estocásticos o señales con múltiples variable aleatorias que tienen una distribución de probabilidad específica.

En este trabajo, el criterio de decisión se diseña de tal forma que sea capaz de discernir si una señal (estructura en la imagen de ultrasonido) está presente o no. Como el tratamiento dado es puramente estadístico, se van a tener dos tipos de distribuciones de probabilidad: una cuando la señal está presente y otra cuando está ausente. El criterio de decisión es entonces una función matemática que analiza la distribución de una muestra de ejemplo y luego determina si esa muestra contiene o no la señal de acuerdo a si es mayor o no a un respectivo umbral. En la tabla 1 se observan los cuatro tipos de respuestas que se pueden encontrar con el criterio de decisión de acuerdo con la presencia y ausencia de la señal o estructuras como es el caso de este proyecto.

Tabla 1. Criterio de decisión.

Realidad	Decisión	
	Positiva	Negativa
Señal Presente < Umbral	VP (Verdaderos-Positivos)	FP (Falso-Positivos)
Señal Ausente ≥ Umbral	FN (Falsos-Negativos)	VN (Verdaderos-Negativos)

3.1.2 Teoría de detección de señales y Prueba de Hipótesis

Las proporciones de los éxitos y falsas alarmas reflejan el efecto de dos parámetros: el primero refleja la separación entre la señal y el ruido; el segundo, el índice de detectabilidad en la imagen. El camino más común para expresar la regla de decisión es un umbral, el cual viene relacionado con el conocido observador ideal.

El rendimiento de un observador es analizado por las probabilidades de error de la decisión (tabla 1). La curva ROC (Característica Operativa del Receptor) es el procedimiento más común para evaluar el rendimiento del observador. Una curva ROC grafica los valores de probabilidad de los Verdaderos-Positivos (VP) para todos los posibles valores de Falsos-Positivos (FP). Curvas con áreas cercanas a 1 identifican un alto desempeño del observador en la evaluación del diagnóstico.

Otra medida muy utilizada para evaluar el desempeño del observador está representada por la relación señal a ruido, definida como la separación media de la probabilidad de la estadística de prueba por la desviación estándar:

$$SNR = \frac{\mu_1 - \mu_0}{\sqrt{0.5(\sigma_1^2 + \sigma_0^2)}} \quad (1)$$

donde μ_1 , μ_0 , σ_1^2 y σ_0^2 son las medias y las varianzas de la estadística de prueba de la hipótesis de señal presente y la de señal ausente, respectivamente.

Para el diagnóstico existen varios modelos y procedimientos que permiten definir un observador. Estos están expresados matemáticamente o computacionalmente [19, 50].

3.1.3 Modelos de observadores para la detección en imágenes de ultrasonido

Los modelos de observadores han sido formulados por dos razones. La primera es que en algunos casos han sido desarrollados para mejorar la predicción del observador humano. La segunda razón es referida a la necesidad de un modelo más complejo de detección que considere procesos aleatorios donde las características de las señales son desconocidas. En muchos casos el modelo de observador ideal es incapaz de adaptarse a tareas complejas. Algunos modelos de observadores ideales serán descritos en esta sección.

3.1.3.1 Observador ideal Bayesiano

EL observador ideal Bayesiano es el sistema con el mejor desempeño dado por la curva ROC [19]. Tiene la mayor probabilidad de Verdaderos-Positivos para todos los Falso-Positivos comparados con otros tipos de observadores. Matemáticamente, la estadística de prueba está dada por una relación de probabilidad logarítmica [46]:

$$\lambda(g) = \log \left(\frac{pdf(g/H_1)}{pdf(g/H_0)} \right) \quad (2)$$

donde H_1 y H_0 representan la hipótesis de señal presente y señal ausente, y la *pdf* representa la densidad de probabilidad en cada caso y g representan los pixeles de la imagen ordenados en forma vectorial.

Con probabilidades a priori y un modelo de costos para un modelo Bayesiano, se puede seleccionar un valor umbral que optimice la relación costo –beneficio en la regla de decisión.

El observador ideal es muy importante en el diagnóstico médico. En este tipo de aplicaciones se debe conocer toda la información de la imagen para diseñar la regla de decisión. Si el desempeño del observador ideal es mejor que el del observador humano, entonces se sugiere utilizar algoritmos que mejoren la calidad de la imagen.

3.1.3.2 Señales Estadísticamente Conocidas

Se considera que una señal es estadísticamente conocida para la tarea de detección si se conoce la potencia del ruido, el tamaño de la lesión, el contraste del objeto, la forma y la localización. Se desconoce la realización aleatoria del objeto y el proceso del ruido. En el modelo se asume que el objeto puede ser modelado como un proceso aleatorio Gaussiano de media cero y puede ser modelado como se observa en los trabajos [23,47, 48, 49, 50].

$$\begin{aligned} pr(g/H_1) &= N(0, K_1) \\ pr(g/H_0) &= N(0, K_0) \end{aligned} \tag{3}$$

donde K_1 y K_0 representan la matriz de covarianza de la señal presente y la señal ausente, respectivamente, y g representan los píxeles de la imagen ordenados en forma vectorial.

La relación de probabilidad logarítmica es la función de decisión del observador ideal. De la ecuación anterior, ignorando las constantes y los términos independientes, la regla de decisión queda determinada por:

$$\lambda(g) = g^t (K_1^{-1} - K_0^{-1})g \tag{4}$$

3.1.3.3 Observador Hotelling

El modelo estadístico de la señal estrictamente conocida no es bueno en algunas tareas de clasificación clínica. El tamaño, la forma, y la localización de las estructuras a ser detectadas o discriminadas no son conocidas a priori, y el fondo de la imagen no es uniforme. El observador Hotelling es un discriminador lineal óptimo. Fue propuesto para propósitos médicos por Barrett [18]. En el proceso se calculan las medias y las matrices de covarianzas de un conjunto de objetos.

Dos matrices son definidas S_1 y S_2 . La primera es la matriz de dispersión que mide la desviación de la imagen promedio para cada clase y la imagen promedio de todas las clases.

$$S_1 = \sum_{j=1}^J P_j (\bar{f} - \bar{f}_j) (\bar{f} - \bar{f}_j)' \quad (5)$$

donde j representa las clases de la imagen, P_j es la probabilidad de la clase j , \bar{f}_j es la imagen promedio para la clase j , y \bar{f} es la imagen promedio de todas las clases.

$$\bar{f} = \sum_{j=1}^J P_j \bar{f}_j \quad (6)$$

S_2 es la matriz de covarianza promedio:

$$S_2 = \sum_{j=1}^J P_j K_j \quad (7)$$

donde P_j es la probabilidad de la clase j y K_j es la matriz de covarianza de la clase j .

Para tareas binarias [18] se tiene que:

$$S_1 = \sum_{j=1}^J P_1 P_2 (\bar{f}_2 - \bar{f}_1) (\bar{f}_2 - \bar{f}_1)' \quad (8)$$

Por lo tanto, la regla de decisión del observador Hotelling es:

$$\lambda = \left(H(\bar{f}_2 - \bar{f}_1) \right)' S_2^{-1} H f \quad (9)$$

El observador Hotelling ha sido exitoso para predecir el desempeño humano en algunas tareas de variabilidad del objeto [51-53].

3.1.3.4 Modelos Non prewhitening (NPWMF)

El modelo NPWMF ha demostrado en diversas investigaciones que su detectabilidad permite buena correlación con el observador humano [54,55]. La relación señal a ruido SNR o el índice de detectabilidad de este observador esta dado por:

$$d_{NPW} = \frac{\langle s \cdot g_1 \rangle - \langle s \cdot g_0 \rangle}{\sqrt{1/2 \cdot (\sigma^2(s \cdot g_1) + \sigma^2(s \cdot g_0))}} \quad (10)$$

donde g_0 y g_1 son los vectores que contienen la imagen con la señal ausente y la señal presente respectivamente, s es el vector esperado, el cual es calculado a priori de las señales presentes y ausentes, y σ^2 es la varianza de la imagen.

El modelo NPWMF es otro método óptimo de detección, aunque es incapaz de tener en cuenta la correlación del ruido o alternativamente el uso de información implícita en la correlación del ruido.

3.1.3.5 El observador Humano

Para muchos propósitos, las imágenes médicas son interpretadas por observadores humanos. Por lo tanto, el desempeño en tareas clínicas relevantes es un estándar para evaluar los sistemas de imagenología. Las tareas de detección para las cuales los experimentos humanos son desarrollados casi siempre son binarias, es decir que hay dos posibles estados: anormal o normal. Las imágenes usadas para los experimentos pueden

ser obtenidas por simulaciones, a través de fantasma (*phantom*) anatómicos, o por un conjunto de imágenes clínicas reales.

3.1

3.2 Filtrado

La calidad de las imágenes de ultrasonido es limitada tanto en resolución como en contraste debido a la interferencia constructiva y destructiva de las dispersiones cuando se forma la imagen. Hemos mencionado que estas interferencias producen el *speckle* que degradan significativamente la imagen, lo cual aumenta la dificultad para un diagnóstico médico. Es frecuente observar el *speckle* en imágenes de órganos blandos como el hígado y el riñón, cuyas estructuras son muy pequeñas con respecto a las grandes longitudes de onda utilizadas en ultrasonido.

Varios filtros han sido desarrollados para reducir el ruido *speckle*, entre los que se encuentran filtros lineales [56,69], promedio temporal [15,22, 57-59], y filtro de mediana [60, 61]. Por otra parte, se han usado combinaciones de filtros no lineales para la reducción de ruido [62].

Sin embargo, los métodos desarrollados para suprimir ruido aditivo tienen poca aplicación cuando se trata de reducir *speckle*. Los filtros lineales [62] no son una herramienta óptima para esta tarea de supresión de *speckle* ya que suavizan la imagen mientras degradan detalles importantes como bordes y algunas texturas.

3.2.1 Filtro de Mediana

El filtrado de mediana elimina artefactos en pequeñas áreas. Debido a esto, cuando el tamaño del *speckle* es más grande que la ventana del filtro, no se presenta ningún cambio en la imagen [64]. Varios filtros adaptativos implementados han llegado a ser ineficientes

debido a distintos parámetros entre los que se destacan el tamaño de la ventana que se utiliza y el umbral del *speckle* usado, lo que ha ocasionado que el método no se relacione con los modelos de *speckle* dados en la literatura [63].

Los filtros adaptativos de mediana propuestos, en particular Loupas et al. [65], definen un filtro de mediana de pesos el cual usa la relación de media a varianza como una medida de que tan cercano es el valor de los píxeles en un área. Una relación de media a varianza pequeña causa que el filtro adicione un peso al pixel del centro de la ventana antes de realizar la operación de mediana. Por el contrario, si la relación señal a ruido es grande implica que el pixel central está en la región de intensidad donde los píxeles son casi uniformes. En este caso se le da un peso más grande. El peso asignado a cada pixel a una distancia d del pixel central [65] está dado por la expresión:

$$w = \left[99 - 20d \frac{\sigma^2}{\mu} \right] \quad (11)$$

donde σ^2 es la varianza local, μ es la media local. Los valores de 99 y 20 son constantes determinadas empíricamente. Con el algoritmo de mediana adaptativa se puede aplicar más o menos emborronamiento en la imagen dependiendo de la estadística local de la misma.

3.2.2 El filtro SRAD

El método de difusión no lineal [26, 62-64, 66-78] puede ser considerado como un filtro adaptativo cuya dirección de suavizado e intensidad son controlados por una función de bordes. Un filtro de difusión anisotrópica para reducción de *speckle* (SRAD) [26] trabaja sobre un coeficiente instantáneo de variación como un detector de borde para imágenes con *speckle*. Un detector de *speckle* que simplemente combina la magnitud del gradiente y laplaciano no puede realizar bien la tarea para bordes entre regiones con diferentes niveles de grises. Un método para la reducción de ruido y mejora de la calidad de la

imagen se basa en modelos de difusión coherente no lineal (NCD) [63]. Este enfoque combina tres modelos diferentes: difusión isotrópica, difusión coherente anisotrópica y movimiento de curvatura media. Se parte de un filtro de difusión isotrópica, pasando por un filtro coherente anisotrópico, para finalmente tener en cuenta el movimiento de curvatura media. Así las regiones con *speckle* son reducidas preservando la información de las estructuras de los objetos. La desventaja del modelo (NCD) es que un filtro Gaussiano no selectivo es necesario, lo cual puede eliminar pequeños detalles que son suavizados por la ventana. El método de difusión para la supresión de *speckle* es presentado por Xiao et al. [80]. El filtro es definido por la descomposición en líneas de una ventana rectangular en varias orientaciones. Sin embargo, la técnica de difusión no lineal trabaja con el operador gradiente lo cual no puede separar de forma precisa la señal y el ruido.

3.2.3 El filtro de Frost

Es un filtro adaptativo que incorpora la estadística local de la imagen en el proceso de filtrado asumiendo una distribución exponencial negativa del ruido *speckle*. El filtro se basa en un peso promedio de los valores en la ventana del filtro, con los pesos de cada pixel determinados por la estadística local para minimizar el error cuadrático medio de la señal estimada.

Los pesos del filtro están determinados por una función exponencial negativa de la desviación estándar calculada localmente para cada ventana del filtro, y que además decae con la distancia del centro de la ventana. El pixel del centro de la ventana tiene un mayor peso a medida que aumenta la varianza en la ventana del filtro. Por lo tanto, el filtro suaviza más en áreas homogéneas, estima una señal cercana al valor observado [79] en áreas heterogéneas.

3.2.4 Filtro de Lee

El filtro de Lee utiliza un enfoque de los mínimos cuadrados para estimar la intensidad de la señal en el pixel del centro de la ventana del filtro. La media local de la intensidad en la ventana y un factor de ganancia se calculan de la varianza local y la desviación estándar del ruido. El filtro supone una distribución Gaussiana para el ruido y calcula la desviación estándar del ruido para cada ventana del filtro.

Este filtro genera un valor de salida cercano a la media local en áreas uniformes y un valor cercano a la imagen original en regiones de alto contraste. La imagen se suaviza mucho más en áreas uniformes mientras preserva los bordes y otros detalles. El filtro de Lee no necesita parámetros de entrada [80, 81].

3.2.5 Filtro de Kuan

El filtro de Kuan (MAP) usa un enfoque de la probabilidad máxima para estimar los valores del centro de la ventana de la imagen. El filtro MAP asume que el *speckle* tiene una distribución exponencial y maximiza la función de probabilidad en el centro de la ventana.

Por otra parte, el filtro Kuan adaptativo usa el cálculo del error cuadrático medio mínimo para estimar el valor en el centro de la ventana de la imagen a partir de la estadística local. Este es similar al enfoque del filtro de Lee, pero hace simplificaciones en los cálculos. El filtro adaptativo asume la distribución del ruido como Gaussiana y no requiere de parámetros de usuario [82].

3.2.6 Filtrado usando Transformada Wavelet

Otro método de filtrado que permite la reducción de ruido son las técnicas basadas en multiresolución utilizando Wavelet. En estas técnicas, una imagen se descompone en múltiples escalas y se utilizan diversos métodos para reducir el ruido *speckle* en el dominio multiresolución. Suelen denominarse como las técnicas shrinkage.

3.2.6.1 Técnicas shrinkage

La mayoría de técnicas de umbralización [36, 37] se basan en la eliminación de ruido con un umbral suave. Estas son comúnmente conocidas como técnicas shrinkage. La señal se descompone en el dominio wavelet y los coeficientes obtenidos son umbralizados.

