

UNIVERSIDAD TECNOLÓGICA DE BOLIVAR

FACULTAD DE INGENIERÍAS

Título: Evaluación de técnicas de segmentación de imágenes de ultrasonido por crecimiento de regiones

Autor: Yireh Castrillo

Directora: Sonia Helena Contreras Ortiz

Cartagena

Evaluación de técnicas de segmentación de imágenes de ultrasonido
por crecimiento de regiones

Yireh Castrillo

Directora: Sonia Helena Contreras Ortiz

Universidad Tecnológica de Bolívar
Facultad de Ingenierías.
Programa de Ingeniería Eléctrica.
Cartagena

Evaluación de técnicas de segmentación de imágenes de ultrasonido
por crecimiento de regiones

Yireh Castrillo

Trabajo de grado para optar al título de

Ingeniero Eléctrico

Directora: Sonia Helena Contreras Ortiz

Universidad Tecnológica de Bolívar
Facultad de Ingenierías.
Cartagena

Tabla de contenido

| | |
|--|-----------|
| Resumen..... | 5 |
| 1. Introducción | 6 |
| 2. Marco Teórico | 8 |
| 2.1 Formación de imagen..... | 8 |
| 2.2 Artefactos que afectan las imágenes de ultrasonido..... | 11 |
| Umbralización..... | 14 |
| Bordes | 14 |
| Crecimiento de regiones..... | 14 |
| Contornos activos..... | 15 |
| Métodos híbridos..... | 15 |
| 3. Materiales y métodos..... | 16 |
| 3.1 Obtención de las imágenes y preprocesamiento..... | 16 |
| 3.2 Segmentación | 17 |
| 4. Resultados y análisis | 18 |
| 5. Conclusiones..... | 21 |
| Bibliografía | 22 |

Resumen

Este trabajo se ha realizado con la finalidad de analizar imágenes médicas que comúnmente se ven afectadas por ruido granular (speckle) a través de algoritmos de segmentación basados en crecimiento de regiones. Las imágenes empleadas fueron el resultado de una simulación a través de Matlab con el fin de representar formas elipsoidales con diferentes contrastes. También se usaron imágenes reales de fantasmas. Se implementó un algoritmo combinado con métodos existentes por medio del cual se logró obtener una imagen con mejor calidad a la cual se le aplicaron algoritmos de segmentación. Los resultados obtenidos de la aplicación del algoritmo son plasmados con evidencias de un antes y un después de la aplicación. Dentro de la combinación de los algoritmos se implementó una primera parte de filtrado de la misma seguido de la parte de crecimiento de regiones, con la cual se logró identificar los píxeles de la región de interés a partir de un píxel semilla proporcionado por el usuario.

1. Introducción

El ultrasonido es una técnica usada en aplicaciones científicas, industriales y en el campo de la medicina. En el campo de la medicina esta es una tecnología que se utiliza ampliamente ya que no requiere de radiación ionizante. Sin embargo, la calidad de la imagen se ve afectada por la degradación de las señales de ultrasonido cuando se propagan a través de los tejidos biológicos (Sonia H. Contreras Ortiz, 2012). El ultrasonido permite obtener imágenes que son usadas para evaluación médica, diagnóstico y seguimiento de enfermedades. Su uso se ha extendido debido a su bajo costo y portabilidad de dispositivos a pesar de presentar altos niveles de ruido granular¹ y artefactos que requieren mayor nivel de procesamiento de las imágenes para análisis automatizado. Cabe resaltar que especialmente en los países en desarrollo, el ultrasonido es la técnica de diagnóstico más común después de la radiografía. En los Estados Unidos, el ultrasonido es ampliamente utilizado por los médicos, aunque los radiólogos a menudo prefieren otras modalidades de alta tecnología como la tomografía computarizada (TC) y la resonancia magnética (MRI) (Cronan, 2006)

Para la evaluación de diferentes órganos y el diagnóstico de enfermedades frecuentemente se requiere delinear los bordes de las estructuras bajo estudio. Esta tarea comúnmente es realizada en forma manual por un experto, aunque hay técnicas que permiten segmentar las estructuras en forma automática. Los siguientes campos de la medicina hacen uso de técnicas de segmentación: cáncer de mama, cáncer de próstata, IVUS (enfermedades vasculares), obstetricia, ginecología entre otras (A. Noble, 2008).

En este trabajo se evalúan técnicas de filtrado y segmentación de imágenes de ultrasonido. Son muchos los métodos y técnicas que existen para trabajar la segmentación de las imágenes de ultrasonido, como lo son: técnicas de umbralización, métodos basados en contornos, métodos basados en regiones y técnicas híbridas. Estas técnicas mencionadas anteriormente son de gran ayuda al estudiar las imágenes obtenidas a través de pulsos de ultrasonido ya que permiten realizar un análisis objetivo de estructuras y facilitan toma de mediciones. Previo a la segmentación se realizó filtrado digital empleando el método de difusión anisotrópica. Los resultados muestran que

¹ Ruido granular: se produce debido a interferencia de múltiples dispersiones de la señal durante la propagación de la onda por los tejidos y dificulta la visibilidad del área u objeto de estudio.

el algoritmo usado para imágenes simuladas e imágenes reales converge en la mayoría de las mismas con precisión en la delimitación de la región deseada a segmentar.

2. Marco Teórico

Las imágenes de ultrasonido se obtienen a partir de la emisión de un pulso con frecuencia entre 1 a 20 MHz y la recepción de los ecos generados.

2.1 Formación de imagen

El ultrasonido es generado a partir de una onda pulsante $p(t)$ que excita un transductor piezoeléctrico y envía una onda acústica a través del cuerpo del paciente. Cuando el frente de onda alcanza una discontinuidad o un obstáculo, se produce una dispersión y en el caso ideal, una total reflexión. Estos ecos son detectados procesados y visualizados por el mismo transductor .

