



UNIVERSIDADE DA BEIRA INTERIOR
Engenharia

Segmentação de Massas em Ultrasons Peitorais usando Técnicas de Multiresolução

Jorge Rafael Mendes Rodrigues

Dissertação para obtenção do Grau de Mestre em
Engenharia Electrotécnica e de Computadores
(2º ciclo de estudos)

Orientador: Prof. Doutor António Manuel Gonçalves Pinheiro

Covilhã, Outubro de 2012

Dedicatória

Aos meus pais, pela paciência, pela dedicação sempre incansável e pelo apoio incondicional. Serão sempre o meu primeiro exemplo e o mais presente motivo do meu trabalho.

Ao meu irmão, para quem sempre tentei ser um exemplo.

Ao meu avós, especialmente para o meu avô Ovídio, pela educação e pelas lições de vida.

Aos meus irmãos da Desertuna, pelo companheirismo e amizade para a vida e por toda a ajuda sobre os obstáculos que fui encontrando ao longo do meu percurso acadêmico.

Agradecimentos

O meu sincero agradecimento ao meu orientador, o Prof. Doutor António Pinheiro, primeiro que tudo, pela disponibilidade imediata que apresentou para orientar, de forma valiosa, este trabalho. Tenho, ainda, a agradecer-lhe pela persistência e pela boa relação de trabalho, nem sempre fácil, durante todo o percurso que levou à conclusão desta dissertação.

Resumo

A imagem de ultrasons é uma ferramenta de diagnóstico importante e cada vez mais aplicada na detecção do cancro da mama. No entanto, este tipo de exame é, intrinsecamente, degradado por ruído e pelo baixo contraste, resultando em dificuldades na detecção de massas ou nódulos e, acima de tudo, na avaliação do seu tamanho e forma. Neste sentido, as técnicas de diagnóstico assistido por computador surgem como um factor de suporte importante para a análise deste tipo de imagem.

No presente trabalho, uma abordagem bifaseada para um método de segmentação de ultrasons mamários, totalmente automático, é apresentada. A primeira etapa procura realizar uma segmentação inicial da imagem, que permita a localização primária da Região de Interesse (ROI). A segunda parte foca-se na área definida na etapa anterior, tendo como objectivo a melhoria da resolução espacial da segmentação.

Na primeira etapa de segmentação, diversas técnicas de classificação binária são aplicadas para realizar a segmentação da imagem, utilizando características multiresolução para o descriptor de pixel - filtragem FIR passa-banda e difusão não linear e curvatura *scale-space* de alta escala. Estas técnicas de processamento de imagem são aplicadas para a redução da influência dos componentes de ruído inerentes aos ultrasons e, simultaneamente, recolher informação estrutural e estatística adequada para a segmentação das massas. Os dados são classificados usando Support Vector Machines e Análise Discriminante.

Na segunda fase, as máscaras obtidas a partir da segmentação inicial são dilatadas, produzindo uma área restrita que contém a ROI. Considerando apenas os pixels pertencentes a esta região, uma nova segmentação é executada, através do algoritmo AdaBoost, usando a difusão não linear e curvaturas de menor escala. Um algoritmo de contornos activos é, também, aplicado para melhorar os resultados da segmentação, sendo as máscaras da segmentação inicial utilizadas como contornos iniciais.

Os resultados finais confirmam a metodologia proposta como sendo uma solução promissora para a segmentação de massas em imagens de ultrasons da mama, revelando, em termos globais, bons resultados de acurácia - 97,58% (AdaBoost) e 97,70% (Contornos Activos) -, sensibilidade - 76,46% (AdaBoost) e 75,40% (Contornos Activos) - e de precisão - 87,26% (AdaBoost) e 87,51% (Contornos Activos).