Los métodos de umbralización sufren de dos grandes inconvenientes. En primer lugar, no se ha podido encontrar la solución óptima para todo tipo de imágenes. En segundo lugar, se aconseja no utilizar el mismo modelo de ruido en diferentes resoluciones ya que el umbral seleccionado puede no coincidir con la distribución específica de los componentes de la señal y el ruido en todas las escalas.

Las dos funciones de umbralización a nivel de sub-bandas más comúnmente utilizadas se describen a continuación.

3.2.6.1.1 Umbral Duro

En esta alternativa de umbralización se mantiene la entrada si ésta es mayor que el umbral, de lo contrario se pone a cero. El procedimiento de umbralización elimina el ruido sólo de los coeficientes wavelet de las sub-bandas de detalle manteniendo los coeficientes de baja resolución sin modificaciones.

$$\widehat{cD}_j^i = \begin{cases} cD_j^i & |cD_j^i| > T \\ 0 & \text{otros} \end{cases} \quad (12)$$

donde cD_j^i representa la sub-banda, j la orientación (Horizontal, vertical y Diagonal), i es el nivel de descomposición. En la figura 15 se muestra la forma de la función dada en la ecuación 12.




Figura 15. Función de umbral duro aplicada a las sub-bandas de detalles en cada nivel de descomposición

3.2.6.1.2 Umbral Suave

En la función de umbralización suave (shrinkage) los coeficientes wavelet cuyos valores absolutos son inferiores a un umbral se sustituyen por cero, mientras que los otros son modificados por la función shrinkage.

$$\widehat{cD}_j^i = \begin{cases} (cD_j^i - \text{sgn}(cD_j^i)T)I & |cD_j^i| > T \\ 0 & \text{otros} \end{cases} \quad (13)$$

Una ilustración de esta función se presenta en la figura 16.




Figura 16. Función de umbralización suave aplicada a las sub-bandas de detalles en cada nivel de descomposición

3.6.1.2 Estimación de parámetros para la Umbralización

Inicialmente se estima la varianza del ruido σ^2 . En algunas situaciones es posible medir σ^2 teniendo en cuenta la información de la imagen con ruido. Para esta aplicación, se estima a partir de la sub-banda cD_D^1 usando un estimador de mediana [36].

$$\sigma^2 = \left[\frac{\text{mediana}[cD_D^1]}{0.6745} \right]^2 \quad (14)$$

Recordemos que el modelo de observación de la imagen está dado por:

$$IR = NxR \quad (15)$$

Al realizar la transformación, se obtener:

$$\log IR = \log N + \log R \quad \text{o} \quad Y = X + e \quad (16)$$

Al aplicar la transformada logarítmica, la imagen libre de ruido transformada y el ruido transformado son independientes el uno del otro. Por lo tanto

$$\sigma_Y^2 = \sigma_X^2 + \sigma^2 \quad (17)$$

donde σ_Y^2 corresponde a la varianza de la imagen corrupta por el ruido y σ_X^2 la varianza de la imagen libre de ruido. Dado que Y se modela con media cero, σ_Y^2 puede ser encontrada empíricamente por:

$$\widehat{\sigma_Y^2} = \frac{1}{n^2} \sum_{i,j=1}^n (cD_j^i)^2 \quad (18)$$

La variable $n \times n$ es referida al tamaño de la sub-banda en consideración. La relación de umbral está dada por la siguiente expresión:

$$\hat{T}(\hat{\sigma}_x) = \frac{\hat{\sigma}^2}{\hat{\sigma}_x} \quad (19)$$

donde σ_x es hallada de la ecuación:

$$\hat{\sigma}_x = \sqrt{\max(\hat{\sigma}_Y^2 - \hat{\sigma}^2, 0)} \quad (20)$$

En el caso que $\hat{\sigma}^2 \geq \hat{\sigma}_Y^2$, $\hat{\sigma}_x$ se toma como cero.

Además de los filtros previamente mencionados, se han diseñados muchos que permiten realizar la tarea de supresión de *speckle*, algunos con mejor comportamiento que otros en cuanto a preservar bordes y características de la imagen, pero todos con algún tipo de limitación. En el siguiente capítulo se describirán los métodos de filtrado utilizados en este proyecto para reducir el ruido *speckle*, en estructuras de bajo contraste, en imágenes de ultrasonido.

CAPITULO 4

ALGORITMOS DE DETECCIÓN Y FILTRADO PROPUESTOS PARA ESTRUCTURAS DE BAJO CONTRASTE EN IMÁGENES DE ULTRASONIDO

En este capítulo se analizan los métodos de detección y filtrado implementados y adoptados en este proyecto. Aquí se detallan cada uno de los métodos, describiendo sus características más importantes, así como todo el proceso matemático que los gobierna.

4.1 Creación de un Banco de Datos de Imágenes de Ultrasonido de Estructuras de Bajo Contraste

La primera tarea en el desarrollo del proyecto es obtener un banco de datos o la información que se usa para la validación y evaluación de los algoritmos. Aquí se da una breve descripción de cada uno de los tipos de imágenes de ultrasonido que fueron utilizadas en la tesis.

4.1.1 Generación de imágenes utilizando el programa FIELD II

Las imágenes fantasmas (*phantom*) generadas para este trabajo corresponden a estructuras circulares que simulan quistes y que, además, pueden presentar diferentes tamaños y contrastes. La imagen de salida final está dada en niveles de gris. Este programa permite generar fantasmas (*phantoms*) para validar programas que requieran de imágenes de ultrasonido. El programa FIELD II [83] permite el acceso de forma gratuita para investigaciones relacionadas en este campo a través del sitio web server.oersted.dtu.dk/personal/jaj/field/?examples/cyst_phantom/cyst_phantom.html.

Las simulaciones se llevaron a cabo con diferentes parámetros tales como frecuencia de muestreo, atenuación y números de líneas. El código para la generación del fantasma (*phantom*) incluye puntos de dispersión y estructuras circulares de diferentes tamaños y coeficientes de dispersión como se puede apreciar en la figura 17.

Las simulaciones fueron realizadas usando frecuencias de transductor de 3.5 MHz, 5 MHz y 7MHz las cuales son las más comunes para imágenes médicas de ultrasonido.




Figura 17. Fantasma (*Phantom*) usado para simulación (Imagen tomada del Proceeding of SPIE Vol. 6913, 69133P-3, 2008)

4.1.2 Generación de imágenes utilizando usando el algoritmo propuesto por Pizurica

Algunas imágenes sintéticas útiles para validación han sido tomadas de la Dr. Alexandra Pizurica [33]. Estas imágenes son usadas para evaluar los métodos de filtrado implementados realizando comparaciones con otros de la literatura. Las imágenes generadas con este algoritmo producen un aspecto de *speckle* muy similar al de imágenes reales, por lo que han sido usadas por muchos investigadores.

El algoritmo de generación de *speckle* es simulado a través de la magnitud de un campo aleatorio Gaussiano complejo al cual se le aplica un filtro pasa bajo. La cantidad de

speckle en la imagen depende del parámetro de desviación estándar que se introduzca y debe estar en un rango de 0.1 a 1. Con un valor bajo de varianza se visualiza la imagen como si estuviera libre de ruido, mientras que un valor alto representa una imagen con mucho *speckle*.

4.1.3 Imágenes de fantasmas (*Phantom*) Reales

Las imágenes *phantom* de ultrasonido real fueron tomadas con el dispositivo *Vevo 2100* de la empresa *Visualsonics*, el cual es un sistema de ultrasonido de alta resolución. Entre las características configurables de este equipo, para la adquisición de las imágenes, se encuentran la frecuencia de transmisión, ganancia de adquisición, profundidad y ancho de la imagen. En la tabla 2 se muestran las diferentes especificaciones de las imágenes que se utilizan para el procesamiento y validación de los algoritmos.

Tabla 2. Especificaciones de las imágenes reales.

Imágenes	Ganancia (dB)	Frecuencia de transmisión (MHz)	Ancho de la imagen (mm)	Profundidad de la imagen (mm)	Número de estructuras de bajo contraste
1	19	15	32	21	9
2	14	15	32	20	10
3	8	15	24	26	3
4	14	15	32	23	2
5	14	15	24	30	3
6	8	15	24	36	6
7	18	21	17	15	5
9	11	21	17	23	6
10	8	21	17	30	6
11	21	30	15	12	3
12	17	30	15	12	3

14	17	30	15	19	3
16	17	40	14	10	1
17	30	40	14	10	2
18	17	40	14	10	8
21	17	40	14	15	2
22	22	40	13	14	1

Las imágenes de ultrasonido ilustradas en la figura 18 fueron adquiridas usando combinaciones de las diferentes características o especificaciones dadas en la tabla 2. La variabilidad se ve reflejada en la cantidad y el tamaño del *speckle*. Hay que mencionar que todas las estructuras son circulares y tienen un tamaño de 2 mm, pero su tamaño relativo en la imagen varía con la profundidad con la que fue adquirida. Las imágenes fueron adquiridas a través del sitio web <http://www.brl.uiuc.edu/Downloads/> correspondiente al Laboratorio de Bioacústica de la Universidad de Illinois.




Figura 18. Imágenes de ultrasonido de fantasmas con frecuencia de transmisión a. 15 MHz, b. 21 MHz, c. 30 MHz y d. 40 MHz.

4.2 Algoritmos de detección

En busca de encontrar un criterio de decisión para detectar una estructura inmersa en *speckle*, en imágenes de ultrasonido modo B, se debe tener en cuenta las propiedades estadísticas de la imagen. El objetivo es analizar teórica y experimentalmente el desempeño de la regla de decisión en imágenes originales filtradas y sin filtrar a través de la tasa de verdaderos positivos y falsos positivos detectados en la imagen. La naturaleza del *speckle* es clasificada de acuerdo al número de dispersiones por celda de resolución. Dependiendo de esto podemos tener un “*Speckle* Formado Completamente” donde la amplitud de las retrodispersiones puede ser modelada como una función de Rayleigh.

En cada caso se considera que el sistema de ultrasonido es un proceso estocástico donde cada imagen es una realización de dicho proceso. Adicionalmente, se parte de la suposición que cada pixel de esta imagen es una variable aleatoria del proceso. Así, en una imagen cuyo tamaño es de 120x120 pixeles se tiene una cantidad de 14400 variables aleatorias con distribuciones de probabilidad específicas. Para el análisis de los algoritmos de detección, cada imagen es convertida en forma vectorial y, posteriormente, tratada como una señal unidimensional.

4.2.1 Análisis estadístico con distribución de Rayleigh

Una estructura en la imagen es un área dentro de la misma con un valor diferente de varianza con respecto al fondo. Cuando se presenta una estructura, la varianza es más alta que la del fondo de la imagen. También puede presentarse una estructura cuando ocurre el caso contrario, la varianza de la estructura es más baja que la del fondo. En la figura 19 se ilustran ejemplos de estos dos casos.




Figura 19. Estructuras con diferentes contrastes, a. 0.2652, b. 0.2457, c. 0.1796.

El índice de detectabilidad de la estructura es derivada de la estadística de primer y segundo orden del *speckle*. La distribución del *speckle* está definida por una función de Rayleigh.

De acuerdo a las investigaciones realizadas por Burckhardt [56], la estadística de primer orden es independiente del transductor. Por el contrario, cuando se calcula el segundo momento estadístico como son la covarianza y la función de correlación del *speckle*, estas dependen de la resolución y están directamente relacionadas con la apertura del transductor.

Tal como se mencionó anteriormente, la señal de ultrasonido recibida se modela como un campo aleatorio complejo; es decir, la suma de los ecos recibidos en un periodo específico puede ser descrita como la combinación de la parte real e imaginaria [56], $x = x_r + x_i$, cuya función de distribución puede ser expresada como:

$$p(x_r) = p(x_i) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x_i^2}{2\sigma^2}\right) \quad (21)$$

donde σ es la desviación estándar.

Además, la señal compleja x tiene una distribución conjunta entre la parte imaginaria y la real. La ecuación que describe este comportamiento se expresa como:

$$p(x_r, x_i) = \frac{1}{2\pi\sigma} \exp\left(-\frac{x_r^2 + x_i^2}{2\sigma^2}\right) \quad (22)$$

Esto simplemente es el producto de dos funciones de densidad Gaussianas independientes con media cero y varianza σ^2 . Esto puede ser reescrito como:

$$p(x) = \frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right), V \geq 0 \quad (23)$$

donde x es la magnitud de la señal compleja. De forma convencional, se tiene que:

$$\begin{cases} p(x) = \frac{x}{\psi} \exp\left(-\frac{x^2}{2\psi}\right) & , V \geq 0 \\ 0 & \text{para otros valores} \end{cases} \quad (24)$$

donde $\psi = \sigma^2$ corresponde a la amplitud de dispersión media cuadrática [15, 84].

Para el análisis de la estadística de x se requiere de los primeros momentos estadísticos de la distribución de Rayleigh. La media de la función de Rayleigh se expresa como:

$$\bar{x} = \sqrt{\frac{\pi\psi}{2}} \quad (25)$$

y la varianza:

$$\text{var}(x) = \left(\frac{4-\pi}{2}\right)\psi \quad (26)$$

La intensidad es proporcional a la raíz de la amplitud, por lo cual se puede obtener una distribución exponencial:

$$p(I) = \frac{1}{2\sigma^2} \exp\left(-\frac{I}{2\sigma^2}\right) \quad (27)$$

El desempeño en la detección puede ser cuantificada por la relación señal a ruido (SNR).

Aquí se calcula la relación de probabilidad cuando se tiene la hipótesis de lesión presente y lesión ausente usando la regla de Bayes explicada en la sección 3.1.3.1. El primer paso es utilizar la función de distribución de Rayleigh de la imagen de ultrasonido modo B. Asumiendo que cada punto de *speckle* es independiente del otro, la probabilidad de x dada la señal presente ψ_1 esta determinada por la siguiente expresión:

$$f(x_i/\psi_1) = \prod_{i=1}^M \frac{x_i}{\psi_1} \exp\left(-\frac{x_i^2}{2\psi_1}\right) \quad (28)$$

donde M es el número de píxeles analizados en la imagen. La probabilidad debido a la señal ausente está dada por:

$$f(x_i/\psi_2) = \prod_{i=1}^M \frac{x_i}{\psi_2} \exp\left(-\frac{x_i^2}{2\psi_2}\right) \quad (29)$$

La relación de probabilidad para la señal es entonces:

$$\gamma'' = \frac{f(x_i/\psi_1)}{f(x_i/\psi_2)} = \prod_{i=1}^M \frac{\psi_1}{\psi_2} \exp\left(-\frac{x_i^2}{2}\left(\frac{1}{\psi_1} - \frac{1}{\psi_2}\right)\right) \quad (30)$$

Aplicando el logaritmo a la relación de probabilidad nos resulta:

$$\gamma' = \log\left(\frac{\psi_1}{\psi_2}\right)^M \gamma'' \quad (31)$$

$$\gamma' = \sum_{i=1}^M x_i^2 \left(\frac{\psi_1 - \psi_2}{2\psi_1\psi_2}\right) \quad (32)$$

Los factores ψ_i ($i= 1,2$) son constantes y por lo tanto independientes del valor medido de la variable aleatoria x_i . La regla de decisión se reduce a

$$\begin{aligned} \gamma = \sum_{i=1}^M x_i^2 & \geq \text{Umbral} \rightarrow \gamma \in H_0 \\ 1 \leq i < M & < \text{Umbral} \rightarrow \gamma \in H_1 \end{aligned} \quad (33)$$

donde H_1 y H_0 representan la hipótesis de lesión presente y lesión ausente. La ecuación (33) indica que el criterio de decisión γ es proporcional a la intensidad promedio de la región estudiada.