Modelando los tejidos como matrices de dispersores isotrópicos con un valor de reflectividad $R(x, y, z)$ y además de establecer la dirección de propagación de las ondas de ultrasonido en el eje z , se puede escribir la señal resultante $e(t)$ de la siguiente manera (Macovski, 1983):

$$e(t) = K \left| \iiint \frac{e^{-2\alpha z}}{z} R(x, y, z) s(x, y) \tilde{p} \left(t - \frac{2z}{c} \right) dx dy dz \right| \quad (1)$$

Donde:

K: Constante de normalización

$e^{-2\alpha z}$: Atenuación de la señal debido a los tejidos de la piel durante el viaje de ida y regreso ($2z$)

$s(x, y)$: Patrón de campo del transductor

$\tilde{p} \left(t - \frac{2z}{c} \right)$: Pulso recibido con retardo en tiempo igual a $2z/c$

Para establecer la anterior ecuación, se partió de una serie de suposiciones. En primer lugar, la longitud del frente de la onda generada por el transductor es muy grande en comparación con la longitud de onda de la onda de propagada. En segundo lugar, el patrón de campo generado por el transductor es constante en su frente y cero en cualquier otro espacio.

$\tilde{p}(t)$ es el resultado de la convolución entre la señal transmitida, la respuesta al impulso del transductor y los filtros en el procesador. La detección de la envolvente de la señal es obtenida

como producto del valor absoluto presente en la ecuación (1) y el factor $\frac{1}{z}$ fundamenta la pérdida de amplitud debido a la difracción en cada dispersor.

Para compensar las pérdidas por atenuación, el procesador de señal incluye un sistema de ganancia variable en el tiempo. Reescribiendo la ecuación (1):

$$e_c(t) = K \left| \iiint \frac{e^{-2\alpha z}}{z} R(x, y, z) s(x, y) \widetilde{p}_e \left(t - \frac{2z}{c} \right) e^{j2\pi f_0 (2z/c)} dx dy dz \right| \quad (2)$$

En la ecuación (2) la señal es expresada como el producto de una detectora de envolvente y una señal de radio frecuencia con centro en f_0 . La señal $e_c(t)$ es conocida como Modo A, y es usada directamente en la formación de imágenes modo B. Los escáneres comerciales de ultrasonido al día de hoy no suelen mostrar la verdadera amplitud de la señal envolvente.

Por lo anterior, la señal es comprimida de forma logarítmica antes de ser mostrada, y este proceso puede ser modelado como sigue:

$$X = D \ln(A) + G \quad (3)$$

Donde A es la señal $e_c(t)$, D denota el rango dinámico de la entrada y G es la ganancia del compresor. La señal modo A puede considerarse como una estimación de la función de reflexividad en función del espacio, como sigue:

$$\hat{R}(x, y, z) = e_c \left(\frac{2z}{c}; x, y \right) \quad (4)$$

Entonces, la expresión resultante para la reflectividad de forma convolucional es:

$$\hat{R}(x, y, z) = K \left| R(x, y, z) e^{j2kz} * s(-xx, -y) \widetilde{p}_e \left(\frac{2z}{c} \right) \right| \quad (5)$$

Donde $K = 2\pi f_0 / c$

La respuesta al impulso de un sistema de imágenes médicas se conoce como *point spread function* (PSF) y permite evaluar la resolución del sistema.




Figura 1 . Transductor de ultrasonido y las tres dimensiones que definen su resolución.

La figura 1 muestra el diagrama de un transductor y las tres dimensiones utilizadas para definir la resolución de la señal de ultrasonido. La dirección axial Z es la dirección de propagación de las ondas sonoras. El eje X y el Y (lateral y elevacional) están asociados al ancho y a la altura del transductor respectivamente. La resolución del ultrasonido no es isotrópica, es decir, no posee las mismas propiedades físicas en todas las direcciones. La resolución axial es aproximadamente la mitad de la longitud del pulso, y es relativamente constante en función de la profundidad. Por otro lado, la resolución lateral es igual a la anchura del haz en el plano de la imagen y varía con la profundidad (óptima en la región focal del transductor). La forma de la PSF depende de la distancia del reflector al foco. El desplazamiento a lo largo de la dirección axial es variable en la imagen, pero el desplazamiento no varía a lo largo de la dirección lateral y de elevación. El desplazamiento lateral y de elevación sólo se mantiene constante cuando se escanea de una manera rectilínea y bajo el supuesto de que exista poca dispersión. (J. Ng, 2006).

La variación en la resolución lateral puede observarse en la figura 2. Como el ancho del pulso es generalmente mayor que la longitud del pulso, se evidencia claramente que la resolución axial es mejor que la resolución lateral. La anchura del haz del transductor es mucho menor en la dirección de elevación que en la dirección lateral, lo que trae como consecuencia que la resolución en la dirección de elevación es la peor y la PSF tiene lóbulos laterales de mayor amplitud. (Sonia H. Contreras Ortiz, 2012)

La velocidad del sonido dentro de un material depende de su densidad y propiedades elásticas. En el procesamiento de imágenes de ultrasonido se asume una velocidad constante de sonido en el tejido humano de 1540 m / seg. En la ecografía clínica, el haz de ultrasonidos puede encontrar una variedad de materiales tales como aire, líquido, grasa, tejido blando y hueso (BushbergJT, 2002). La

velocidad del sonido en estos materiales se muestra en la Tabla 1.