Palavras-chave

Ultrasons Peitorais, Segmentação de Imagem, Difusão Não Linear, Filtragem FIR Passa-banda, Curvatura *Scale-space*, Support Vector Machines, Análise Discriminante, AdaBoost, Contornos Activos

Abstract

Breast ultrasound imaging is an important and increasingly applied diagnostic tool for breast cancer detection. However, this type of exam is intrinsically degraded by noise, resulting in a difficult detection of masses or nodules, and, most importantly, the evaluation of their size and shape. Computer-aided diagnosis arises as a major help factor, for the analysis of this type of medical imaging.

In this work, a two-stage approach towards a fully automated BUS segmentation method is presented. The first stage attempts an initial segmentation of the BUS image, used to track the ROI. The second part focuses on the area surrounding the ROI defined in the first stage, improving the spatial resolution of the segmentation.

In the first segmentation stage, several binary classification techniques are applied to perform image segmentation, using multi-resolution features to construct the pixel descriptor - FIR band-pass filtering and high scale non-linear diffusion and *scale-space* curvature. These processing techniques were chosen to reduce the influence of noise components that are inherent to ultrasound images and, simultaneously, select structural and statistical information suitable for the segmentation of masses. The data is classified using Support Vector Machines and Discriminant Analysis.

In the second stage, the masks obtained from the initial segmentation are dilated, yielding a restricted area containing the ROI. Considering only the pixels inside this region, a new segmentation task is performed. The images are classified using an AdaBoost classifier, using lower scale non-linear diffusion and *scale-space* curvature measures. Active contours are also used to improve the segmentation results, being the initial segmentation masks are used as initial contours.

Final results confirm the proposed methods as a promising solution for mass segmentation in BUS images, achieving good overall accuracy - 97.58% for (AdaBoost) and 97.70% (Active Contours) -, recall - 76.46% (AdaBoost) and 75.40% (Active Contours) - and precision - 87.26% (AdaBoost) and 87.51% (Active Contours) - results.

Keywords

Breast Ultrasound Images, Image Segmentation, Non-linear diffusion, Band-pass FIR Filtering, *Scale-space* Curvature, Support Vector Machines, Discriminant Analysis, AdaBoost, Active Contours

Índice

1	Introdução	1
1.1	Objectivos e descrição do trabalho	3
2	Estado de arte	5
2.1	Pré-processamento	5
2.2	Segmentação	7
2.2.1	Segmentação usando classificadores - Redes Neurais e Support Vector Machines	10
3	Descrição das metodologias	11
3.1	Técnicas de processamento de imagem - Descriptor de pixel	11
3.1.1	Difusão Não-linear	11
3.1.2	Filtragem Passa-banda	14
3.1.3	Curvatura <i>scale-space</i>	15
3.2	Métodos aplicados na segmentação de massas	17
3.2.1	Support Vector Machines	17
3.2.2	Análise Discriminante	19
3.2.3	AdaBoost	21
3.2.4	Contornos activos sem limiares	22
4	Segmentação de massas	25
4.1	Base de dados	25
4.2	Treino e aplicação dos classificadores	27
4.3	Métodos heurísticos para a seleção da ROI	28
5	Refinação da segmentação	33
5.1	Segmentação fina usando o algoritmo AdaBoost	33
5.2	Segmentação fina usando Contornos Activos	35
6	Resultados	37
6.1	Segmentação inicial	37
6.2	Segmentação fina	39
7	Considerações finais	45
	Bibliografia	47
A	Anexos	51

Lista de Figuras

1.1	Exemplo de imagem de ultrasons peitoral (modo B).	2
2.1	Organização do processo de diagnóstico assistido por computador.	5
3.1	Exemplo de resultado da difusão não linear (b), relativamente à imagem original (a).	13
3.2	Esquema da filtragem passa-banda.	14
3.3	Exemplo de resultado das filtrações passa-banda (b), relativamente à imagem original (a).	15
3.4	Exemplo de resultado do cálculo da curvatura no <i>scale-space</i> (b) e (c), relativamente à imagem original (a).	16
3.5	Contornos activos.	22
4.1	Base de dados (1).	25
4.2	Base de dados (2).	26
4.3	Base de dados (3).	27
4.4	Descriptor de pixel para a segmentação inicial.	29
4.5	Seleção dos pixels de treino para a segmentação inicial com SVM e AD.	30
4.6	Supressão de objectos ligados aos limites da imagem.	31
4.7	Abertura com recuperação da forma original.	31
4.8	Seleção de regiões com a maior área.	32
5.1	Seleção dos pixels de treino para a segmentação fina com AdaBoost.	34
5.2	Restrição da área da classificação com o algoritmo AdaBoost.	35
6.1	Exemplo de resultados (1).	41
6.2	Exemplo de resultados (2).	42
6.3	Exemplo de resultados (3).	43
6.4	Exemplo de resultados (4).	44