La media del criterio de decisión está determinada por:

$$\bar{\gamma} = M\overline{x_i^2} = 2M\psi \quad (34)$$

y la varianza:

$$\sigma_\gamma^2 = 4M\psi \quad (35)$$

Sin embargo, para valores de M muy grandes la suma de los valores de las intensidades tiende hacia una distribución Gaussiana de acuerdo al teorema del Limite Central. En

aplicaciones de imágenes médicas de bajo contraste esta suposición se mantiene, tanto para áreas con lesión como para áreas de fondo. El desempeño de una regla de decisión óptima para diferenciar entre dos señales Gaussianas está dada por:

$$SNR_{opt} = \frac{\Delta\mu}{\sigma} \quad (36)$$

Donde $\Delta\mu = 2M(\psi_1 - \psi_2)$ es la diferencia entre las medias de las dos áreas (con y sin estructura), y $\sigma = 2M^{\frac{1}{2}}(\psi_1^2 + \psi_2^2)^{1/2}$ es la desviación estándar promedio. El factor de contraste, C_ψ está definido como

$$C_\psi = \left(\frac{\psi_1 - \psi_2}{(\psi_1^2 + \psi_2^2)^{1/2}} \right) \quad (37)$$

Smith [15] asume una estructura circular y un *speckle* elíptico. Esto nos permite especificar la SNR_{opt} .

$$SNR_{opt} = \left[\frac{\pi d^2 / 4}{\pi S_{cx} S_{cz}} \right]^{1/2} C_\psi \quad (38)$$

o

$$SNR_{opt} = \frac{d}{\sqrt{S_{cx} S_{cz}}} C_\psi \quad (39)$$

donde d es el diámetro de la estructura; la correlación del *speckle* S_c está dada por los parámetros S_{cx} y S_{cz} los cuales corresponden al tamaño del *speckle* en la imagen, en las respectivas direcciones horizontal y vertical; C_ψ es el factor de contraste. La detectabilidad para estructuras de bajo contraste está determinada por SNR_{opt} y, como lo especifica la ecuación, está influenciada por el diámetro d de la estructura, el tamaño del *speckle* y el contraste. De esto se puede concluir que las estructuras de alto contraste con respecto al fondo son más fáciles de detectar por el observador. Además, la detectabilidad incrementa cuando el *speckle* es imperceptible.

Los estudios realizados por Insana [21] muestran una variación en la relación señal a ruido óptima. Esto se escribe como:

$$SNR_{opt} = \frac{\sqrt{\pi}}{2} \frac{d}{\sqrt{S_{cx} S_{cz}}} C_\psi \quad (40)$$

4.2.2 Análisis estadístico con distribución Gaussiana no correlacionado

Es importante tener en cuenta otras distribuciones cuando se analizan imágenes de ultrasonido. Otra que es utilizada es la distribución Gaussiana la cual será evaluada con las mismas hipótesis estudiadas para la distribución de Rayleigh, en las que se supone que los puntos de *speckle* son independientes. Se asume que las observaciones x tiene una distribución Gaussiana con media cero y varianza σ . Se desea evaluar la hipótesis $H_0 \rightarrow \sigma_0$ cuando no se tiene estructura y $H_1 \rightarrow \sigma_1$ en presencia de estructura. Aquí la varianza de la distribución Gaussiana cambia con la presencia de estructura.

Usando la distribución Gaussiana $f(x) = \prod_{i=1}^M \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-x^2/2\sigma^2\right)$, la relación de probabilidad para un criterio de detección es:

$$\gamma_{Gauss}'' = \frac{f(x_i/\sigma_1)}{f(x_i/\sigma_2)} = \prod_{i=1}^M \frac{\frac{1}{\sigma_1\sqrt{2\pi}} \exp\left(-x^2/2\sigma_1^2\right)}{\frac{1}{\sigma_2\sqrt{2\pi}} \exp\left(-x^2/2\sigma_2^2\right)} \quad (41)$$

Aplicando el logaritmo y usando sus propiedades se puede escribir la relación de probabilidad como:

$$\gamma'_{Gauss} = \ln\left(\frac{1}{\sigma_1\sqrt{2\pi}}\right)^M + \sum_{i=1}^M -x^2/2\sigma_1^2 + \ln\left(\frac{1}{\sigma_2\sqrt{2\pi}}\right)^M + \sum_{i=1}^M -x^2/2\sigma_2^2 \quad (42)$$

Si se ignoran todos los términos que no dependen de x , la expresión final del criterio de decisión queda como:

$$\gamma_{Gauss} = \sum_{i=1}^M (\sigma_2^{-2} - \sigma_1^{-2}) x^2 \quad \begin{array}{l} \geq \text{Umbral} \rightarrow \gamma_{Gauss} \in H_0 \\ < \text{Umbral} \rightarrow \gamma_{Gauss} \in H_1 \end{array} \quad (43)$$

donde H_1 y H_0 representan la hipótesis de la estructura presente y ausente respectivamente, x representa los pixeles de la imagen de ultrasonido ordenados en forma vectorial, σ_1 y σ_2 son la desviaciones estándar de la estructura presente y ausente.

4.2.3 Análisis estadístico correlacionado

Se debe observar que las variables aleatorias (los pixeles) que forman la imagen de ultrasonido modo B están generalmente correlacionadas. La correlación entre los pixeles puede ser calculada a través del segundo momento estadístico. En la teoría de decisión estadística, calcular la correlación entre los pixeles o variables aleatorias de una imagen de ultrasonido con distribución Rayleigh podría ser posible si existiera una descripción matemática de la función de distribución conjunta para múltiples variables aleatorias que considerara la correlación entre dichas variables. Sin embargo, este modelo matemático en la literatura aun no ha sido propuesto, por lo que aun se continua con el análisis basado en la suposición de independencia de las variables que forman la imagen de ultrasonido como fue propuesto por Smith et al. [15].

4.2.3.1 Distribución Gaussiana Correlacionada

Para este caso se asume que la función de la estructura es modelada como un proceso aleatorio normal multivariable de media cero (MVN por sus siglas en inglés), así que la señal de eco es también un proceso aleatorio Gaussiano de media cero con distribuciones de probabilidad para la señal presente y ausente como se observa en la siguiente expresión:

$$\begin{aligned} f(x/H_1) &= \text{MVN}(0, K_1) \\ f(x/H_0) &= \text{MVN}(0, K_0) \end{aligned} \quad (44)$$

Aquí tenemos las matrices de covarianza $K_1 = K_{g/H_1} = \langle xx^t / H_1 \rangle$ para la señal presente y $K_0 = K_{g/H_0} = \langle xx^t / H_0 \rangle$ para la señal ausente. Aplicando Bayes para el caso Gaussiano, binario, de dos clases se obtiene:

$$\gamma' = \frac{f\left(\frac{x}{H_1}\right)}{f\left(\frac{x}{H_0}\right)} = \frac{\frac{1}{(2\pi)^{M/2} |K_1|^{1/2}} \exp^{-(1/2)((x-m_1)^T K_1^{-1} (x-m_1))}}{\frac{1}{(2\pi)^{M/2} |K_0|^{1/2}} \exp^{-(1/2)((x-m_0)^T K_0^{-1} (x-m_0))}} \quad (45)$$

La expresión puede ser rescrita como:

$$\gamma' = \frac{|K_1|^{1/2}}{|K_0|^{1/2}} \exp\left(-\frac{1}{2}(x-m_1)^T K_1^{-1}(x-m_1) + \frac{1}{2}(x-m_0)^T K_0^{-1}(x-m_0)\right) \quad (46)$$

donde x representa los pixeles de la imagen de ultrasonido ordenados en forma vectorial; K_1 y K_0 son las matrices de covarianza de la señal presente y la señal ausente respectivamente. Estas matrices contienen la información de correlación entre las variables aleatorias que forman la imagen de ultrasonido. Aplicando la relación de probabilidad logarítmica a la ecuación (46) se obtiene:

$$\gamma = \log\left(\frac{|K_1|^{1/2}}{|K_0|^{1/2}}\right) - \frac{1}{2}(x-m_1)^T K_1^{-1}(x-m_1) + \frac{1}{2}(x-m_0)^T K_0^{-1}(x-m_0) \quad (47)$$

donde $\log\left(\frac{|K_1|^{1/2}}{|K_0|^{1/2}}\right)$ es el mismo para todos los casos y no depende de la observación.

Por consiguiente, la regla de decisión γ , para el caso Gaussiano se puede expresar como:

$$\gamma = x^T(K_0^{-1} - K_1^{-1})x \quad \begin{array}{l} \geq \text{Umbral} \rightarrow \gamma \in H_0 \\ < \text{Umbral} \rightarrow \gamma \in H_1 \end{array} \quad (48)$$

Como en los casos previos la regla de decisión γ depende de un umbral que determina la presencia H_1 o ausencia H_0 de la estructura, x representa los pixeles de la imagen de ultrasonido ordenados en forma vectorial.

4.3 Algoritmos de Filtrado

Existen diferentes tipos de algoritmos que nos permiten filtrar la imagen de ultrasonido para suprimir el *speckle* y de esta manera mejorarla para el proceso de detección que se lleva a cabo posteriormente. Aunque el *speckle* no es un ruido propiamente dicho, sino una característica propia de todo el sistema de ultrasonido, normalmente se acostumbra a tratarlo como ruido para desarrollar algoritmos que permitan reducir su presencia en la imagen. En esta sección se da una descripción detallada de los dos métodos de filtrado

implementados en el proyecto. El primero de ellos utiliza un estimador Bayesiano sobre los coeficientes de la imagen luego de que ha sido descompuesta usando wavelet. El segundo método emplea la transformada de Hermite y tratar de estimar los pixeles que corresponden al ruido para luego suprimirlos. En ambos casos es necesario llevar a cabo una descomposición multiresolución.

En este trabajo se implementan dos algoritmos multiresolución para reducir el *speckle* en imágenes de ultrasonido. El primero utiliza la teoría bayesiana aplicada en el dominio de la transformada Wavelet [27] y el segundo utiliza una máscara de clasificación de pixeles en el dominio de la transformada Hermite [85, 86].

El esquema de la figura 20 muestra el proceso que se lleva a cabo para la reducción de ruido *speckle* usando las técnicas de multiresolución.




Figura 20. Diagrama de bloques del filtrado de imágenes de ultrasonido usando técnicas multiresolución.

4.3.1 Método Bayesiano usando la Transformada Wavelet

Se ha mencionado anteriormente que la calidad de la imagen de ultrasonido es generalmente limitada por los patrones de *speckle*. Estos, al degradar significativamente la calidad de imagen, aumentan las dificultades para hacer un buen diagnóstico. Aquí se implementa un algoritmo Bayesiano que permite hacer un mejoramiento de la imagen de ultrasonido. La descripción se lleva a cabo en tres etapas: 1) Modelamiento del *speckle*, 2) Descripción de la transformada Wavelet y 3) Desarrollo del algoritmo Bayesiano.

4.3.1.1 Parámetros del *speckle* en la imagen de ultrasonido

El *speckle* se presenta generalmente en los análisis de todo sistema de ultrasonido o cualquier otro que utilice fuentes de radiación coherentes para generar imágenes. El modelamiento que se le ha dado a este patrón durante mucho tiempo es considerarlo como un tipo de ruido multiplicativo. Existen muchos trabajos [31, 33] que modelan las imágenes con *speckle* de acuerdo a la siguiente formulación matemática:

$$g(x, y) = y(x, y) \cdot n(x, y) \quad (49)$$

donde y es la señal libre de ruido; n es la contribución de *speckle* en la imagen y g corresponde a la imagen con *speckle*; (i, j) son las coordenadas espaciales en la imagen. Las componentes de ruido aditivo son insignificantes con respecto al *speckle* en la imagen por lo que no son consideradas en la ecuación (49). Las componentes multiplicativas son transformadas en aditivas al aplicar una transformación logarítmica a toda la imagen. La expresión resultante se muestra a continuación:

$$\log(g(x, y)) = \log(y(x, y)) + \log(n(x, y)) \quad (50)$$

Así, el modelo descrito en la ecuación (49) se escribe como:

$$y(x, y) = f(x, y) + N(x, y) \quad (51)$$

Por consiguiente, los métodos de supresión de ruido aditivo pueden ser aplicados a la imagen transformada para reducir el *speckle*. Una vez realizado el proceso de filtrado, aplicamos una transformación exponencial para retornar al espacio de la imagen original.

4.3.1.2 Descripción de la Transformada Wavelet Discreta para Representación Multiresolución

Una wavelet es una forma de onda de duración finita o limitada con un valor medio cero. Así como el análisis de Fourier básicamente consiste en descomponer señales en ondas sinusoidales de diferentes frecuencias, el análisis wavelet consiste en descomponer la señal en versiones escaladas y trasladadas de la wavelet original. Por tanto, el procedimiento de análisis wavelet se basa en la adopción de una función prototipo llamada wavelet de análisis o wavelet madre [87].

Esta descomposición produce una familia de descomposiciones jerárquicamente organizadas, lo cual significa que una señal puede ser descompuesta por un conjunto de coeficientes conocidos por aproximaciones y detalles. Por definición la transformada wavelet diádica en una dimensión para una función f se puede calcular utilizando la siguiente expresión:

$$C(a, b) = \int_{-\infty}^{\infty} f(x) \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) dx \quad a \in R^+ \quad y \quad b \in R^+ \quad (52)$$

donde $C(a, b)$ son los coeficientes obtenidos de la transformada, a y b se asocian con la escala y la posición de la señal base o wavelet madre ψ . Este concepto de descomposición

usando wavelet se puede extender al caso de dos dimensiones, que es el tipo de señales que nos interesan (las imágenes). Con esta idea, nuestra función base se define como:

$$\frac{1}{\sqrt{a_1 a_2}} \psi \left(\frac{x_1 - b_1}{a_1}, \frac{x_2 - b_2}{a_2} \right) \quad (53)$$

con $x = (x_1, x_2) \in R^2$, $a_1 > 0$, $a_2 > 0$ b_1 y $b_2 \in R$

Dado que las imágenes son representaciones discretas es conveniente usar definiciones discretas de esta transformada:

$$C(a, b) = C(j, k) = \sum_{x \in Z} \sum_{y \in Z} f(x, y) g_{j, k}(x, y) \quad (54)$$

con $a = 2^j$, $b = k2^j$, $j \in N$, $k \in Z$

donde Z es el conjunto de los número enteros y N el de los naturales.

Dado que el conjunto de señales wavelet usadas para la descomposición representan un conjunto de funciones ortogonales entre sí, se puede decir que el proceso es reversible. Esto significa que la señal original puede ser recobrada a partir de los coeficientes obtenidos. El proceso inverso en el dominio discreto para dos dimensiones está dado por:

$$f(x, y) = \sum_{j \in Z} \sum_{k \in Z} C(j, k) \psi_{j, k}(x, y) \quad (55)$$

donde ψ es la función wavelet usada para reconstruir la imagen.

Una forma eficiente de implementar este esquema fue desarrollado por Mallat [88] mediante el uso de un banco de filtros. De la teoría del procesamiento digital de imágenes se sabe que el filtrado pasa-bajo suaviza la imagen mientras que el pasa-alto resalta los

bordes. En el primer caso la imagen sigue siendo visible mientras que en el segundo ya no lo es. Debido a esto en la teoría se habla de una descomposición de la imagen de entrada en dos componentes: *aproximación de baja resolución* y *detalle de la señal* [89]. Este conjunto de señales obtenidas se conoce como sub-bandas de la transformada, las cuales se pueden seguir descomponiendo bajo el mismo principio o criterio, lo que finalmente nos da un cierto número de bandas de frecuencia.