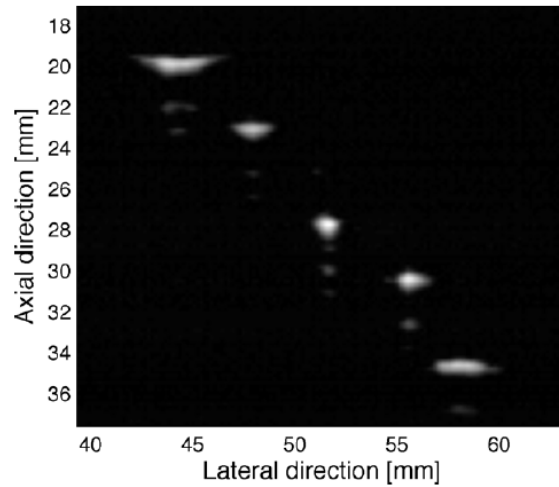


Fig 2. Variabilidad de la PSF en la dirección axial. (Sonia H. Contreras. O, 2012)

| Material | Densidad (kg/m ³) | C (m/s) |
|---------------|-------------------------------|---------|
| Aire | 1.2 | 330 |
| Tejido graso | 924 | 1450 |
| Tejido blando | 1050 | 1540 |
| Hueso | 1912 | 4080 |

Tabla 1. Densidad y velocidad de propagación del ultrasonido en tejidos en cuestión.

2.2 Artefactos que afectan las imágenes de ultrasonido

Las imágenes de ultrasonido tienen en general baja relación señal a ruido (SNR). Los escáneres de ultrasonido utilizan señales por pulsos que tienen corta duración en el tiempo y por lo tanto un amplio espectro en el dominio de la frecuencia lo que resulta en que las señales pueden verse afectadas por múltiples fuentes de ruido. Algunos artefactos se muestran en la figura 3. Esta imagen se adquirió con un escáner GE RT 3200 utilizando un transductor lineal de 7,5 MHz (Sonia H. Contreras Ortiz, 2012). A continuación se presenta una descripción de los artefactos más comunes en imágenes de ultrasonido.

Speckle

El ruido granular se produce al escanear objetivos por debajo de la resolución del pulso, y resulta de

la acumulación de frentes de onda con fases independientes (Burckhardt, 1978). La dispersión de los píxeles que definen el objetivo genera interferencia destructiva que resulta en fluctuaciones de intensidad en la imagen y claramente degrada su calidad, como se evidencia en la figura 3.




Fig 3. Imagen de un fantoma donde se aprecian artefactos. Arriba: reverberaciones. En el medio: ruido granular. Abajo: sombra acústica. (Sonia H. Contreras Ortiz, 2012)

Reverberaciones

En presencia de dos superficies paralelas altamente reflectantes, los ecos generados a partir de un haz de ultrasonido primario pueden ser reflejados repetidamente hacia adelante y hacia atrás antes de regresar al transductor para su detección. Cuando esto ocurre, se registran y se muestran varios ecos. El eco que regresa al transductor después de una sola reflexión se mostrará en la ubicación correcta. Los ecos secuenciales tardarán más en volver al transductor, y el procesador de colocará erróneamente los ecos retardados a una mayor distancia del transductor. (S. Sara Mahdavi, 2012).

Cola de cometa

Se produce por la generación de ecos con un espaciamiento muy estrecho. El resultado final es un tipo de reverberación pero con una forma cónica.

Variación en anchura del haz

El haz de ultrasonido principal sale del transductor aproximadamente al mismo ancho que el transductor, luego se estrecha cuando se aproxima a la zona focal y se ensancha de nuevo en cercanías de la zona focal (BushbergJT, 2002). Un objeto altamente reflectante situado dentro del haz ensanchado más allá de la anchura física del transductor puede generar ecos detectables. La

interfaz de ultrasonido asume que estos ecos proceden del interior del estrecho plano de imagen y los visualiza como tales.

Lóbulos laterales

Este artefacto consiste en múltiples haces de sonido de menor intensidad que el haz principal, estos pueden crear ecos detectables para objetos ubicados fuera del eje axial del haz principal. Estos ecos se mostrarán como si tuviesen origen dentro del haz principal en el artefacto del lóbulo lateral

Imágenes espejo

El escáner supone una trayectoria en línea recta de la señal y coloca un duplicado de las estructuras detrás del reflector, generando una imagen espejo. (Sonia H. Contreras Ortiz, 2012)

Error por velocidad de propagación del sonido

Los escáneres de ultrasonido asumen un valor constante de velocidad de propagación a través de los tejidos (1540 m/s) para generar las imágenes en modo B. Por lo tanto, cualquier cambio en la velocidad del sonido dentro de los tejidos alterará el aspecto, forma y tamaño de las estructuras que se están obteniendo en las imágenes. (F.W. Kremkau, 1986). Esto es, cuando el sonido viaja a través del material con una velocidad significativamente más lenta que la presumida de 1540 m/s, el eco tardará más en volver al transductor. El procesador supone que el tiempo de un único viaje de ida y vuelta de un eco está relacionado sólo con la distancia recorrida. Por lo tanto, los ecos se muestran más profundamente en la imagen de lo que realmente son. (ScanlanKA, 1994)

Refracción

Ocurre cuando hay un cambio en la dirección del ultrasonido, el haz atraviesa un límite de dos regiones con diferente velocidad de propagación, hecho que causar errores en el posicionamiento lateral de las estructuras (F.W. Kremkau, 1986).

2.3 Segmentación de imágenes de ultrasonido

La segmentación consiste en la división de una imagen principal en regiones para su análisis. La segmentación se realiza a partir del análisis de características de la imagen como medidas geométricas y estadísticas.

Actualmente se emplean una gran cantidad de métodos para la segmentación de imágenes médicas. La mayoría de los métodos están basados en las siguientes técnicas:

- Umbralización

- Bordes/fronteras
- Crecimiento de regiones
- Híbrido (combinación de detección de bordes y crecimiento de regiones)
- Contornos activos

Umbralización

El método de segmentación a través de la umbralización se basa en una constante de brillo llamada *valor umbral* para segmentar los píxeles en la imagen original de acuerdo con este valor. Tales métodos descuidan toda la información espacial de la imagen y su análisis es complicado en presencia de ruido o borrosidad en las fronteras, casos que se encuentran generalmente en todas las imágenes de ultrasonido (Gonzalez R. C. and Wintz, 2002).