Lista de Tabelas

6.1	Resultados segmentação inicial.	37
6.2	Resultados seleção maior área.	38
6.3	Resultados abertura	38
6.4	Resultados globais dos métodos de segmentação fina.	39

Lista de Acrónimos

AD	Análise Discriminante
BUS	Ultrasons Peitorais (Breast Ultrasound)
SVM	Support Vector Machines
RN	Redes Neurais
ROI	Região de Interesse

Capítulo 1

Introdução

O cancro da mama é a causa de morte com maior prevalência nas mulheres, tendo sido registado, globalmente, como um dos quatro tipos de cancro com maior taxa de mortalidade. Em 2008, foram estimadas, pela Organização Mundial de Saúde (OMS), 458 000 mortes associadas ao cancro da mama, com um total de 1 384 milhões de novos casos diagnosticados [DCSJ10, LBL⁺05, SFC⁺06]. Nas últimas décadas, tem-se assistido a um aumento da incidência de novos casos. Por outro lado, tem-se assistido a uma redução gradual da taxa de mortalidade relacionada com o cancro da mama. Esta redução, apesar de generalizada, verifica-se especialmente em países mais desenvolvidos e com maior poder económico, onde os meios de diagnóstico se encontram mais divulgados e são mais aplicados, dado que a deteção precoce desempenha um papel fulcral no tratamento, com êxito, deste tipo de patologias [DCSJ10, LBL⁺05, SFC⁺06]. Constata-se, portanto, uma necessidade crescente de desenvolvimento e aplicação de novos meios de diagnóstico, na deteção precoce e na monitorização de novas ocorrências.

O diagnóstico do cancro da mama poderá recorrer a diversas técnicas. Desde logo, os exames físicos como a palpação, bem como a análise do historial clínico e dos factores de risco associados ao paciente, surgem como os métodos mais tradicionais e mais aplicados. Outras ferramentas de apoio ao diagnóstico têm sido introduzidas ao longo do tempo, como sejam os métodos imagiológicos - Ressonância magnética, mamografia e ultrasons - ou a biópsia, sendo esta aplicada, normalmente, apenas como último recurso ou como exame complementar para a confirmação do diagnóstico. De entre estas, a mamografia e os ultrasons são os mais frequentemente usados como exames complementares.

Actualmente, a mamografia é extensivamente aplicada na avaliação de casos assintomáticos. A mamografia perfila-se como um instrumento útil na deteção de microcalcificações, conseguindo um desempenho superior ao dos ultrasons. Apesar deste facto, a interpretação das mamografias pode ser difícil para os radiologistas, levando a uma taxa elevada de falsos positivos submetidos a biópsia. Além de ser um método altamente invasivo, desconfortável e caro, a taxa de obtenção de resultados positivos através da utilização da biópsia é baixa, situando-se entre os 10% e os 31% [CWM⁺03], o que torna este procedimento evitável.

As imagens de diagnóstico por ultrasons são adquiridas através do uso de ondas acústicas longitudinais, com frequências situadas, tipicamente, entre 1MHz e 20MHz [HR02, ES08]. As imagens obtidas representam a medida da reflexão das ondas ultrasonoras por parte dos tecidos onde estas incidem.

A sonografia permite a representação de estruturas corporais, com base na sua densidade ou nas suas propriedades elásticas. Consoante o modo de tratamento dos dados recolhidos pelo transdutor, é possível definir três tipologias principais, que resultam em diferentes âmbitos de análise da informação.