Como se ha dicho, la representación multiresolución llevada a cabo por la transformada wavelet discreta en dos dimensiones fragmenta el espectro de frecuencia de una imagen I en una imagen sub-banda pasa bajo cA^j y un conjunto de imágenes sub-bandas pasa bandas con orientaciones horizontal cDH^j , vertical cDV^j , y diagonal cDD^j , con $j = 1, \dots, L$, donde L denota el número de niveles usados en la representación. De forma general, la representación multiresolución se implementan por una cascada de filtros de análisis/síntesis (A/S). Esta transformada usa dos tipos de funciones base: $h(x)$ para la descomposición multiresolución (análisis) y $g(x)$ para la reconstrucción (síntesis) de la imagen original a partir de sus coeficientes en el dominio de wavelet.

La figura 21 muestra la implementación de una representación multiresolución de un nivel ($L=1$) de la transformada wavelet diádica discreta. Como se puede observar la implementación en 2-D usa bancos de filtros de análisis pasa-bajos $h_1(x)$ y pasa-altos $h_2(x)$. La reconstrucción es el proceso inverso y para ella se usan filtros de síntesis unidimensionales $g_1(x)$ y $g_2(x)$.




Figura 21. Implementación de la Transformada wavelet Discreta en 2-D.

Todo este proceso tiene una representación matemática. Sea $A_N(x,y)$ una imagen en dos dimensiones, h_1 y h_2 los filtros de análisis usados para calcular la transformada wavelet discreta en 2-D, en el cual h_1 y h_2 representan los coeficientes del filtro pasa-bajos y pasa-altos, respectivamente. Entonces la transformada wavelet de nivel j :

$$\{cA_{N+1}(x, y)^j, cDH(x, y)^j, cDV(x, y)^j, cDD(x, y)^j\}^{j=1} \quad (56)$$

de $A_N(x,y)$ puede ser obtenida como:

$$cA_{N+1}(x, y)^j = \sum_{m,n \in \mathbb{Z}} H_1(m)H_1(n)A_N(2x-m, 2y-n) \quad (57)$$

$$cDH(x, y)^j = \sum_{m,n \in \mathbb{Z}} H_1(m)H_2(n)A_N(2x-m, 2y-n) \quad (58)$$

$$cDV(x, y)^j = \sum_{m,n \in \mathbb{Z}} H_2(m)H_1(n)A_N(2x-m, 2y-n) \quad (59)$$

$$cDD(x, y)^j = \sum_{m,n \in \mathbb{Z}} H_2(m)H_2(n)A_N(2x-m, 2y-n) \quad (67)$$

donde (x, y) , m y n son las coordenadas en el dominio espacial.

Si se quiere seguir con la descomposición, solo hay que tomar la sub-banda de baja resolución cA^j y repetir el proceso. La mayor ventaja de usar la transformada wavelet es que puede manejar diferentes resoluciones de imágenes y permite la descomposición en diferentes clases de coeficientes mientras se preserva la información de la imagen. En imágenes médicas, la utilidad de esta transformada tiene mayor incidencia en el mejoramiento de zonas de bajo contraste y en la detección de componentes de alta frecuencia.

De la misma forma, la transformada inversa puede ser escrita a partir de sus coeficientes

$cD_{H,V,D}^j(x, y)$ como:

$$A_{N-1}(x, y) = 4 * [\sum_{m,n \in \mathbb{Z}} g_1(m)g_1(n)A_N(\frac{1}{2}(x-m), \frac{1}{2}(y-n)) + \sum_{m,n \in \mathbb{Z}} g_1(m)g_2(n) cD_H^j(\frac{1}{2}(x-m), \frac{1}{2}(y-n)) + \sum_{m,n \in \mathbb{Z}} g_2(m)g_1(n) cD_V^j(\frac{1}{2}(x-m), \frac{1}{2}(y-n)) + \sum_{m,n \in \mathbb{Z}} g_2(m)g_2(n) cD_D^j(\frac{1}{2}(x-m), \frac{1}{2}(y-n))] \quad (60)$$

En la literatura existe un gran número de funciones wavelet que han sido propuestas, entre ellas las más conocidas son “haar”, “daubechies”, “symlet”, “coiflet”, “meyer”, “biortogonal”, “sombbrero mexicano”, entre otras. La selección de una wavelet para un determinado trabajo depende mucho de la aplicación. En este trabajo se utilizaron las familias wavelet mencionadas previamente.

4.3.1.3 Desarrollo del Algoritmo Bayesiano

El algoritmo implementado en este proyecto fue propuesto por Gupta et al. [27]. Aquí se propone modelar el *speckle* como una función de distribución de Rayleigh para el caso de una imagen que contiene un *speckle* formado completamente. Por otra parte, la señal libre de *speckle* se modela como una distribución Gaussiana. Por lo tanto, la función de densidad (pdf) de la distribución de Rayleigh que caracteriza el *speckle* puede ser definida por:

$$p(N) = \frac{N}{\alpha} \exp\left(-\frac{N^2}{2\alpha}\right) \quad n \geq 0 \quad (61)$$

Asumiendo igualmente probables los valores negativos y positivos de los coeficientes de la Wavelet, la pdf del *speckle* viene dada por:

$$p(n) = \frac{n}{2\alpha^2} \exp\left(-\frac{n}{2\alpha^2}\right) U(n) - \frac{n}{2\alpha^2} \exp\left(-\frac{n}{2\alpha^2}\right) U(-n) \quad (62)$$

donde $U(n)$ es igual a 1 para $n \geq 0$ y cero para otros valores. El valor de $|n| = N$.

Mihck et al. [90] demostró que el histograma de los coeficientes puede ser aproximado por un distribución Gaussiana de media cero. Esto puede ser representado matemáticamente como:

$$p_f(f) = \frac{1}{\sigma_f \sqrt{2\pi}} \exp\left(-\frac{f^2}{2\sigma_f^2}\right) \quad -\infty < f < \infty \quad (63)$$

Aquí se debe realizar una transformación logarítmica de los datos. Por la propiedad de linealidad de la transformada wavelet, esto se puede expresar como:

$$C^j(y_{x,y}) = C^j(f_{x,y} + N_{x,y}) \quad (64)$$

Esta expresión puede ser reescrita así:

$$C^j(y_{x,y}) = C^j(f_{x,y}) + C^j(N_{x,y}) \quad (65)$$

donde C es el operador de la transformada Wavelet y j es el parámetro de escala. Para el desarrollo matemático, se va reescribir los parámetros como p_t , f_t y N_t que corresponden a la transformación Wavelet para cada parámetro:

$$y_t = f_t + N_t \quad (66)$$

Despejando N , para hallar la probabilidad del *speckle*, nos resulta:

$$N_t = y_t - f_t \quad (67)$$

La probabilidad condicional para el parámetro desconocido f , en el caso del ruido, usando la distribución Rayleigh, es especificada por:

$$p\left(\frac{y_t}{f_t}\right) = p_N(y_t - f_t) \quad (68)$$

Reemplazando en la ecuación (61), la expresión resultante es:

$$p\left(\frac{y_t}{f_t}\right) = \frac{(y_t - f_t)}{\alpha^2} \exp\left(-\frac{(y_t - f_t)^2}{2\alpha^2}\right) \quad (69)$$

La meta es encontrar la estimación de f que corresponde a la imagen libre de ruido de un conjunto de observaciones con *speckle* usando un estimador de máximo a posteriori (MAP). Valiéndose de la regla de Bayes se obtiene:

$$p\left(\frac{f_t}{y_t}\right) = \frac{p\left(\frac{y_t}{f_t}\right)p_f(f_t)}{p_T} \quad (70)$$

donde la probabilidad total p_T es la misma en toda la imagen por lo que la expresión puede ser escrita como:

$$p\left(\frac{f_t}{y_t}\right) = p\left(\frac{y_t}{f_t}\right) p_f(f_t) \quad (71)$$

En el caso del estimador MAP, el problema consiste en maximizar la función de densidad (pdf).

$$\hat{f}(y_t) = \max\left(p\left(\frac{f_t}{y_t}\right)\right) = \max\left(\left(\frac{y_t}{f_t}\right) p_f(f_t)\right) \quad (72)$$

$$\hat{f}(y_t) = \max\left(p_N(y_t - f_t) p_f(f_t)\right) \quad (73)$$

Como se observa, la estimación de \hat{f} es escrita en términos de la probabilidad del ruido p_N y de los coeficientes de la señal. Posteriormente, se aplica el logaritmo a la función de estimación:

$$\log(\hat{f}(y_t)) = \max\left(\log\left(p_N(y_t - f_t) p_f(f_t)\right)\right) \quad (74)$$

$$\hat{f}'(y_t) = \max\left(\log(p_N(y_t - f_t)) + \log\left(p_f(f_t)\right)\right) \quad (75)$$

Definiendo que $r(f(y_t)) = \log\left(p_f(f_t)\right)$ tenemos:

$$\hat{f}'(y_t) = \max\left(\log\left(\frac{(y_t - f_t)}{\alpha^2} \exp\left(-\frac{(y_t - f_t)^2}{2\alpha^2}\right)\right) + r(f)\right) \quad (76)$$

Por las propiedades del logaritmo, esta ecuación puede ser escrita como:

$$\hat{f}'(y_t) = \max\left(\log\left(\frac{(y_t - f_t)}{\alpha^2}\right) - \frac{(y_t - f_t)^2}{2\alpha^2} + r(f)\right) \quad (77)$$

Para encontrar los valores estimado de f_t derivamos la función $\hat{f}'(y_t)$ con respecto a x :

$$0 = -\frac{1}{(y_t - f_t)} + \frac{(y_t - f_t)}{\alpha^2} + r'(f) \quad (78)$$

La función $r(f) = \log\left(\frac{1}{\sqrt{2\pi}\sigma_f}\right) - \frac{f^2}{2\sigma_f^2}$ debe ser derivada para resolver la ecuación (78). La derivada de $r(f)$ se muestra en la ecuación (79).

$$r'(f) = -\frac{f}{\sigma_f^2} \quad (79)$$

Por lo que reemplazando en la ecuación (78)

$$0 = -\frac{1}{(y_t - f_t)} + \frac{(y_t - f_t)}{\alpha^2} + -\frac{f}{\sigma_f^2} \quad (80)$$

Resolviendo la ecuación (80) nos resulta:

$$(\sigma_f^2 + \alpha^2)f^2 + (-\alpha^2 y + 2\sigma_f^2 y)f + (\sigma_f^2 y^2 - \alpha^2 \sigma_f^2) = 0 \quad (81)$$

Despejando f de la ecuación (81) se obtiene:

$$\hat{f}(y_t) = \text{sign}(y_t) \left(\max \left(0, \frac{(2|y|2\sigma_f^2 + \alpha^2|y| - \sqrt{\alpha^4 y^2 + 4\alpha^2 \sigma_f^2 + 4\alpha^2 \sigma_f^4})}{2(\sigma_f^2 + \alpha^2)} \right) \right) \quad (82)$$

La estimación $\hat{f}(y_t)$ se hace para cada coeficiente de la transformada Wavelet.

4.3.1.4 Cálculo para estimar $\hat{f}(y_t)$

Posteriormente, se estima la varianza del ruido σ^2 y el parámetro α a través del primer y segundo momento de la ecuación (62), donde la media y la varianza de el ruido es cero y $2\alpha^2$, respectivamente. Esto implica que:

$$\alpha = \frac{\sigma}{\sqrt{2}} \quad (83)$$

Teniendo en cuenta los efectos de la correlación del *speckle* en la descomposición wavelet, la varianza del ruido σ^2 es estimada de la primera y segunda sub-banda de detalle diagonal (cD_D^1 y cD_D^2) [91] usando la formula:

$$\sigma^2 = \left[\frac{\text{mediana}|cD_j^i|}{0.6745} \right]^2 \quad cD_j^i \in \{cD_D^1 \text{ y } cD_D^2\} \quad (84)$$

A continuación, para cada coeficiente wavelet de las sub-bandas de detalle ($c \in cD_H^i, cD_V^i, cD_D^i, i = 1, 2, \dots, I$) se calcula la varianza de la señal $\hat{\sigma}_f = \sqrt{\max(\hat{\sigma}_y^2 - \hat{\sigma}^2, 0)}$ y la varianza del ruido σ_y^2 . La variable σ_y^2 para el proyecto se halla de los coeficientes de la wavelet con una ventana (3x3) usando:

$$\widehat{\sigma_Y^2} = \frac{1}{a^2} \sum_{i,j \in A_k} (cD_j^i)^2 \quad (85)$$

donde A_k es la ventana de tamaño $a \times a$ (que para este caso es de 3×3) centrada en la posición k .

4.3.1.5 Técnica de Mejoramiento Propuesta – Ganancia Adaptiva Local Exponencial

GALE

Uno de las principales ventajas de usar mejoramiento multiescala es que el filtro diseñado puede ser enfocado a mejorar de forma separada cada información de detalle teniendo en cuenta la necesidad de cada aplicación. Además, los algoritmos de eliminación de *speckle* pueden ser incorporados en la representación multiresolución. Un problema del mejoramiento de imágenes en algunas aplicaciones es la habilidad del algoritmo o método desarrollado de enfatizar en los bordes mientras se reduce el ruido.

En este trabajo desarrollamos un método de mejoramiento en el que proponemos una simple función de transformación que emplea una ganancia adaptiva exponencial, la cual depende del contraste local medido en la vecindad de un pixel. Esta función la aplicamos en todas las sub-bandas de detalles para todos los niveles de aproximación. Por tanto, cada pixel en la sub-banda i , es multiplicado por una ganancia exponencial:

$$\widehat{cD}_{H,V,D}^i(x, y) = \left[(k \exp^{(1-c(x,y)/c_{max})}) (cD_{H,V,D}^i(x, y)) \right]_{H,V,D}^i \quad (86)$$

donde $c(x,y)$ es el contraste local calculado en la vecindad del pixel $cD_{H,V,D}^i(x, y)$; C_{max} es el contraste máximo calculado sobre cada sub-banda de detalle al nivel i de descomposición y k es una constante. Por simplicidad, en este trabajo $k = 1$. Mirando la ecuación (86), es posible notar que la expresión $k \exp[1 - c(x,y)/c_{max}]_{H,V,D}^i$ es un parámetro de ganancia que se incrementa exponencialmente a medida que el contraste de un pixel dado disminuye. Este parámetro puede ser también controlado por la constante k . Para medir el contraste local en las vecindades de cada pixel, aquí

adoptamos un simple y efectivo método basado en la diferencia de intensidades máximas y mínimas en la ventana W que rodea el pixel en evaluación. Este medida de contraste fue definida en [36] como:

$$c(x, y) = \max(W(x, y)) - \min(W(x, y)) \quad (87)$$

donde $W(x, y)$ representa la vecindad cuadrada de un pixel en las tres imágenes de detalles después de realizarse la estimación Bayesiana, y la cual está centrada en el pixel $cD_{H,V,D}(x, y)$ al nivel de descomposición i .

4.3.2 Transformada Hermite para Filtrado en imágenes de Ultrasonido

El siguiente filtro analizado se basa en una descomposición multiresolución utilizando la transformada de Hermite. Análogamente, la descripción de este proceso de filtrado se hace en dos etapas: 1) Definición de la transformada Hermite en forma general y 2) Parámetros estadísticos considerados para reducir el *speckle* en la imagen de ultrasonido.