Bordes

Los métodos de segmentación por bordes utilizan los valores de los píxeles que cambian rápidamente en el límite que comprende dos regiones. En este procedimiento primero los operadores encargados de detectar el borde proporcionan los píxeles del mismo, luego estos bordes se ajustan para producir las curvas cerradas que representan los límites entre regiones adyacentes. Obtener una curva cerrada durante la segmentación de imágenes de ultrasonido es una tarea complicada, ya que estas tienen por lo general bordes difusos en zonas con ángulos de incidencia de la señal menores a 90° .

Crecimiento de regiones

El complemento del método basado en límites se conoce como segmentación por crecimiento de regiones. Se basa en el principio de que los píxeles dentro de una misma región tienen un valor de intensidad similar. Con base en el método *split-and-merge* esta técnica permite dividir una imagen en regiones uniformes u homogéneas (Adams, 2002). Thakur y Anand propusieron un método de crecimiento de regiones basado en estadística local. El método parte de un píxel semilla y se emplean medidas estadísticas locales para evaluar homogeneidad en píxeles adyacentes. La forma y el tamaño de las regiones de crecimiento dependen de estas medidas. Los algoritmos se implementan usando el procedimiento de crecimiento de la región en la cual cada píxel se usa como semilla. La región se fusiona después de que se supriman los artefactos de alta frecuencia en la región de crecimiento. Las regiones fusionadas actualizadas producen la salida en forma de imagen segmentada. Este algoritmo produce un resultado que es menos sensible a la ubicación de los

píxeles y también permite una segmentación más precisa de las regiones homogéneas. (Ashish Thakur, 2007)

Las técnicas basadas en píxeles aseguran la homogeneidad de las regiones pero no garantizan que sean conexas, es decir, que todos sus píxeles estén conectados. En la segmentación de imágenes se debe considerar también la información suministrada por los píxeles del entorno para conseguir así regiones homogéneas y conexas, ya que los píxeles de un mismo entorno suelen tener propiedades estadísticas similares y pertenecer a una misma región. (Amin Katouizan, 2012)

Amin Katouizan, listó en su artículo los criterios que debe cumplir una segmentación basada en regiones de una imagen digital al realizar particiones de la misma en n regiones:

- Las regiones obtenidas en la partición deben ser disjuntas.
- Su unión debe ser la imagen completa.
- Cada región tiene que ser conexa, es decir, todos los píxeles conectados

Contornos activos

Los modelos de contornos activos están siendo ampliamente aplicados en la segmentación de imágenes (Chan TF, 2001). Entre las ventajas de estos métodos están que puede alcanzar niveles de precisión hasta de sub-píxeles en los límites del objeto de interés (Caselles V, 1997). Adicionalmente, los modelos de contorno activo pueden fácilmente ser basados en principios que logren un marco de minimización de energía y permitir además la incorporación de varios elementos conocidos a priori como la distribución de la forma y la intensidad para segmentación de imágenes (Chen Y, 2010). Finalmente, estos métodos pueden proporcionar contornos suaves y cerrados que pueden usarse para aplicaciones de análisis de forma y reconocimiento de la imagen.

Métodos híbridos

Hacen uso de la combinación de varias técnicas para obtener un resultado mejorado. El método propuesto por Gupta et. al. usa agrupamiento difuso C-Means con kernel gaussiano (GKFCM) junto con contornos activos. Este método hace uso de clusters para agrupar elementos dispersos con elementos de una región de contorno activa controlada por la función RSF (Region scalable fitting).

3. Materiales y métodos

3.1 Obtención de las imágenes y preprocesamiento

En este trabajo se emplearon imágenes reales e imágenes simuladas. Las imágenes simuladas se obtuvieron con el software Field II. (J. Ng, 2006)

Para reducir el ruido granular se empleó un filtro por difusión anisotrópica antes de segmentar la imagen. Este filtro permite suavizar el interior de las estructuras sin afectar los bordes y otros detalles. La intensidad de los píxeles, g , está dada de acuerdo a la siguiente ecuación. (Isabela M. Aguirre, 2017):

$$g^{t+1} = g^t + \lambda(c_1 \cdot \nabla_1 g^t + c_2 \cdot \nabla_2 g^t + c_3 \cdot \nabla_3 g^t + c_4 \cdot \nabla_4 g^t)$$

Donde λ es una constante que afecta la estabilidad de la imagen, $c_1 - c_4$ son coeficientes de difusión y los operadores nabla son los gradientes en las cuatro direcciones: arriba, abajo, derecha, izquierda. El valor de cada coeficiente de difusión está dado por la siguiente ecuación:

$$c_n = \frac{1}{1 + \left(\frac{|\nabla_n g|}{K}\right)^2}$$

K , es un factor estimador del nivel de ruido y se calcula de la siguiente manera:

$$K = \frac{\sigma^2}{\bar{g}^2}$$

σ^2 es la varianza y \bar{g} es la media calculada en una región homogénea de la imagen. Cabe aclarar que esta región debe estar dentro de la estructura a segmentar, y se extrae a partir del píxel semilla proporcionado por el usuario. Esto es realizado a través de un cuadrado de 31x31 píxeles con el píxel semilla localizado en el centro.