O modo A representa, graficamente, a amplitude da onda recebida em função do tempo. Sendo o modo mais básico de utilização dos ultrasons, é aplicado na caracterização de superfícies. A

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

relação tempo-distância pode ser, também inferida por este modo, sendo calculada dividindo a velocidade de propagação das ondas ultrasonoras por 2 (propagação em direção ao tecido alvo e de volta ao transdutor).

O modo B é o modo mais comum de aplicação de ultrasons, especialmente no que toca à medicina e permite a visualização de imagens bidimensionais. No caso concreto do diagnóstico de lesões mamárias, este modo é amplamente utilizado e é, por esse motivo, sobre este tipo de imagens que o presente trabalho se debruça. A amplitude recebida é traduzida em intensidade, para uma dada localização do tecido alvo. As interfaces entre tecidos com diferentes impedâncias apresentam intensidade superior à registada em zonas com impedâncias semelhantes, como sejam regiões internas de um dado órgão ou estrutura, por exemplo. A figura 1.1 apresenta um exemplo de um exame de ultrasons em modo B.




Figura 1.1: Exemplo de imagem de ultrasons peitoral (modo B).

Finalmente, o modo M é utilizado para a descrição de estruturas em movimento, quer pela representação das estruturas em função do tempo, quer pela medição da frequência do sinal - imagens Doppler. Este modo de aplicação de ultrasons é extensivamente aplicado em cardiologia, nomeadamente, em ecocardiografias e na análise do fluxo vascular. Normalmente, os resultados de exames em modo M são apresentados sobre exames em modo B, o que permite a localização de estruturas de interesse.

Contrariamente à mamografia, a ultra-sonografia não utiliza radiação ionizante, é uma técnica não invasiva e praticamente inofensiva. Além disso, o equipamento de ultrassom é portátil, de baixo custo e permite o diagnóstico em tempo real. Por estas características, os ultrasons têm sido aplicados como um método valioso para a deteção e caracterização precoce de nódulos mamários, com particular incidência em mulheres jovens ou grávidas. Este tipo de exame revela, também, melhores resultados comparativamente à mamografia, no que toca à triagem de mulheres com tecidos mamários densos.

Não sendo aplicáveis, de forma extensiva, ao rastreio precoce para o cancro da mama, dada a sua inconsistência na deteção de sinais primordiais de cancro, como sejam as microcalcificações, os ultrasons assumem grande relevância em exames regulares, tendo sido demonstrado que o uso deste método, como procedimento complementar para a mamografia, aumenta a

sensibilidade de 74% a 97% [CWMC05, LMF+00, BSGRH04, HJCM07, TLC+10]. Os ultrasons são, ainda, considerados como sendo a melhor modalidade para a análise de nós linfáticos [BMCB+02], e foram vistos como a melhor maneira de distinguir se o nó é sólido ou contém líquido [LMF+00, BSGRH04, CKC+02, SaMRH+04, TLC+10], atingindo uma precisão próxima de 100% em imagens observadas por radiologistas experientes. Para além das suas características atractivas, no que concerne à segurança e conforto na utilização, os ultrasons permitem o acesso a imagem tridimensional, fornecendo informação de difícil obtenção, podendo ajudar a reduzir o recurso a biópsias desnecessárias [ZLL+07, SaMRH+04, CCK+05, CCC+05, CCCM03].

Contudo, os ultrasons apresentam, tipicamente, baixo contraste na escala de cinzas e elevada quantidade de ruído de alta frequência, intrínsecos ao processo de aquisição da imagem. De igual modo, o aparecimento de sombras e outros artefactos são, também, comuns neste método imagiológico, degradando a qualidade da imagem. Na análise de ultrasons, verifica-se uma elevada subjectividade na distinção entre tecidos benignos e malignos, levando à necessidade de radiologistas experientes. Por estes motivos, a introdução de técnicas de Diagnóstico Assistido por Computador (DAC) tornou-se um factor importante, no apoio ao diagnóstico de patologias mamárias.