4.3.2.1 Definición de la Transformada de Hermite

La transformada de Hermite es un caso especial de la transformada polinomial, que puede ser usada para el análisis multiresolución en imágenes. La transformada polinomial permite obtener una descomposición localizada de la imagen mediante el uso de una función ventana. Se emplean varios tamaños de ventana para obtener el análisis multiresolución. Los coeficientes polinomiales $L_{m,n-m}(p, q)$ se calculan a través de la convolución de la imagen original $L(x, y)$ y el filtro. El filtro de análisis va estar determinado por:

$$D_{m,n-m}(x, y) = G_{m,n-m}(-x, -y) V^2(-x, -y) \quad (88)$$

donde $V(x, y)$ es la función ventana; $G(x, y)$ son las funciones polinomios bases, las cuales están determinadas totalmente por la función ventana de tal forma que deben ser ortonormales a $V^2(x, y)$. Por lo tanto, la imagen original convolucionada con el filtro se denota por:

$$L_{m,n-m}(p, q) = L(x, y) * D_{m,n-m}(x, y) \quad (89)$$

Para el proceso de reconstrucción de la imagen original a través de los coeficientes se calcula la transformada inversa. Este proceso se realiza a través de la interpolación de los coeficientes polinomiales $L_{m,n-m}(p, q)$ con la funciones patrón. Esta función patrón se computa como:

$$P_{m,n-m}(x - p, y - q) = \frac{G_{m,n-m}(x,y)V(x,y)}{W(x,y)} \quad (90)$$

La función de peso es calculada a través de:

$$W(x, y) = \sum_{(p,q) \in S} V(x - p, y - q) \quad (91)$$

donde $V(x, y)$ es la función ventana, que en el caso de la transformada Hermite corresponde a una función Gaussiana. El conjunto de polinomios ortogonales son los polinomios de Hermite.

El proceso de filtrado usando la Transformada de Hermite [85, 86, 92] para este caso es similar al usado con la transformada Wavelet. La idea es cambiar de espacio de representación, aplicar el filtrado y retornar nuevamente al espacio de la imagen original.

4.3.2.2 Umbral de clasificación para cada pixel usando la Transformada de Hermite

El algoritmo de supresión de ruido emplea la energía de los coeficientes polinomiales para detectar las características significativas en la imagen. La imagen de energía corresponde a los coeficientes de primer orden de la transformada de Hermite (L_{10}^2, L_{01}^2). Estos indican pixeles significativos y la localización de los bordes en la imagen. La expresión para hallar la imagen de energía está determinada por:

$$e = L_{10}^2 + L_{01}^2 \quad (92)$$

A partir de los coeficientes L_{10}^2 y L_{01}^2 vamos a determinar una máscara de energía para localizar las partes importantes y reducir el *speckle* en la imagen. La máscara de energía se calcula fijando un umbral D para la imagen de energía e y permite separar los coeficientes que corresponden a detalles importantes de la imagen. El umbral para este proceso puede ser encontrado por:

$$D(x, y) = \frac{2\vartheta \ln\left(\frac{1}{P_R}\right) L_{00}^2}{AN} \quad (93)$$

donde $\vartheta = |R_L(x, y) * D_{10}(x, y) * D_{01}(x, y)|_{x=y=0}$, R_L es la función de autocorrelación de L ; P_R es la probabilidad de ruido que se desea en la imagen final; L_{00}^2 es el coeficiente de orden cero; A es la $(SNR_{1LoOK})^2 \approx (1.9131)^2$ y N es el número de looks de la imagen L [86].

CAPITULO 5

RESULTADOS

En este trabajo, se propuso un método de detección de estructuras de bajo contraste en imágenes de ultrasonido. Debido a que el *speckle* dificulta el análisis de las imágenes de ultrasonido, se evaluó el algoritmo de detección utilizando las técnicas de filtrado utilizando técnicas bayesianas, bayesiano de ganancia adaptiva local exponencial - GALE y la transformada Hermite. En este capítulo se analizan los resultados obtenidos para todos los algoritmos implementados. Los resultados del algoritmo de detección se presentarán tanto para las imágenes filtradas y mejoradas, como para las imágenes sin procesar. La secuencia que se llevará a cabo en el reporte de los resultados se expone en la figura 22.

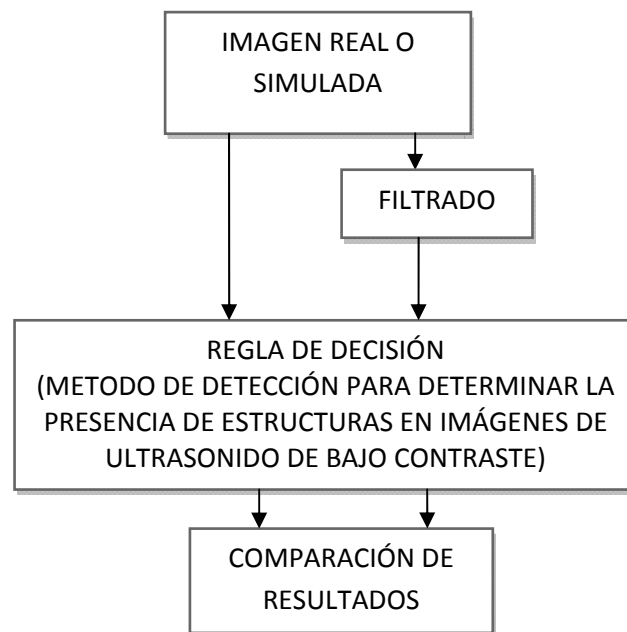


Figura 22. Secuencia para el análisis de resultados.

Los resultados de los métodos implementados son analizados usando imágenes de ultrasonido reales y simuladas que contienen estructuras de bajo contraste. Cabe recordar que estas estructuras tratan de simular lesiones del cuerpo humano como pueden ser quistes y masas tumorales. Las imágenes simuladas con el programa FIELD II son muy

conocidas y utilizadas por los investigadores para validar los sistemas de detección [83]. Para evaluar el comportamiento de detección de las imágenes filtradas y sin filtrar se seleccionaron un conjunto de imágenes cuyas estructuras varían en tamaño y contraste. Sobre ellas se aplicaron cada uno de los métodos descritos anteriormente. En total se tienen 148 imágenes reales y 100 imágenes simuladas. En cada conjunto de imágenes de prueba, la mitad tiene estructura y la otra mitad no contiene.

La figura 23a ilustra una imagen de un *phantom* simulado con el programa *FIELD II*, el cual fue generado con una frecuencia del transductor de 3.5 MHz y frecuencia de muestreo de 100 MHz. Esta imagen tiene un tamaño de 120x120 píxeles en niveles de grises y el tamaño de la estructura es de 3 mm. En la figura 23b se tiene una imagen real que contiene una estructura circular de 2mm generada con una frecuencia del transductor de 15MHz y con un tamaño de 120x120 píxeles en niveles de gris. Estas imágenes reales fueron obtenidas con un escáner de ultrasonido *Vevo 2100* distribuido por *Visualsonics*.




Figura 23. Imagen de ultrasonido con estructura a) Simulada [83] b) Real (Imagen tomada de <http://www.brl.uiuc.edu>)

Teniendo el conjunto de imágenes a procesar, el siguiente paso es analizar el comportamiento de los algoritmos desarrollados. En el caso de los filtros de reducción de *speckle* se hacen comparaciones con otros métodos conocidos en la literatura y que fueron expuestos de forma general en el capítulo 3. Con respecto a los métodos de detección, se evalúa el comportamiento para las imágenes usando las imágenes originales y filtradas previamente.

5.1 Filtrado

Para evaluar el desempeño de los métodos de filtrados adoptados en este proyecto, se llevan a cabo comparaciones visuales y cuantitativas con los resultados arrojados por los otros métodos de la literatura. Los filtros usados para comparación son el filtro de Wiener [30, 81], el filtro de Lee [80], el métodos de umbralización suave [36] basados en wavelet y la técnica desarrollada por Pizurica et al., [33].

5.1.1 Resultados usando el algoritmo de filtrado Bayesiano basado en wavelet

En esta sección se analizan los resultados visuales cuando se utiliza el filtro de clasificación Bayesiana aplicada en el dominio de wavelet. En esta parte se utilizan dos versiones de este filtro: la versión original propuesta por Gupta et al. [27] y aquella donde se incluye el mecanismo de mejoramiento de contraste desarrollado por nosotros, el cual hemos llamado “Ganancia Adaptiva Local Exponencial - GALE”. Esta técnica de mejoramiento fue explicada con detalles en el en el inciso 4.3.1.5.

En la literatura existe un gran número de familias wavelet que pueden ser usadas para llevar a cabo el proceso de descomposición: haar, Daubechies - dbN, Coiflet, Symlet-symN, Biorthogonal-biorN, Meyer-meyN. El algoritmo se evalúa con varias de estas familias wavelet usando diferentes órdenes en cada una de ellas a varios niveles de descomposición. Cada imagen mejorada obtenida se visualiza de tal forma que puede ser contrastada con la imagen original y con los resultados de los otros métodos.

En un primer estudio se determina el tipo de familia wavelet que presenta mejor comportamiento en los resultados, y el número de niveles de descomposición adecuado para el mejoramiento de la imagen de ultrasonido (Apéndice A).

Adicionalmente, para la estimar la varianza del ruido y otros parámetros útiles en el procesador de Bayes o método Bayesiano se utiliza una ventana de 3x3 en cada una de las sub-bandas de detalle a la representación multiresolución. No hay un criterio que diga cuál debe ser el tamaño de ventana óptimo.

La figura 24a ilustra una imagen de ultrasonido real con estructura, la cual no se aprecia muy bien por el alto contenido de *speckle*. La imagen tiene una estructura de 2mm generada con una frecuencia del transductor de 15MHz y con un tamaño de imagen de 120x120. Esta imagen fue procesada con los algoritmos implementados y es comparada con los demás filtros mencionados.

Como se puede observar, esta imagen presenta unas características visuales bastante pobres que impiden determinar con claridad la estructura. La figura 24 muestra los resultados después de aplicar los filtros de reducción de *speckle* sobre la imagen usando el método Bayesiano y los respectivos métodos de comparación. En el método Bayesiano y las técnicas de umbralización basadas en wavelet se usaron cuatro niveles de descomposición con la familia wavelet “coifelt” de orden 1 (Apéndice A).

El mismo procedimiento se realiza para evaluar el comportamiento de estos filtros sobre una imagen de ultrasonido simulada. En esta sección solo se hacen comparaciones entre el método Bayesiano basado en wavelet y los demás métodos usados como referencias o puntos de comparación.

En la figura 25 se ilustra una imagen simulada con el programa FIELD II [83] con estructura y los resultados del filtrado para reducción de *speckle* con los respectivos métodos mencionados y descritos previamente. La imagen tiene una estructura de 4mm generada con una frecuencia del transductor de 5 MHz y con un tamaño de imagen de 120x120 donde la región encerrada por la circunferencia corresponde a la estructura.




Figura 24. Imagen a. de Ultrasonido real inicial. La región encerrada por la circunferencia amarilla corresponde a la estructura, b. filtrada usando Umbralización suave, c. filtrada usando Bayesiano Multiresolución con $L = 4$ y `coiflet1`, d. filtrada utilizando bayesiano con Ganancia Adaptiva Local Exponencial GALE con $L = 4$ y `coiflet1`, e. filtrada con el algoritmo propuesto por Pizurica et al. [33], f. filtrada con Wiener y g. filtrada con Lee [80].




Figura 25. Imagen a. de Ultrasonido simulada con estructura sin procesar donde la región encerrada por la circunferencia amarilla corresponde a la estructura, b. Filtrada usando Umbralización suave, c. Filtrada usando Bayesiano Multiresolución con $L = 4$ y `coiflet1`, d. Bayesiano con Ganancia Adaptiva Local Exponencial GALE con $L = 4$ y `coiflet1`, e. Algoritmo propuesto por Pizurica et al., f. Filtrada con Wiener y g. Filtrada con Lee [80].

De forma general cada uno de los métodos de filtrado tiende a suavizar la imagen para reducir el ruido *speckle*. Es notable que en la figura 25d el filtro bayesiano con Ganancia Adaptiva Local Exponencial GALE elimina el *speckle* en mayor proporción que los demás filtros mientras los bordes de la estructura no se degradan en gran proporción. Los filtros de Lee [80], wiener y de umbralización no presentan buenos resultados en la reducción del *speckle*. Aquí las imágenes resultantes no difieren mucho de las imágenes originales. Adicionalmente, el método de Pizurica [33] no funciona bien sobre las imágenes reales.

5.1.2 Resultado usando el algoritmos de filtrado basado en Hermite

Los resultados del algoritmo usando la transformada Hermite se presentan en esta sección. El procedimiento seguido aquí es el mismo que para el caso anterior. Se trata de hacer una evaluación cualitativa y visual de este filtro comparándolo con los demás filtros de la literatura. De la misma forma se utilizan imágenes reales y simuladas que contienen estructura.

La figura 26 muestra una imagen de ultrasonido real con estructura y los respectivos resultados luego de aplicarles el filtro basado en Hermite y los demás dados en la literatura usados para realizar comparaciones. La imagen presentada tiene una estructura de 2mm generada con una frecuencia del transductor de 15MHz y con un tamaño de imagen de 120x120. La localización de la estructura dentro de la imagen se encuentra encerrada por una circunferencia amarilla.

Análogamente, se evalúa el comportamiento del filtro de Hermite usando las imágenes de ultrasonido simuladas. En la figura 27 se ilustran la imagen original simulada y los resultados visuales de los filtros aplicados sobre este tipo de imágenes. El tamaño de la imagen es de 120x120, posee una estructura de 4mm generada con una frecuencia del transductor de 3.5 MHz. La región encerrada por la circunferencia corresponde a la estructura.




Figura 26. Imagen a. de ultrasonido real inicial con estructura. La estructura se encuentra ubicada en la circunferencia amarilla, b. Filtrada usando Umbralización suave, c. Filtrada usando Hermite, d. Algoritmo propuesto por Pizurica et al. [33], e. Filtrada con Wiener y f. Filtrada con Lee [80].




Figura 27. Imagen a. de ultrasonido simulada inicial con estructura. La circunferencia marca la ubicación de la estructura, b. Filtrada usando Umbralización suave, c. Filtrada usando Hermite, d. Algoritmo propuesto por Pizurica et al. [33], e. Filtrada con Wiener y f. Filtrada con Lee [80].

De los resultados obtenidos se puede apreciar que cualitativamente el filtrado de Hermite en la figura 27c presenta un mejor desempeño en comparación con los otros métodos, tal como sucedió en el caso anterior con el filtrado Bayesiano con función de contraste adaptativa. De la figura 27c se puede notar que el filtrado con Hermite además de eliminar el *speckle* considerablemente trata de recuperar los bordes de la estructura. Esto se presenta como una ventaja adicional dado que los contornos en las imágenes de ultrasonido son por lo general muy confusos y poco definidos.