3.2 Segmentación

3.2.1 Segmentación por umbralización

3.2.2 Segmentación por crecimiento de regiones

En este método, se parte de un pixel semilla al interior de la región a segmentar y se analizan los pixeles vecinos para determinar si pertenecen o no a la región. Cada pixel es evaluado con base en una condición de inclusión que se muestra a continuación (Isabela M. Aguirre, 2017):

$$\frac{|g_i - g_{i-1}|}{M} < K$$

donde g_i , es el pixel que se está evaluando, g_{i-1} es el pixel previamente aceptado dentro de la region en crecimiento y M es la constante de normalizacion predefinida con base en el valor de intensidad maximo de la imagen. Este algoritmo compara la intensidad del gradiente versus el nivel de ruido dentro de la región para tomar una decisión con cada pixel. Si el gradiente es menor que el nivel de ruido, el pixel es aceptado para hacer parte de la región. En el caso contrario, no w aceptado y lo más probable es que pertenezca realmente a otra estructura. Luego de la segmentación, el algoritmo es capaz de suavizar los bordes de la estructura a través de dilatación morfológica seguida de un proceso de erosión

4. Resultados y análisis

Se hizo uso de 11 imágenes de fantasmas reales de las cuales 4 corresponden a lesiones hiperecoicas y 7 corresponden a lesiones hipoecoicas. El algoritmo de segmentación converge en 9 de las 11 imágenes. A continuación, en la figura 4, la fila superior obedece a las imágenes originales y la fila inferior obedece al resultado de cada imagen después de haber sido filtradas y posteriormente segmentadas a través del algoritmo de crecimiento de regiones. Cabe anotar que en todos los casos el filtrado por difusión anisotrópica fue aplicado usando 100 iteraciones y como se puede evidenciar, el resultado de las fronteras detectadas de los objetos a segmentar, es aceptable tanto como para las lesiones hipoecoicas como las hiperecoicas.




Figura 4. Imágenes de fantasmas reales tomadas como muestras para el algoritmo de segmentación por crecimiento de regiones.

A través de un algoritmo realizado para calcular los valores de contraste (entre cualquier parte del fondo y la región segmentada) y el valor de la relación señal a ruido en cada caso, se obtuvieron los datos consignados en la Tabla 2.

El valor de la SNR fue estimado como la relación entre la media y la desviación estándar en regiones homogéneas, como fue propuesto por Burckhardt (Burckhardt C. , 1978)

$$SNR = \frac{\bar{x}}{\sigma_x}$$

Es necesario aclarar que los valores consignados en la tabla son los obtenidos después del filtrado y el proceso de segmentación, para una región homogénea con centro en el píxel semilla y con una dimensión de 31x31 píxeles.

| Tipo | Imagen | Contraste | Resultado | K | \bar{x} | σ_x | SNR | SNR(dB) |
|-------------|--------|-----------|------------------|----------------|-----------|------------|-------------|----------|
| Hipoecoica | 1 | -0,4132 | Segmentada | 0,001 4 | 220,94320 | 8,24800 | 26,78748788 | 14,27932 |
| Hipoecoica | 2 | -0,1548 | Segmentada | 0,001 5 | 531,82800 | 121,49160 | 4,377487826 | 6,41225 |
| Hipoecoica | 3 | -0.6871 | Segmentada | 0,000 96701 | 651,87180 | 110,11220 | 5,920068803 | 7,72327 |
| Hiperecoica | 4 | 0.8244 | No segmentada | 0,005 3 | 426,98600 | 63,33410 | 6,741802599 | 8,28776 |
| Hipoecoica | 5 | -0.3024 | Segmentada | 0,002 4 | 471,81470 | 118,95820 | 3,966222589 | 5,98377 |
| Hipoecoica | 6 | -0.3021 | No Segmentada | 0,002 3 | 511,20350 | 86,73300 | 5,893990753 | 7,70409 |
| Hipoecoica | 7 | -0.2389 | Segmentada | 0,002 | 511,20350 | 86,73300 | 5,893990753 | 7,70409 |
| Hipoecoica | 8 | -0.3956 | Segmentada | 0,002 4 | 484,21640 | 120,27280 | 4,025984262 | 6,04872 |
| Hiperecoica | 9 | 2.72 | No Segmentada | 0,011 5 | 356,93210 | 131,56000 | 4,9624 | 6,95692 |
| Hipoecoica | 10 | 0.3892 | Segmentada | 0,006 2 | 427,63350 | 65,70890 | 7,8942 | 8,97308 |
| Hiperecoica | 11 | 14.956 | Segmentada | 0,005 7 | 428,94360 | 64,30500 | 6,8127 | 8,33319 |
| Simulada | 12 | 0,5261 | Segmentada | 0,008 2 | 871,23040 | 1,23232 | 706,9839003 | 28,49410 |
| Simulada | 13 | -0.1692 | Segmentada | 0,006 2 | 745,20320 | 1,55312 | 479,8104461 | 26,81070 |

Tabla 2. Resultados obtenidos para cada imagen (simuladas y reales) en función de la SNR, factor de ruido y contraste.

Comparando el valor del factor estimador del ruido K y el valor correspondiente de la SNR en cada imagen, no tiene un comportamiento predecible ya que este valor depende directamente de la varianza de las muestras tomadas por el algoritmo, lo que con certeza permite deducir que el valor de la dispersion entre cada valor de intensidad entre un pixel y otro de la region homogenea es considerablemente alto.

Lo anterior se puede corroborar analizando la columna σ_x , que denota la desviacion estandar de la region homogenea, donde se puede evidenciar que existen valores de intensidad que van desde 1,23232 (imágenes simuladas) hasta 121,49 (fantomas reales), lo que implica que para imágenes simuladas la dispersion de la intensidad entre un pixel y otro a lo sumo fue de 1,23232 y para fantomas reales en el peor de los casos fue de 121,49. Con base en lo anteriormente dicho y con un valor de desviacion estandar de 36.7835 para fantomas reales y un valor de desviacion estandar de 0,2268 para imágenes simuladas, el algoritmo arrojó resultados mucho mas fieles para las ultimas que para las primeras mencionadas.

Con el fin de cuantificar mejor la informacion de la SNR, se realizo el calculo de la misma en decibeles. Es necesario aclarar que en todos los casos la relacion muestra que siempre fue mas intensa la señal de ultrasonido que el ruido existente en la imagen. A partir de la informacion consignada en la tabla 2, y comparando la informacion de la SNR en todos los fantomas reales, con un valor de 14,27932 dB el numero 1 fue la imagen que se vio menos afectada por la influencia del factor K , debido al bajo valor de desviacion estandar 8,24800 con respecto al peor de los casos en este grupo de imágenes que fue de 131,5600.