1.1 Objectivos e descrição do trabalho

O presente trabalho propõe um método completamente automatizado para a segmentação de massas em imagens de ultrasons peitorais. As metodologias implementadas aplicam diferentes técnicas de processamento de imagem e de segmentação, com o intuito de obter os contornos de massas presentes neste tipo de exames.

O método proposto subdivide-se em duas fases, de modo a responder às especificidades dos ultrasons e conseguir uma segmentação correcta e precisa. Numa primeira fase, o objectivo do trabalho passa por obter uma segmentação inicial, através da aplicação de classificadores sobre os pixels da imagem. O uso de classificadores baseia-se na extração de descritores de pixel, contruídos com o recurso a técnicas de processamento que permitam, simultaneamente, melhorar a qualidade da imagem, fundamentalmente, através da redução da influência do ruído, e evidenciar características significantes da imagem, homogeneizando regiões da imagem ou melhorando o contraste nos limiares.

Neste sentido, são utilizadas a difusão não linear, a filtragem passa-banda com filtros FIR e a curvatura obtida em diferentes escalas da imagem original. O resultado destes processamentos vai permitir a definição de um descriptor de pixel. Usando este descriptor, são testados vários classificadores distintos - Support Vector Machines (SVM) e Análise Discriminante (AD) - para segmentar as imagens, resultando em máscaras binárias. Sobre os resultados destes classificadores, uma série de métodos heurísticos são aplicados, com o objectivo de seleccionar a Região de Interesse (ROI) e evitar o eventual ruído das segmentações com os classificadores, preparando estes resultados para a segunda fase do método.

Na primeira fase, no caso da difusão não linear e da curvatura, a imagem será analisada em escalas altas, o que permite uma maior redução do ruído da imagem. Juntamente com a diminuição do nível de pormenor, dever-se-á favorecer o treino dos classificadores, tendo em vista a localização correcta da ROI e a redução do ruído na segmentação pelos classificadores. Contudo, esta opção acarreta a perda de definição espacial dos resultados.

Na segunda fase do método proposto no presente trabalho, a imagem é sujeita a novo processo

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

de segmentação, sendo este focado na ROI detectada na primeira fase. O principal objectivo desta segunda fase passa por melhorar a resolução espacial dos resultados iniciais. Para tal, e tendo em conta que este novo estágio será mais focado numa região mais reduzida que contém a ROI, a análise da imagem é feita em escalas mais baixas, que permitem a melhoria dessa resolução. As técnicas testadas na segmentação fina da ROI são o classificador AdaBoost, usando um descriptor de pixel composto pela difusão não linear e pela curvatura em escalas mais baixas da imagem, e o método de contornos activos sem limiares. De forma semelhante ao realizado na primeira fase, são também usados métodos heurísticos para a melhoria dos resultados finais.

Neste trabalho, e focando os objectivos definidos, apenas são utilizados exemplos de exames contendo massas. Todas as implementações necessárias ao desenvolvimento deste trabalho, em termos experimentais, são efectuadas com o *software* MATLAB R2011b, da MathWorks.

Além desta introdução, o trabalho encontra-se, essencialmente, dividido em cinco capítulos. No capítulo 2, é apresentado o estado de arte, onde são descritas as aplicações mais relevantes, no que concerne ao processamento e segmentação de ultrasons mamários. No capítulo seguinte, são descritas todas as técnicas utilizadas no trabalho, cujo fluxo e esquematização se encontra no capítulo 4. Seguidamente, no capítulo 5 são apresentados e discutidos os resultados experimentais deste trabalho, culminando numa análise sumativa e conclusiva, constante do sexto e último capítulo da presente dissertação.