5.1.3 Evaluación cuantitativa de los filtros implementados.

Hasta el momento se han dado resultados visuales y cualitativos con respecto a los procesos de filtrado sobre la imágenes de ultrasonido. Sin embargo, el análisis de los resultados visuales depende mucho de quien observa las imágenes finales. Es posible que varios observadores no seleccionen el mismo filtro como el mejor de todos los evaluados. Una forma de evitar esto es hacer un análisis numérico o cuantitativo de los resultados. Para llevar a cabo este estudio, aquí definimos varias métricas útiles para hacer este tipo de cuantificación. Los resultados numéricos son soportados por comparación cuantitativa sobre las imágenes libres de ruido (originales) y las imágenes al aplicarles las técnicas de reducción de ruido (esto se realizó para imágenes sintéticas, ya que para las imágenes reales de ultrasonido no tenemos información de la imágenes libres de ruido). Varias métricas cuantitativas son calculadas en este trabajo, entre ellas encontramos:

✓ *La relación señal a ruido – SNR.*

Se define como el margen que hay entre la imagen original libre de ruido y la imagen del ruido que la corrompe.

$$SNR = 10 \cdot \log_{10} \left(\frac{\sigma_S^2}{\sigma_N^2} \right) \quad (94)$$

donde σ_S^2 corresponde a la varianza de la imagen libre de ruido, y σ_N^2 es la varianza de error entre la imagen original y la imagen filtrada. Un valor grande en SNR se asocia a una buena calidad en la imagen.

✓ *La Relación Señal a Ruido Pico - PSNR*

Relación entre la potencia máxima posible de la imagen de entrada y el ruido que corrompe la imagen original.

$$PSNR = 10 \cdot \log_{10} \left(\frac{M_{ax\ intensidad}^2}{MSE} \right) \quad (95)$$

donde el valor de $M_{ax\ intensidad}^2$ es el máximo nivel de gris que puede tomar un pixel de la imagen.

✓ *Coficiente de Correlación – CoC*

Es la medida de similaridad entre la imagen original libre de ruido y la imagen del ruido que la corrompe

$$CoC = \frac{\sum(x-\bar{x})(\hat{x}-\bar{\hat{x}})}{\sqrt{\sum(x-\bar{x})^2 \sum(\hat{x}-\bar{\hat{x}})^2}} \quad (96)$$

donde \bar{x} y $\bar{\hat{x}}$ corresponden a la media de la señal original y de la imagen filtrada respectivamente.

Una vez definida cada una de las métricas a utilizar procedemos a evaluar las imágenes de prueba. En la figura 28 y 29 se muestran la imagen de ultrasonido simulada que fue obtenida de Pizurica [33] y que corresponde a un ejemplo común usado en la literatura para validar algoritmos de filtrado sobre imágenes de ultrasonido. Cabe anotar que esta evaluación se hace sobre las imágenes de ultrasonido simuladas debido a que se necesitan los parámetros de las imágenes libre de ruido. Las tablas 3 y 4 muestran los resultados de

estas métricas utilizando dos imágenes con características diferentes en cuanto a la varianza del ruido.




Figura 28. Comparación cualitativa con la imagen con speckle simulado usada en la literatura para validar algoritmos de filtrado para imágenes de ultrasonido ($\sigma = 0.4$ y $\text{SNR} = 7.8231\text{dB}$). a. Imagen Original (Imagen tomada del trabajo de Pizurica [33]), b. Speckle Simulado (Imagen tomada del trabajo de Pizurica [33]), c. Filtro de Lee [80], d. Wiener, e. Umbralización Suave, f. Método de Pizurica [33], g. Bayesiano, h. Hermite y i. Bayesiano con Ganancia Adaptiva Local Exponencial GALE.




Figura 29. Comparación cualitativa y cuantitativa con la imagen con speckle simulado usada en la literatura para validar algoritmos de filtrado para imágenes de ultrasonido ($\sigma = 0.9$ y $\text{SNR} = 4.28$ dB). a. Imagen Original [33], b. Speckle Simulado [33], c. Filtro de Lee [80], d. Wiener, e. Umbralización Suave, f. Método de Pizurica [33], g. Bayesiano, h. Hermite y i. Bayesiano con Ganancia Adaptiva Local Exponencial GALE.

Tabla 3. Resultados cuantitativos de los filtros aplicados en la imagen con speckle simulado con desviación estándar $\sigma = 0.4$.

Método	Medida cuantitativa		
	SNR(dB)	PSNR	CoC
$\sigma = 0.4$			
Imagen de entrada con ruido <i>speckle</i> [33]	7.8231	29.8628	0.9868
Filtro de Lee [80]	5.0428	22.2583	0.9632
Filtro de Wiener	7.0045	28.2232	0.9812
Umbral suave	7.4044	28.2130	0.9810
Pizurica's method [33]	7.8242	29.7319	0.9867
Bayesiano multiresolución	7.8294	29.8764	0.9867
Bayesiano con Ganancia Adaptiva Local	8.6884	31.5310	0.9914
Exponencial GALE			
Hermite	9.0449	32.3057	0.9923

Tabla 4. Resultados cuantitativos de los filtros aplicados en la imagen con speckle simulado con desviación estándar $\sigma = 0.9$.

Método	Medida cuantitativa		
	SNR(dB)	PSNR	CoC
$\sigma = 0.9$			
Imagen de entrada con ruido <i>speckle</i>	4.2820	22.7811	0.9661
Filtro de Lee	4.7352	22.9140	0.9457
Filtro de Wiener	4.4182	23.0539	0.9380
Umbral suave	4.7922	23.7953	0.9468
Pizurica's method	4.9982	24.2104	0.9486
Bayesiano multiresolución	5.8447	25.8958	0.9661
Bayesiano con Ganancia Adaptiva Local	5.8902	25.2593	0.9663
Exponencial GALE			
Hermite	7.3980	29.0066	0.9836

En cada uno de los casos analizados, se obtuvieron mejores resultados usando las técnicas de filtrado Bayesiano multiresolución, Bayesiano de contraste adaptativo y basado en Hermite, siendo esta última la de mejor desempeño en cada una de las métricas. Análogamente, los mejores resultados experimentales se obtuvieron con cuatro niveles de descomposición y la función Coiflet de orden 1 para el método de filtrado Bayesiano basado o aplicado en el dominio wavelet.

5.2 Resultados de los algoritmos de detección

En esta segunda parte de los experimentos se evaluó el desempeño de los algoritmos de detección usando las imágenes de ultrasonido reales y simuladas descritas en las secciones previas, así como las versiones filtradas de las mismas. De la teoría descrita en los capítulos anteriores se ha dicho y demostrado que las imágenes de ultrasonido cuyo *speckle* ha sido formado completamente presentan una distribución de Rayleigh. Sin embargo, como se están llevando a cabo procesos de filtrado surge la siguiente pregunta: **¿Qué sucede con esta distribución cuando las imágenes son filtradas con alguno de los dos métodos desarrollados?** La respuesta a este cuestionamiento se responde a partir del conocido teorema del límite central. Hemos mencionado que las imágenes de ultrasonido son procesos estocásticos formados por una cantidad de variables aleatorias equivalentes al número de píxeles que contiene la imagen. El mencionado teorema nos dice que la suma de muchas variables aleatorias de cualquier distribución de probabilidad da como resultado una nueva variable aleatoria con distribución Gaussiana. En ese sentido y sabiendo que cada uno de los procesos de filtrado incluyen en sus operaciones muchas sumas entre píxeles, los cuales corresponden a las variables aleatorias, nosotros asumimos en este proyecto que la distribución de probabilidad de la imagen resultante del filtrado posee una distribución Gaussiana.

Adicionalmente, los filtros aquí señalados reducen el *speckle* a través de un proceso de suavizado de la imagen. Esto implica que la imagen a medida que se filtra tiende a ser

mucho más homogénea en cuanto a los niveles de grises. Esta homogeneidad hace de alguna forma que la distribución final tienda a una función Gaussiana.

Para ilustrar un poco este comportamiento, en las figuras 30 y 31 se observan las distribuciones de probabilidad calculadas de forma experimental sobre varias imágenes de ultrasonido originales y sus respectivas versiones filtradas.

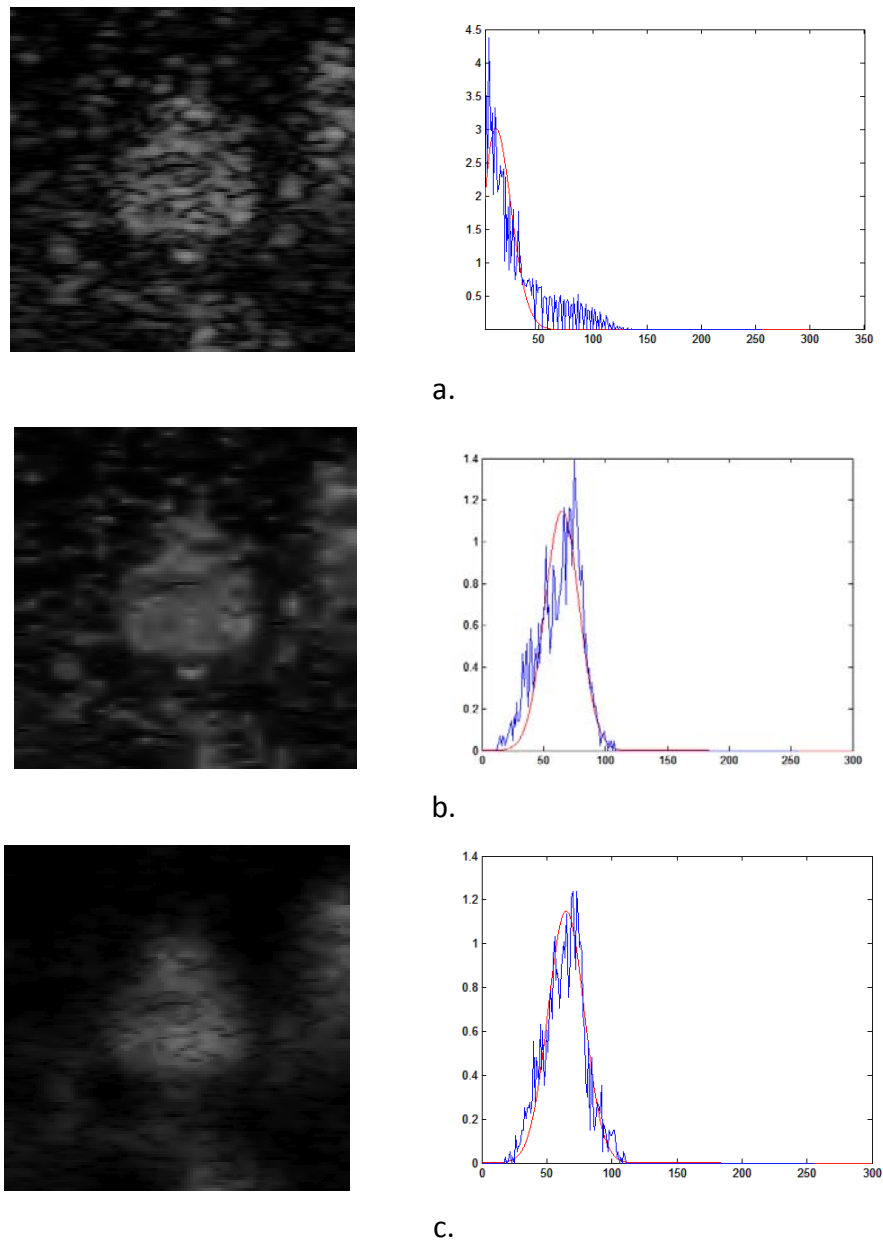


Figura 30. a. Imagen original con estructura y el histograma en azul, b. Imagen filtrada usando el método Bayesiano y el histograma en azul, c. Imagen filtrada usando el método Bayesiano con Ganancia Adaptiva Local Exponencial GALE y el histograma en azul.




Figura 31. a. Imagen de ultrasonido del fondo sin estructura y el histograma en azul, b. Imagen filtrada usando el método Bayesiano y el histograma en azul, c. Imagen filtrada usando el método Bayesiano con Ganancia Adaptiva Local Exponencial GALE y el histograma en azul.

De las imágenes 30 y 31 es notable que la distribución de la imagen filtrada tiende a una función Gaussiana. En estas figuras se ha marcado el histograma de la imagen en color azul. Adicionalmente, en rojo se ha tratado de ajustar una función teórica de Rayleigh para el caso de la imagen original y Gaussiana para el caso de las imágenes filtradas. En base al

análisis hecho, se optó por aplicar el método de detección basado en la distribución de Rayleigh cuando se procesan las imágenes originales. En el caso contrario, es decir cuando se analizan las imágenes filtradas, se utiliza el criterio de decisión derivado de asumir distribuciones de probabilidad Gaussianas.

Para la evaluación del desempeño de los métodos de detección se usó la curva ROC (Característica Operativa del Receptor) la cual es muy útil en sistemas de clasificación binario [19]. Esta curva nos permite evaluar la razón de verdaderos positivos (Sensibilidad) con respecto a la razón de falsos positivos (Especificidad). Por lo tanto, la curva ROC es calculada usando las imágenes de prueba originales y filtradas, además de las reales y simuladas. Estos métodos de detección generalmente son direccionados a desarrollar herramientas que puedan ayudar o bien reemplazar al observador humano en la tarea de detección de lesiones.

En la figura 32 se puede observar las curvas ROC obtenidas cuando se evalúan las imágenes reales de prueba. En total se tiene 146 imágenes reales, de las cuales se tienen 73 con estructura y 73 sin estructura.




Figura 32. Curva ROC para evaluar el desempeño de la detección en imágenes de ultrasonido reales.

De la teoría de detección se sabe que el mejor desempeño es obtenido cuando la curva ROC se aproxima mucho al punto de valor 1 del eje vertical izquierdo [18-20]. En este punto se obtiene el mayor número de aciertos (verdaderos positivos) con respecto al menor número de errores (falsos positivos). De la figura 32 se aprecia que el mejor desempeño en la detección de estructuras se logra cuando las imágenes son filtradas con el método bayesiano con ganancia adaptiva local exponencial GALE, seguido por el método de filtrado basado en la transformada Hermite. Cuando se trabajan los algoritmos de detección sobre las imágenes con *speckle* u originales se reduce la detectabilidad de las estructuras.

Cuando se utiliza el método de detección Gaussiano es necesario conocer los parámetros estadísticos de primer y segundo orden que rigen a las imágenes con y sin estructura (en presencia y ausencia de señal) tal como se describió en el capítulo 4, ecuación (48). En este proyecto, se hace un entrenamiento previo con varias imágenes filtradas de prueba para obtener dichos parámetros. En este sentido, se utilizan la misma cantidad de imágenes con estructura y sin estructura para hacer dicha estimación.

En la figura 32, el mejor resultado de la detección obtenido con las imágenes de ultrasonido de fantasmas con *speckle* (curva en color azul) es de un 82% correspondiente a 121 imágenes detectadas (con estructura y sin estructura) de un total de 146 imágenes. La sensibilidad obtenida es de 0.8082 y la especificidad es de 0.8493. En el caso de las imágenes filtradas utilizando el método Bayesiano (curva en color rojo), el mejor resultado de la detección fue de 83.5% equivalente a 122 aciertos de las 146 imágenes, con un valor de sensibilidad de 0.9041 y de especificidad de 0.7671. Por lo tanto, se logra un incremento en el porcentaje de detección cuando se filtran las imágenes.

No obstante, el mejor desempeño se obtuvo filtrando las imágenes con el método Bayesiano con Ganancia Adaptiva Local Exponencial GALE seguido del filtro basado en

Hermite. El mejor resultado de detección usando los filtros basados en Hermite (curva en color rosado) fue de 85.6% equivalente a 125 imágenes clasificadas correctamente de las 146, donde la sensibilidad fue de 0.8493 y la especificidad de 0.8630. En el caso del método Bayesiano con ganancia adaptiva local exponencial GALE (curva en color verde), el mejor resultado de detección fue de 87.6%, equivalente a 128 imágenes reconocidas de 146 en total que corresponde a 0.9589 de sensibilidad y 0.7945 de especificidad. En la tabla 5 se presentan los datos correspondientes al área bajo la curva (AUC) obtenidas a partir de las gráficas en la figura 32.