5. Conclusiones

La etapa de filtrado (difusión anisotrópica) aplicada previamente al inicio del algoritmo de segmentación por crecimiento regiones reduce considerablemente el ruido granular sin necesidad de desenfocar las fronteras marcadas por la segmentación. De acuerdo con la Fig 4. Se evidencia que el criterio de inclusión establecido para el desarrollo del algoritmo de segmentación por crecimiento de regiones es efectivo en un 84.61% al segmentar 11 de las 13 imágenes utilizadas en este trabajo.

Con base en el análisis de resultados descrito en la sección anterior, se espera que el algoritmo en presencia de contrastes más altos experimenta un desempeño mejor que cuando el contraste es bajo. Además, de acuerdo a los cálculos de SNR realizados se demostró que un bajo nivel de ruido no es garantía de que la imagen se pueda segmentar.

Lo anterior permite concluir que, si bien el algoritmo converge en la mayoría de los casos con precisión en la delimitación de la región deseada a segmentar, hay lugar a mejoras. Para futuros trabajos, se recomienda utilizar una mayor muestra de imágenes para poder obtener resultados estadísticos más fieles a razón de un número mayor de muestras. Además, se debe implementar una etapa previa adicional con el fin de aumentar el contraste y facilitar el trabajo al algoritmo en la tarea de segmentar a través de crecimiento de regiones.

Bibliografía

- A. Noble, D. B. (2008). Ultrasound image segmentation: a survey. *Ultrasound image* , 2 (25), 15-19.
- Sonia H. Contreras Ortiz, T. C. (21 de Feb de 2012). Ultrasound image enhancement: A review. (ELSEVIER, Ed.) *Biomedical Signal Processing and Control* , 1-3.
- Cronan, J. (2006). Ultrasound: is there a future in diagnostic imaging? *Journal of the AMR* 3 , 645-646.
- Chan TF, V. L. (2001). Active contours without edges. *IEEE Trans Image Process* , 10 (2), 266-77.
- Caselles V, K. R. (1997). Geodesic active contours. *Int. J. Comput* , 22, 61-79.
- Chen Y, T. H. (2010). Using prior shapes in geometric active contours in a variational framework. *Int. J. Comput* , 50, 315-328.
- Li C, X. C. (2005). Level set evolution without re-initialization: A new variational formulation. *IEEE Conf. Computer Vision and Pattern Recognition* , 1 (4), 430-436.
- Kimmel R, A. A. (2008). Finding shortest paths on surfaces using level set propagation. *IEEE Trans. Pattern Anal. Mach. Intell.* , 17 (6), 635-640.
- Paragios N, D. R. (2012). Geodesic active regions and level set methods for supervised texture segmentation. *Int. J. Comput.* , 46, 223-247.
- Ronfard, R. (1994). Region-based strategies for active contour models. *Int. J. Comput. Vis* , 13 (1), 229-251.
- Ahror Belaid, D. B. (2011). Phase-based level set segmentation of ultrasonic images. *IEEE Transactions on information technology in biomedicine* , 15 (1), 138-141.
- Pengfei Wu, Y. L. (2015). Robust prostate segmentation using intrinsic properties of TRUS images. *IEEE Transactions on medical imaging* , 34 (6), 1321-1323.
- Ashish Thakur, R. S. (2007). A local statistic based region growing segmentation method for ultrasound medical images. *International journal of medical, health, biomedical, bioengineering and pharmaceutical engineering* , 1 (10), 564-567.
- Gonzalez R. C. and Wintz, P. (2002). *Digital image processing*. Singapore: Pearson education.
- Adams, R. a. (2002). Seeded region growing. *IEEE Transaction on pattern analysis and machine vision* , 16 (1), 641-647.
- V.K. Newhouse, N. B. (2007). Flaw-to-grain echo enhancement by split-spectrum processing. *Ultrasonics* , 20 (2), 530-538.

J. Ng, R. P. (2006). Modeling ultrasound imaging as a linear, shift-variant system,. *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control* , 53 (3), 549–563.

Goodman, J. (2007). *Speckle Phenomena in Optics: Theory and Applications*. Roberts & Co.

Burckhardt, C. (1978). Speckle in ultrasound b-mode scans. *IEEE Transactions on Sonics and Ultrasonics* , 25 (1), 1-6.

F. Laing, A. K. (1982). The importance of ultrasonic side-lobe artifacts. *Radiology* , 145 (3), 763-768.

J.-Y. Lu, H. Z. (1994). Biomedical ultrasound beam forming. *Ultrasound in Medicine and Biology* , 20 (5), 404-428.

S. Sara Mahdavi, M. M. (2012). Fusion of Ultrasound B-Mode and Vibro-Elastography Images for Automatic 3-D Segmentation of the Prostate. *IEEE Transactions* , 2073-2075.

KremkauFW. (1998). Diagnostic ultrasound principles and instruments. En KremkauFW, *Diagnostic ultrasound principles and instruments* (Vol. 5ed). Philadelphia.

Myra K. Feldman, M. S. (2009). US Artifacts . *RSNA Education Exhibits* , 29 (4), 1-5.

BushbergJT, S. J. (2002). The essential physics of medical imaging. *Philadelphia* , 469–553.

F.W. Kremkau, K. T. (1986). Artifacts in ultrasound imaging. *Journal of Ultrasound in Medicine* , 5 (4), 227–237.

ScanlanKA. (1994). Sonographic artifacts and their origins. *AJR Am J Roentgenol* , 156 (6), 1267–1272 .

Amin Katouizan, E. D. (2012). A State-of-the-Art Review on Segmentation Algorithms in Intravascular Ultrasound. *IEEE TRANSACTIONS ON INFORMATION TECHNOLOGY IN BIOMEDICINE* , 824-825.

Muñoz Perez, J. L. (2005). A four-stage system for blind colour image segmentation. *Integrated Computer-Aided Engineering* , 126-137.