Tabla 5. Área bajo la curva correspondiente a la figura 32.

	AUC
Imágenes de ultrasonido de fantasmas con <i>speckle</i> (curva en color azul)	0.9159
Imágenes filtradas con el método Bayesiano (curva en color rojo)	0.9172
Imágenes Filtradas con Hermite (curva de color rosado)	0.9266
Imágenes filtradas con el método Bayesiano con ganancia adaptiva local exponencial GALE (curva de color verde)	0.9535

El mismo procedimiento se lleva a cabo usando las imágenes simuladas con el programa FIELD II. Con estas imágenes simuladas es posible manipular el tamaño de la estructura y el contraste de la imagen de una forma rápida y sencilla. Esto nos da un mayor grado de libertad para evaluar los algoritmos con muchas más posibilidades. En la figura 33 se muestran los resultados de la curva ROC obtenida sobre la imagen original simulada y las filtradas con los métodos desarrollados.




Figura 33. Curva ROC para evaluar el desempeño de la detección de imágenes simuladas.

El mejor resultado de la detección obtenido para estas imágenes simuladas sin filtrar (curva en color azul) fue de 72%, el cual representa 54 imágenes clasificadas correctamente de 74 en total (con y sin estructuras), lo que corresponde a un valor de sensibilidad de 0.8 y de especificidad de 0.15. Aplicando el método Bayesiano (curva en color rojo) el mejor resultado de la detección fue de 0.74 equivalente a 55 imágenes clasificadas correctamente de 74. La sensibilidad y especificidad son 0.83 y 0.55 respectivamente.

Cuando se aplicó el algoritmo de detección a las imágenes filtradas con la transformada de Hermite (curva en color rosado) se obtuvo un porcentaje de aciertos de 86.5% el cual equivale a 64 imágenes clasificadas correctamente de 74 con una sensibilidad de 0.9815 y una especificidad de 0.50. Análogamente, procesando previamente las imágenes con el método de filtrado Bayesiano con Ganancia Adaptiva Local Exponencial GALE (curva en

color verde) se logró un porcentaje de aciertos de 89% equivalente a 66 imágenes clasificadas correctamente de 74 imágenes procesadas. La sensibilidad y especificidad para este caso fueron de 0.9444 y 0.75 respectivamente. En las imágenes simuladas se presenta mayor dificultad debido a que éstas han sido muy degradadas y su contraste es mucho más bajo. En la tabla 6 se muestra el área bajo la curva (AUC) de los datos dados por las curvas de la figura 33.

Tabla 6. Área bajo la curva de la figura 33.

	AUC
Imágenes simuladas sin procesar (curva en color azul)	0.3144
Imágenes filtradas con el método Bayesiano (curva en color rojo)	0.7181
Imágenes filtradas con Hermite (curva de color rosado)	0.9153
Imágenes filtradas con el método Bayesiano con ganancia adaptiva local exponencial GALE (curva de color verde)	0.9380

En la ecuación (39) se ha definido una forma de evaluar el desempeño del observador o sistema de detección a través de la relación señal a ruido SNR obtenida a partir del criterio de decisión. Este método fue desarrollado por Smith and Wagner [17] y utiliza parámetros conocidos de las estructuras en las imágenes de ultrasonido. Estos parámetros corresponden al tamaño de la estructura, el contraste de la misma con respecto al fondo y el tamaño del *speckle*. Este es un caso típico de un método de detección donde la señal es conocida perfectamente y el ruido o fondo también. En la figura 34 se ilustran varias imágenes en las cuales se tiene la misma estructura, pero con una variación de contraste. Cuando se habla de bajo contraste nos referimos a que los niveles de grises de la

estructura son muy parecidos a los del fondo. Esto combinado con el *speckle* hace que el índice de detectabilidad sea bastante pobre en desempeño.




Figura 34. Evaluación de una estructura de 5mm de diámetro con diferentes contrastes. a. 0.3242, b. 0.2568, c.0.2533, d. 0.2317, e. 0.2303

En la figura 35 se puede observar la curva que relaciona el contraste de la estructura con la relación señal a ruido SNR. En este caso se tiene que el diámetro de la estructura es de 5mm (línea en color verde), el tamaño del *speckle* en la dirección axial es de $S_{cx}=0.6$ mm y en la dirección lateral es de $S_{cz}=2$ mm. Análogamente se realizó el estudio para la estructura de 2mm (línea en color rojo) con los mismos parámetros de speckle. Este análisis fue aplicado sobre las imágenes simuladas sin filtrar. Se puede apreciar de la figura 35 que a medida que el nivel de gris de la estructura se va acercando al del fondo (disminuye el contraste) el índice de detectabilidad o relación SNR va disminuyendo lo cual indica que se hace difícil detectar la estructura.




Figura 35. SNR para evaluar el desempeño de detección en imágenes de ultrasonido simuladas con estructuras de 2mm (línea roja) y 5mm (línea verde).

Este procedimiento se lleva a cabo sobre las mismas imágenes pero filtradas previamente. Aquí se evalúa el comportamiento usando el filtro de Hermite. Las imágenes filtradas resultantes se muestran en la figura 36. Se puede ver que además de eliminar el *speckle* en gran porcentaje se ha mejorado sustancialmente los bordes de la estructura. Esto debería conducir a incrementar el índice de detectabilidad.




Figura 36. Imágenes de la figura 34 filtradas con Hermite.

En la figura 37 se observa la relación entre el desempeño del observador ideal y el contraste de la estructura con respecto al fondo. La figura muestra la SNR para una estructura de 5mm (línea en color verde) y una estructura de 2mm (línea en color rojo). Cabe anotar que en este segundo análisis se considera que la distribución de las imágenes filtradas es Gaussiana y que las variables aleatorias que componen las imágenes son independientes y no correlacionadas. En el capítulo anterior se demostró que este caso coincide con el análisis hecho cuando se consideran distribuciones de Rayleigh con las mismas condiciones.

En la gráfica de la figura 37 se observa un comportamiento muy similar al del caso anterior. Entre mayor sea el contraste mejor va a ser la relación señal a ruido del sistema de detección. Este análisis fue posible porque en las imágenes simuladas se puede conocer y controlar de antemano todos parámetros necesarios para obtener la SNR a partir de las reglas de decisión.




Figura 37. SNR para evaluar el desempeño de detección en imágenes de ultrasonido simuladas y filtradas usando Hermite con estructuras de 2mm (línea en color rojo) y 5mm (línea en color verde).

CAPITULO 6

CONCLUSIONES

Las imágenes médicas son una de las herramientas más importantes para llevar a cabo procesos de detección y diagnóstico de enfermedades. En este proyecto se analizaron esencialmente imágenes de ultrasonido, las cuales constituyen una de las modalidades de imagenología que presenta mayor beneficio por su bajo costo, portabilidad y porque usa un tipo de radiación no ionizante. Específicamente se implementaron dos métodos de detección y varios métodos de filtrado para analizar estructuras de bajo contraste que simulan la presencia de tumores en ecografías de mama. En general se usaron varias imágenes reales de ultrasonido e imágenes simuladas para validación de los algoritmos.

El método de filtrado usando Hermite presenta un mejor desempeño visual y cuantitativo sobre ambos tipos de imágenes en comparación con las otras técnicas de filtrado utilizadas. Al aplicar este método sobre las imágenes reales y simuladas se obtiene una buena reducción de *speckle* y se preservan los detalles de las estructuras. Las tres métricas de desempeño usadas como evaluación dadas en las tablas 3 y 4 demuestran que el filtro usando Hermite tiene un mejor comportamiento.

De manera general, las dos técnicas de filtrado implementadas presentan un mejor desempeño comparada con otros métodos propuestos en la literatura, los cuales reducen el *speckle* eficientemente en imágenes simuladas pero trabajan de manera deficiente en imágenes reales de ultrasonido. Además, se demostró que cuantitativamente y cualitativamente las técnicas desarrolladas son superiores considerando las métricas utilizadas.

En esta tesis se asumieron dos métodos de detección teniendo en cuenta la estadística de las imágenes de ultrasonido. En cada caso se consideró que cada imagen es una realización de un proceso estocástico compuesto por múltiples variables aleatorias con distribuciones de probabilidad conocidas. En la primera parte se asumió que la imagen de ultrasonido no filtrada tiene una distribución de Rayleigh cuyas variables aleatorias son independientes y no correlacionadas. Para el caso de las imágenes filtradas se asumió que su distribución resultante es Gaussiana teniendo en cuenta el teorema del límite central. Por esta razón se implementó un método de detección para este tipo de distribución.

Por otro lado, se pudo comprobar que filtrar las imágenes de ultrasonido mejora sustancialmente la detección de las estructuras. Con diferentes tipos de contraste y tamaño de las estructuras, la curva ROC demuestra que hay un mejor comportamiento si las imágenes son filtradas previamente. De la apariencia visual resultante se puede notar también que es incluso mejor para un observador humano llevar a cabo la tarea de detección y análisis sobre las imágenes procesadas con los filtros.


De las curvas ROC mostradas en la figura 32 y 33 se puede concluir que filtrando con el método Bayesiano con ganancia adaptiva local exponencial GALE se obtiene un mejor porcentaje de detectabilidad de las estructuras en comparación con las imágenes originales sin filtrar y con las filtradas usando otros métodos muy comunes en la literatura.

El proyecto desarrollado puede ser una herramienta útil para llevar a cabo tareas de diagnóstico orientadas a la búsqueda de lesiones o tumores dentro de las imágenes de

ultrasonido. Cabe destacar que el tipo de análisis llevado a cabo con este tipo de métodos solo indica si está presente o no la lesión.

Método Bayesiano con Ganancia Adaptiva Local Exponencial GALE usando diferentes familias Wavelet

En la figura A1 se muestran los resultados del filtrado utilizando diferentes familias wavelet de una imagen de ultrasonido de un fantasma con una estructura de 2mm que tiene un tamaño de 120x120.






Figura A1. Imagen a. de Ultrasonido sin procesar, b. filtrada usando Haar $L=2$ (L representa los niveles de descomposición), c. filtrada usando daubechies2 con $L = 2$, d. filtrada usando daubechies2 con $L = 4$, e. filtrada usando coiflet1 con $L = 2$, f. filtrada usando

coiflet1 con $L = 4$, g. filtrada utilizando symlet2 con $L = 2$, h. filtrada utilizando symlet2 con $L = 4$, i. filtrada utilizando biorthogonal2.2 con $L = 2$ y j. filtrada utilizando biorthogonal2.2 con $L = 2$.

En las imágenes se presenta una comparación del filtrado bayesiano con ganancia adaptativa local exponencial GALE utilizando diferentes familias wavelet y con diferentes niveles de descomposición. Como se puede observar, la imagen que presenta mejor apariencia visual es la procesada con coiflet1 y cuatro niveles de descomposición ($L=4$).

REFERENCIAS

- [1] Perez, M. Modelos variacionales para segmentación cardiaca en ultrasonidos, XXI Congreso de Ecuaciones Diferenciales y Aplicaciones XI Congreso de Matemática Aplicada, pp. 1-8, 2009.
- [2] N. Raine-Fenning, K. Jayaprakasan, J. Clewes, I. Joergner, S.D. Bonaki, S. Chamberlain, L Devlin, H Priddle, and I Johnson, SonoA VC: a novel method of automatic volume calculation, *Ultrasound Obstet Gynecol Journal*, vol. 31, pp. 691-696, 2008.
- [3] J.S. Abramowicz and E. Sheiner, In Utero Imaging of the Placenta: Importance for Diseases of Pregnancy, vol. 21, pp. S14-S22, 2007.
- [4] P. Rousset, A. Gompel, S. Christin-maitre, M. Pugeat, D. Hugol, M.A. Ghossain, and J.N. Buy, Ovarian hyperthecosis on grayscale and color Doppler ultrasound, *Ultrasound Obstet Gynecol Journal*, vol 32, pp.694-699, 2008.
- [5] Y Yue, M.M. Croitoru, A. Bidani, J.B. Zwischenberger, J.w. Clark Jr. Nonlinear multiscale wavelet diffusion for speckle suppression and edge enhancement in ultrasound images, *IEEE Transactions on Medical Imaging*, vol. 25, pp.297-311, 2006.
- [6] JW. Tian, L.T. Sun, YH. Guo, H.D. Cheng, and YT. Zhang Computerized-aid diagnosis of breast mass using ultrasound image, *Medical Physics*, vol. 34, pp.3158-3164, 2007.
- [7] A. M. Bosch and et al., Interexamination variation of whole breast ultrasound, *British Journal of Radiology*, vol. 76, pp. 328–331, 2003.
- [8] P.M. Shankar, J.M. Reid, H. Ortega, C.W. Piccoli, and B.B. Goldberg, Use of non-rayleigh statistics for identification of tumors in ultrasonic B-scans of the breast, *IEEE Transactions on Medical Imaging*, vol. 12(4), pp. 687–692, 1993.
- [9] AT Stavros, D., Thickman, CL Rapp, MA Dennis, SH Parker, and GA Sisney, Solid breast nodules: Use of sonography to distinguish between benign and malignant lesions, *Radiological Society of North America*, vol. 196, pp. 122–134, 1995.
- [10] E. Warner and et al., Surveillance of brca1 and brca2 mutation carriers with magnetic resonance imaging, ultrasound, mammography, and clinical breast examination, *The Journal of American Medical Association*, vol. 292(11), pp. 1317–1325, 2004.
- [11] T. Chan and L. Vese, "Active contours without edges", *IEEE Transactions on Image Processing*, vol.10, pp. 266 - 272, 2001.

- [12] V. Grau, A.U.J. Mewes, M. Alcaniz, R. Kikinis, S.K.Warfield, Improved watershed transform for medical image segmentation using prior information, *IEEE Transactions on Medical Imaging*, vol.23(4), pp. 447-458, 2004.
- [13] J. Wu and A. C. S. Chung, A segmentation model using compound Markov random fields based on a boundary model, *IEEE Transaction on Image Processing*, vol. 16, pp. 241-252, Jan 2007.
- [14] Sokratis Makrogiannis, George Economou, Spiros Fotopoulos, and Nikolaos G. Bourbakis, Segmentation of Color Images Using Multiscale Clustering and Graph Theoretic Region Synthesis, *IEEE Transaction on System, Man, and Cybernetics*, vol.35, No.2, 2005.
- [15] R. F. Wagner, S. W. Smith, J. M. Sandrik, and H. Lopez, Statistics of speckle in ultrasound B-scans, *IEEE Transactions on Sonics and Ultrasonics*, vol. SU-30, pp. 156–163, 1983.
- [16] R. F. Wagner, M. F. Insana, and D. G. Brown, Statistical properties of radio-frequency and envelope-detected signals with applications to medical ultrasound, *Journal of the Optical Society of America*, vol. 4, pp. 910–922, 1987.
- [17] S. W. Smith, R. F. Wagner, J. M. Sandrik, and H. Lopez, Low contrast detectability and contrast/detail analysis in medical ultrasound, *IEEE Transactions on Sonics and Ultrasonics*, vol. SU-30, no. 3, pp. 164–173, 1983.
- [18] H. H. Barrett, “Objective assessment of image quality: Effects of quantum noise and object variability”, *Journal of the Optical Society of America*, pp. 1266-1278, 1990.
- [19] H. H. Barrett, C. K. Abbey, and E. Clarkson, Objective assessment of image quality. iii. roc metrics, ideal observers, and likelihood-generating functions, *Journal of the Optical Society of America*, p. 1520-1535, 1998.
- [20] H. H. Barrett, J. L. Denny, R. F. Wagner, and K. J. Meyers, Objective assessment of image quality. ii. fisher information, fourier crosstalk, and figures of merit for task performance, *Journal of the Optical Society of America*, p. 834-852, 1995.
- [21] M. F. Insana and T. J. Hall, Visual detection efficiency in ultrasonic imaging: A framework for objective assessment of image quality, *Journal of the Acoustical Society of America*, vol. 95(4), pp. 2081-2090, 1994.
- [22] J. W. Goodman, *Introduction to Fourier Optics*, 2nd ed., McGraw-Hill, New York, 1996.
- [23] E. Clarkson and H. H. Barrett, Approximations to ideal-observer performance on signal-detection tasks, *Applied Optics*, vol. 39, pp. 1783-1793, 2000.