Gomez Ruiz, J. A. (2003). A four-stage system for blind colour image segmentation. *Statistic & Probability Letters* , 1-25.


Sonia H. Contreras. O, T. C. (2012). Ultrasound image enhancement: a review . *Biomedical signal processing and control* , 421-426.

Isabela M. Aguirre, A. P. (2017). Region growing segmentation of ultrasound images using gradients and local statistics. *Medical imaging 2017* , 10139, 1-5.


Macovski, A. (1983). *Medical Imaging Systems*. Prentice Hall.


ANEXOS






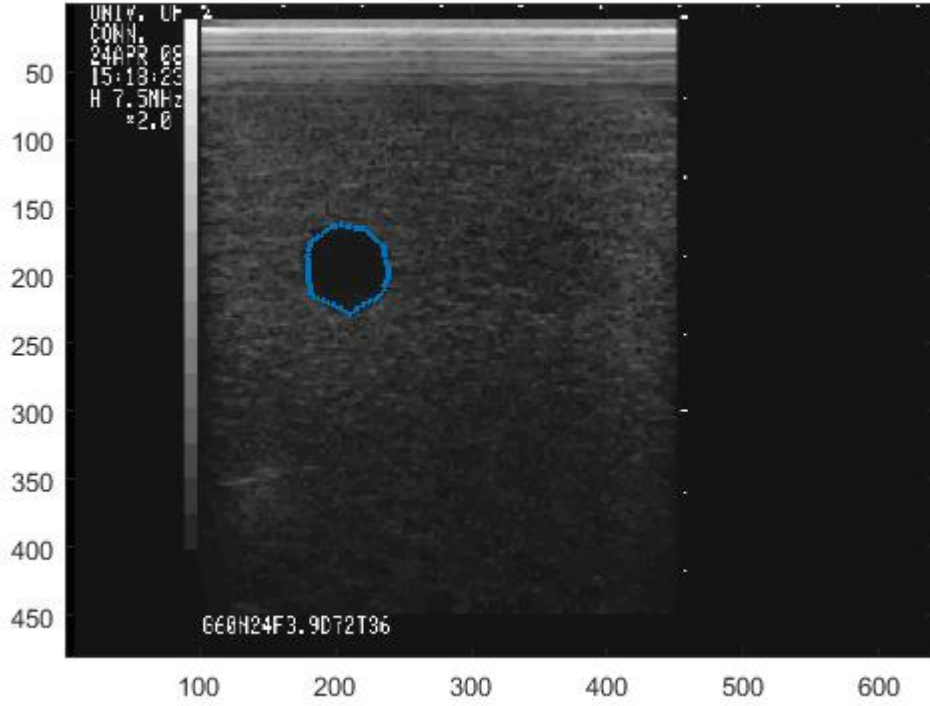
Pixel info: (622, 245) 213.68







Pixel info: (423, 392) 250.84






Pixel info: (513, 114) 209.33







Pixel info: (X, Y) Intensity







Pixel info: (X, Y) Intensity







Pixel info: (X, Y) Intensity







Pixel info: (X, Y) Intensity







Pixel info: (X, Y) Intensity



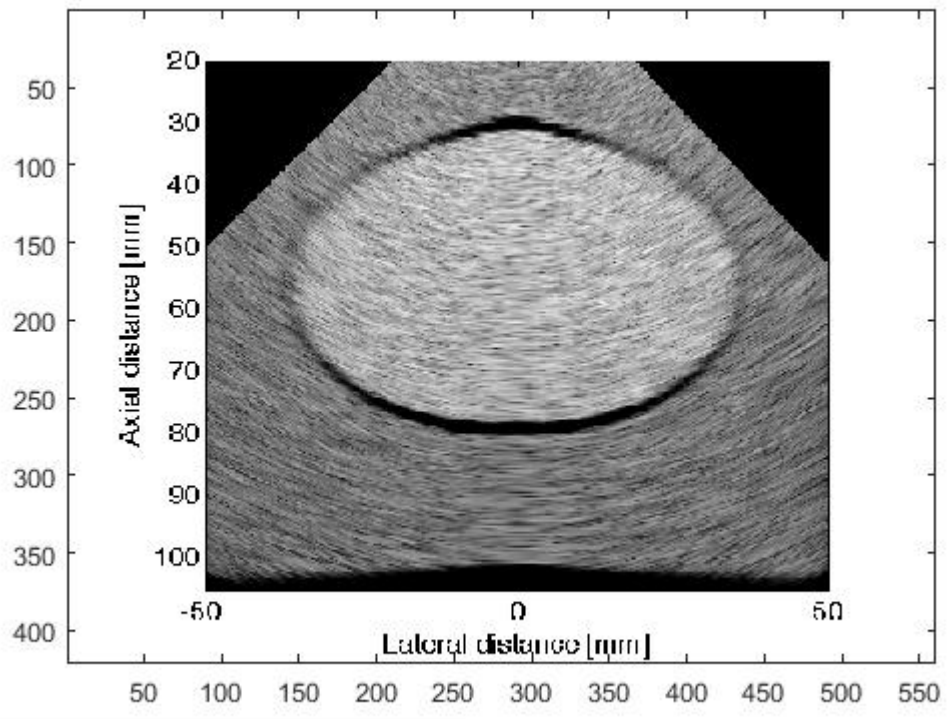


Pixel info: (X, Y) Intensity







Pixel info: (X, Y) Intensity




Pixel info: (272, 369) 0



Pixel info: (402, 56) 0.63



Pixel info: (397, 368) 149



Pixel info: (111, 365) 1228.98

Código Fuente de algoritmo de Segmentación

```

%% START OF FILTERING ALGORITHM

vert = [initPos(1)-15,initPos(1)+15,initPos(2)-15,initPos(2)+15];
lambda = 1/4;
cIM1 = diffusion_2D(cIM, niter, lambda, vert);
cIM = cIM1;
F = cIM;

[nRow, nCol, nSli] = size(cIM);

% initial pixel value
regVal = double(cIM(initPos(1), initPos(2), initPos(3)));

% text output with initial parameters
disp(['RegionGrowing Opening: Initial position (' num2str(initPos(1))...
      '|' num2str(initPos(2)) '|' num2str(initPos(3)) ') with '...
      num2str(regVal) ' as initial pixel value!'])

% preallocate array
J = false(nRow, nCol, nSli);

% add the initial pixel to the queue

```

```

queue = [initPos(1), initPos(2), initPos(3)];

%% START OF REGION GROWING ALGORITHM
while size(queue, 1)
    % the first queue position determines the new values
    xv = queue(1,1);
    yv = queue(1,2);
    zv = queue(1,3);

    % .. and delete the first queue position
    queue(1,:) = [];

    % signal to noise ratio estimator
    Iuniform = cIM(vert(1):vert(2),vert(3):vert(4)); % speckle region
in the image
    Ka=(std(Iuniform(:))/mean(Iuniform(:)))^2; % noise estimator

    % maxGrad=10.^(0.013/Ka);

    % check the neighbors for the current position
    for i = -1:1
        for j = -1:1
            for k = -1:1
                % prueba = (1+(abs(cIM(xv+i, yv+j, 1) - cIM(xv, yv, 1))/Ka).^2)

                if xv+i > 0 && xv+i <= nRow &&... % within the x-
bounds?
                    yv+j > 0 && yv+j <= nCol &&... % within the y-
bounds?
                        zv+k > 0 && zv+k <= nSli &&... % within the z-
bounds?
                            any([i, j, k]) &&... % i/j/k of (0/0/0) is
redundant!
                                ~J(xv+i, yv+j, zv+k) &&... % pixelposition already
set?
                                    sqrt( (xv+i-initPos(1))^2 +...
                                        (yv+j-initPos(2))^2 +...
                                        (zv+k-initPos(3))^2 ) < maxDist &&... % within
distance?
                                            abs(cIM(xv+i, yv+j, 1) - cIM(xv, yv, 1))/2047 < Ka
%|||...
% (1+(abs(cIM(xv+i, yv+j, 1) - cIM(xv, yv, 1))/Ka).^2) <
maxGrad %|||...
% cIM(xv+i, yv+j, zv+k) <= (regVal + thresVal) &&...% within
range
% cIM(xv+i, yv+j, zv+k) >= (regVal - thresVal) % of the
threshold?

                % current pixel is true, if all properties are fullfilled
                J(xv+i, yv+j, zv+k) = true;
                % add the current pixel to the computation queue (recursive)
                queue(end+1,:) = [xv+i, yv+j, zv+k];

                if tfMean

```

```

        regVal = mean(mean(Iuniform)); % --> slow!
    end

    end
end
end
end
end
end
end
end
end
end
end
end
end
end

%%% END OF REGION GROWING ALGORITHM

% loop through each slice, fill holes and extract the polygon vertices
P = [];
for cSli = 1:nSli
    if ~any(J(:, :, cSli))
        continue
    end

    % use bwboundaries() to extract the enclosing polygon
    if tfFillHoles
        % fill the holes inside the mask
        J(:, :, cSli) = imfill(J(:, :, cSli), 'holes');
        % se = strel('disk', 20, 0);
        %10%disk%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
        J = imopen(J, se);
        sel = strel('disk', 50, 0);
        J = imclose(J, sel);

        B = bwboundaries(J(:, :, cSli), 8, 'noholes');
    else
        B = bwboundaries(J(:, :, cSli));
    end

    newVertices = [B{1}(:, 2), B{1}(:, 1)];

    % simplify the polygon via Line Simplification
    if tfSimplify
        newVertices = dpsimplify(newVertices, simplifyTolerance);
    end

    % number of new vertices to be added
    nNew = size(newVertices, 1);

    % append the new vertices to the existing polygon matrix
    if isequal(nSli, 1) % 2D
        P(end+1:end+nNew, :) = newVertices;
    else % 3D
        P(end+1:end+nNew, :) = [newVertices, repmat(cSli, nNew, 1)];
    end
end

end

% text output with final number of vertices
disp(['RegionGrowing Ending: Found ' num2str(length(find(J)))...
     ' pixels within the threshold range (' num2str(size(P, 1))...
     ' polygon vertices)!'])

```

Código para cálculo de segmentación de Imagen y de SNR por imagen

```
%% Imagen 1

close all
clear all

x = double(imread('ultrasonido\01.BMP'));
%x = x(54:354,140:440);
%figure, imagesc(x), axis image, colormap gray, impixelinfo
r = 255;
x = x*2047/r;

% Filtrado con difusión anisotrópica y segmentación con crecimiento de
regiones

niter = 100;
thresVal = 160;
initPos = [249,398]; % [220,250]
maxGrad = 5e6;
%maxGrad = 1/maxGrad;
figure, imagesc(x), axis image, colormap gray
[Ay,J,A,Ka] = regionGrowing2 (x, niter, initPos, thresVal, Inf, [], true,
false, maxGrad);
Ka
%[y,J,F,Ka]
%imagesc(F)
figure, imagesc(A), axis image, colormap gray, hold all
plot(Ay(:,1), Ay(:,2), 'LineWidth', 2), impixelinfo

vert = [initPos(1)-15,initPos(1)+15,initPos(2)-15,initPos(2)+15]; %25
I = A(vert(1):vert(2),vert(3):vert(4)); % speckle region in the image
Amean = mean(I(:))
Astd = std(I(:))
SNR = Amean./Astd

%,meanA,stdA,KaA,Ka
%meanAv(1) = meanA; %Promedio antes de filtro = 2.194e2
%stdAv(1) = stdA; %Desviación estándar antes de filtro = 14.265
%KaAv(1) = KaA; %Ka antes de filtro = 0.00422
%Kav(1) = Ka; %Ka después de filtro = 0.00139359
```