- [24] C.P. Loizou, C.S. Pattichis, M. Pantziaris, R.S.H. Istepanian, M. Pantziaris, T. Tyllis, A. Nicolaidis, Quantitative quality evaluation in ultrasound imaging in carotid artery, *Medical & Biological Engineering & Computing Journal*, vol. 44 (5), 414–426, 2006.
- [25] C.P. Loizou, C.S. Pattichis, C.I. Christodoulou, R.S.H. Istepanian, M. Pantziaris, A. Nicolaidis, Comparative evaluation of despeckle filtering in ultrasound imaging of carotid artery, *IEEE Transactions on Ultrasonics Ferroelectrics and Frequency Control*, vol. 52 (5), 1653–1669. 2005.
- [26] Y. Yu, S.T. Acton, Speckle reducing anisotropic diffusion, *IEEE Transaction on Image Processing*, vol. 11 (11), 1260–1270, 2002.
- [27] S. Gupta, R.C. Chauhan, S.C. Saxena, A wavelet based statistical approach for speckle reduction in medical ultrasound images, *Journal of International Federation of Medical and Biological Engineering*, vol. 42, 189–192, 2004.
- [28] S.H. Xiang, Y.T. Zhang, Maximization of the signal-to-noise ratio for two-dimensional medical ultrasound transducer sensitivity improvement by denoising wavelets, *Proceeding of International Conference on Biomedical Engineering*, 3–5, 1996.
- [29] X. Zong, A.F. Laine, E.A. Geiser, Speckle reduction and contrast enhancement of echocardiograms via multiscale nonlinear processing, *IEEE Transactions on Medical Imaging*, vol. 17, 532–540, 1998.
- [30] A. Achim, A. Bezerianos, P. Tsakalides, Ultrasound image denoising via maximum a posteriori estimation of wavelet coefficients, *Proceeding of EMBS 23rd Annual International Conference of IEEE*, vol. 3, pp. 2553–2556, 2001.
- [31] S. Gupta, R.C. Chauhan, S.C. Saxena, Homomorphic wavelet thresholding technique for denoising medical ultrasound images, *Journal of Medical Engineering & Technology*, vol. 29 (5), 208–214, 2005.
- [32] O.V. Michailovich, A. Tannenbaum, Despeckling of medical ultrasound images, *IEEE Transactions on Ultrasonics Ferroelectrics and Frequency Control*, vol. 53 (1), 2006.
- [33] A. Pižurica, W. Philips, I. Lemahieu, M. Acheroy, A versatile wavelet domain noise filtration technique for medical imaging, *IEEE Transactions on Medical Imaging*, vol. 22 (3), 2003.
- [34] S. Gupta, R.C. Chauhan, S.C. Saxena, A robust multi-scale non-homomorphic approach to speckle reduction in medical ultrasound images, *Journal of International Federation of Medical and Biological Engineering*, vol. 152 (1), 129–135, 2005.

- [35] Y. Yue, M.M. Croitoru, A. Bidani, J.B. Zwischenberger, J.W. Clark, Non-linear multiscale wavelet diffusion for speckle suppression and edge enhancement in ultrasound images, *IEEE Transactions on Medical Imaging*, vol. 25 (3), 2006.
- [36] D. L. Donoho, De-noising by soft-thresholding, *IEEE Transactions on Information Theory*, vol. 41, pp. 613–627, 1995.
- [37] S. Grace Chang, Adaptive Wavelet Thresholding for Image Denoising and Compression, *IEEE Transaction on Image Processing*, vol. 9, No. 9, 2000.
- [38] S. Gupta, R.C., Locally adaptive wavelet domain Bayesian processor for denoising medical ultrasound images using Speckle modelling based on Rayleigh distribution, *IEE Proceedings Vision, Image & Signal Processing*, vol. 152, No. 1, 2005.
- [39] Nadine Barrie Smith, Andrew Webb, *Introduction to Medical Imaging Physics, Engineering and Clinical Applications*, Cambridge University Press, pp 300. 2011.
- [40] Geoff Dougherty, *Digital Image Processing for Medical Applications*, Cambridge University Press, pp 485. 2009.
- [41] Guy C., Ffytche D., *An Introduction to the Principles of Medical Imaging*, Imperial College Press, pp 374. 2005.
- [42] Hendee, W., Russell, E., *Medical Imaging Physics*, A John Wiley & Sons (Wiley -Liss), pp. 502. 2002.
- [43] Suetens, Paul, *Fundamentals of Medical Imaging*, Cambridge University Press, pp 262. 2009.
- [44] Klauser AS and Peetrons P. *Developments in musculoskeletal ultrasound and clinical applications*, *Skeletal Radiology*, 2009.
- [45] Marwick TH. The future of echocardiography, *European Journal of Echocardiography*, vol. 10(5), 594–601, 2009.
- [46] Green, D.M, Swets, J. A., *Signal detection theory and Psychophysics*. Peninsula Publishing, Los Altos, California, USA, 1966.
- [47] C. K. Abbey, R. J. Zemp, and M. F. Insana, Pre-envelope deconvolution for increased lesion detection efficiency in ultrasonic imaging, *Proceedings of SPIE*, vol. 5034, 2003.
- [48] R. J. Zemp, C. K. Abbey, and M. F. Insana, Generalized neq for assessment of ultrasound image quality, *Proceedings of SPIE*, vol. 5030, pp. 391-402, 2003.

- [49] R. J. Zemp, C. K. Abbey, and M. F. Insana, Fundamental performance metrics and optimal image processing strategies for ultrasound systems, Proceedings IEEE Ultrasonics Symposium, 2002.
- [50] Zemp RJ, Parry MD, Abbey CK, Insana MF, Detection performance theory for ultrasound imaging systems, IEEE Transactions on Medical Imaging, vol. 24, 300-310, 2005.
- [51] Fiete RD, Barrett HH, Smith W E, Myers K J, Hotelling trace criterion and its correlation with human-observer performance, Journal of the Optical Society of America, vol. A 4, 945-953, 1987.
- [52] Fiete RD, Barrett HH, Cargill E B, et al, Psychophysical validation of the Hotelling trace criterion as a metric for system performance, Proceedings of the Society Photo-Optical Instrumentation Engineers, vol. 767, 298-305, 1987.
- [53] Rolland JP, Barrett HH, Effect of random background inhomogeneity on observer detection performance, Journal of the Optical Society of America, vol. A 9, 649-658, 1992.
- [54] Lartzien C, Kinahan P, Comtat C, et al., "A tumor detection observer study comparing 2D versus 3D whole-body PET imaging protocols", IEEE Nuclear Science Symposium Conference Record, vol. 3, pp. 81- 86, 2000.
- [55] Lartzien C, "Optimisation des protocoles d'imagerie corps entier en tomographie par émission de positons pour la détection des hyperfixations du 18F-FDG en oncologie", Thèse pour obtenir le grade de Docteur de l'Université Paris XI, 2001.
- [56] Burckhardt, C.B., Speckle in ultrasound B-mode scans. IEEE Transactions on Sonics and Ultrasonics, vol. 25, 1978.
- [57] Abbott, J.G, and Thurstone, F.L., Acoustic speckle: Theory and experimental analysis, Ultrasonic Imaging, vol 4, pp. 303-24, 1979.
- [58] Hendee, W.R., Ritenour, E.R., and Hoffmann, K.R., Medical imaging physics. Medical Physics, vol. 30, pp. 730, 2003.
- [59] Bates, R.H. and Robinson, B.S., Ultrasonic transmission speckle imaging, Ultrasonic Imaging, vol 3, pp. 378-94, 1981.
- [60] Ioannidis, A., Kazakos, D., and Watson, D.D., Application of the median filter on nuclear medicine scintigram images, Proceedings of 7th International Conference on Pattern Recognition, pp. 33-36, 1984.

- [61] Ritenour, E. R., Nelson, T. R. and Raff, U., Application of the median filter to digital radiographic images, Proceedings IEEE International Conference of Acoustics, Speech and Signal Processing, pp. 2311-2314, 1984.
- [62] Adam, D., Beilin-Nissan, S., Friedman, Z., and Behar, V., The combined effect of spatial compounding and nonlinear filtering on the speckle reduction in ultrasound images. Ultrasonics, vol. 44, pp. 166, 2006.
- [63] Abd-Elmoniem, K.Z., Youssef, A.B.M., and Kadah, Y.M., Real-time speckle reduction and coherence enhancement in ultrasound imaging via nonlinear anisotropic diffusion. IEEE Transactions on Biomedical Engineering, vol. 49, pp. 997-1014, 2002.
- [64] Chen, Y., Yin, R.M., Flynn, R., and Broschat, S., Aggressive region growing for speckle reduction in ultrasound images. Pattern Recognition Letters, vol. 24, pp. 997, 2003.
- [65] Loupas, T., McDicken, Allan, P., An adaptive weighted median filter for speckle suppression in medical ultrasonic image, IEEE Transactions on Circuits and Systems, vol. 36, no. 1, pp. 129-135, January 1989.
- [66] Czerwinski, R.N., Jones, D.L., and O'Brien Jr. W.D. Ultrasound speckle reduction by directional median filtering, International Conference on Image Processing, pp. 358 - 361.
- [67] Michailovich, O.V. and Tannenbaum, A., Despeckling of medical ultrasound images. IEEE Transactions on Ultrasonics Ferroelectrics and Frequency Control, vol. 53, pp. 64-78, 2006.
- [68] Bamber, J.C. and Daft, C., Adaptive filtering for reduction of speckle in ultrasonic pulse-echo images, Ultrasonics, vol. 24, 1986.
- [69] Bamber, J.C. and Cook-Martin, G., Texture analysis and speckle reduction in medical echography, SPIE International Symposium on Pattern Recognition and Acoustical Imaging, 120-127, 1987.
- [70] Crawford, D.C., Bell, D.S., and Bamber, J.C. Implementation of ultrasound speckle filters for clinical trial. Proceedings of IEEE Ultrasonics Symposium, 1589-1592, 1990.
- [71] Bamber, J.C. and Phelps, J.V. Real-time implementation of coherent speckle suppression in B-scan images. Ultrasonics, vol. 29, 1991.
- [72] Crawford, D.C., Bell, D.S., and Bamber, J.C., Compensation for the signal processing characteristics of ultrasound B-mode scanners in adaptive speckle reduction, Ultrasound in Medicine and Biology, vol. 19, 1993.

- [73] Shankar, P.M., Speckle reduction in ultrasound B-scans using weighted averaging in spatial compounding, *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control*, vol. 33, pp. 754-758, 1986.
- [74] Verhoeven, J.T.M. and Thijssen, J.M., Improvement of lesion detectability by speckle reduction filtering - A quantitative study, *Ultrasonic Imaging*, vol. 15, pp. 181-204, 1993.
- [75] Bernstein, R., Adaptive nonlinear filters for simultaneous removal of different kinds of noise in images, *IEEE Transactions on Circuits and System*, vol. 34, pp. 1275-1291, 1987.
- [76] Loupas, T., McDicken, W.N., and Allan, P.L., An adaptive weighted median filter for speckle suppression in medical ultrasonic images, *IEEE Transactions on Circuits and System*, vol. 36, pp. 129-135, 1989.
- [77] Karaman, M. Kutay, M.A., and Bozdagi, G. An adaptive speckle suppression filter for medical ultrasonic-imaging, *IEEE Transactions on Medical Imaging*, vol. 14, pp. 283-292, 1995.
- [78] Xiao, C.Y., Su, Z., and Chen, Y.Z. A diffusion stick method for speckle suppression in ultrasonic images, *Pattern Recognition Letters*, vol. 25, pp. 1867-1877, 2004.
- [79] Frost, V.S., Stiles, J.A., Josephine, A., Shanmugan, K. S., and Holtzman, J.C., 1982. A Model for Radar Images and Its Application to Adaptive Digital Filtering of Multiplicative Noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-4, No. 2, 1982.
- [80] Lee, J.S.,. Speckle Analysis and Smoothing of Synthetic Aperture Radar Images, *Computer Graphics and Image Processing*, vol. 17, 24-32. 1981.
- [81] Achim, A., Bezerianos, A., Tsakalides, P., Novel Bayesian multiscale method for speckle removal in medical ultrasound images, *IEEE Transactions on Medical Imaging*, vol. 20, pp. 772-783, 2001.
- [82] Pietro Perona AND Jitendra Malik, Scale-Space and Edge Detection Using Anisotropic Diffusion, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, pp. 629-639, 1990.
- [83] Jensen, J.A., Field: A Program for Simulating Ultrasound Systems, *Medical & Biological Engineering & Computing*, vol. 34, pp. 351-353. 1996.
- [84] G.R. Cooper and C.D. McGillem, *Probabilistic Methods of Signal and System Analysis*. (2nd. Ed.) Florida: Holt, Rhinehart, and Winston, Inc., 1986.

- [85]Escalante-Ramírez, Boris, The Hermite transform as an efficient model for local image analysis: An application to medical image fusion, *Journal Computers and Electrical Engineering*, vol 34, pp. 99-110, 2008.
- [86]Escalante-Ramírez, Boris and López-Caloca, Alejandra A., *The Hermite Transform: An Efficient Tool for Noise Reduction and Image Fusion in Remote Sensing in Signal and Image Processing for Remote Sensing*, Taylor and Francis, pp. 537-555, 2006.
- [87]A. Graps, *An introduction to wavelets*, IEEE Computational Science and Engineering, vol. 2, Issue 2, Summer , pp. 50 – 61, 1995.
- [88]S. Mallat, *A Wavelet Tour of Signal Processing*, Academic Press, 1999.
- [89]Pallares G., De la Cruz M., *Visión por computador – Imágenes Digitales y Aplicaciones*, Alfaomega, 2002.
- [90]Mihçak, M.K. Kozintsev, I., Ramchandran, K. and Moulin, P., Low complexity image denoising based on statistical modeling of wavelet coefficients, *IEEE Signal Processing Letter*, vol. 6, 1999.
- [91]Heinlein P, Drexl J, Schneider W. Integrated wavelets for enhancement of microcalcifications in digital mammography, *IEEE Transactions on Medical Imaging*, vol. 22, 2003.
- [92]Silván-Cárdenas, José L., Escalante-Ramírez, Boris, The multiscale hermite transform for local orientation analysis, *IEEE Transactions on Image Processing*, vol. 15, pp. 1236-1253, 2006.
- [93] J. D. Tucker and M. R. Azimi-Sadjadi, Neyman pearson detection of K-distributed random variables, *Proceedings of SPIE*, vol. 7664, pp. Q1-Q12, 2010.
- [94]S.Kalaivani Narayanan and R.S.D.Wahidabanu, A View on Despeckling in Ultrasound Imaging, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, vol. 2, 2009.