Capítulo 2

Estado de arte

O processamento de imagem envolve várias técnicas, que poderão visar o melhoramento da qualidade de imagem, a extração de características úteis à análise e classificação da mesma ou a identificação de regiões de interesse. Os métodos utilizados neste campo são vastos e variados e a sua seleção e aplicação influenciam, no caso concreto da imagem médica, a qualidade do diagnóstico final. Por sua vez, a especificidade das imagens e das próprias patologias, bem como os recursos computacionais disponíveis, condicionam a escolha das técnicas de processamento e os resultados obtidos. O processamento de imagem, no âmbito dos sistemas de apoio ao diagnóstico, poderão ser enquadrados em diferentes etapas, com objectivos distintos: pré-processamento, segmentação, extração de características e desenvolvimento de descritores e a classificação da informação.

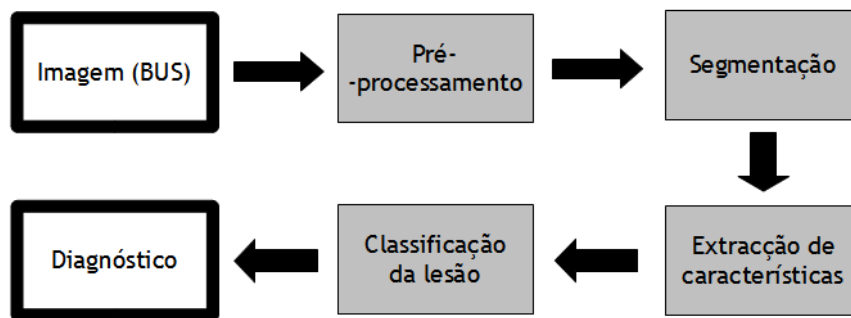


Figura 2.1: Organização do processo de diagnóstico assistido por computador.

No interesse deste trabalho, serão descritos, nesta secção, vários métodos e o seu âmbito de aplicação, no pré-processamento e segmentação de imagens de ultrasons mamários.

2.1 Pré-processamento

As técnicas de pré-processamento procuram melhorar a qualidade da imagem, reduzindo o ruído e homogeneizando regiões da imagem, sem perda de características e informação necessária à análise da imagem. Outro dos aspectos fundamentais das técnicas aplicadas ao pré-processamento de imagem consiste no realce de características importantes, como os contornos ou texturas, bem como a melhoria do contraste.

Filtragem

Os filtros lineares são o tipo mais simples de filtros, sendo de fácil implementação e apresentando bons resultados na remoção de ruído gaussiano. Os filtros médios são exemplo de filtragem linear. São muito utilizados para suavização da imagem. Este filtro opera sobre a

imagem atribuindo, a cada pixel, o valor médio da intensidade na vizinhança, o que promove a homogeneidade da imagem e elimina a sobre-segmentação. Contudo, a aplicação deste tipo de filtro destrói a informação de arestas da imagem, à semelhança da generalidade dos filtros lineares. Os filtros médios adaptativos procuram responder a esta limitação, removendo o ruído localmente e preservando as arestas.

Um dos filtros lineares mais aplicados no processamento de imagem é o filtro gaussiano. Sendo caracterizado por uma curva gaussiana, comporta-se como um filtro passa-baixo, o que permite remover componentes de alta frequência, como sejam o ruído característico dos ultrasons. A filtragem gaussiana permite a análise em scale-space. Cada filtragem sobre a imagem aumenta a escala, eliminando pormenores e simplificando a constituição estrutural da imagem. Apesar de reduzir o fenómeno de sobre-segmentação, este método pode eliminar limiares ou detalhes importantes da imagem, além de apresentar fraca definição espacial [IG98]. Não obstante a boa resposta no que concerne à redução de ruído, os filtros lineares, na sua generalidade, demonstram alguma falta de eficácia no melhoramento da qualidade de imagem, quer ao nível do contraste, quer das suas características estruturais [KSSC85, Lee80, FSSH82].

A filtragem não linear oferece maior diversidade e eficiência no melhoramento da imagem. Os filtros medianos calculam, para cada pixel, a mediana dos valores de intensidade na vizinhança, mediante uma determinada janela. Sendo dos filtros não lineares mais simples, resultam melhor que os filtros médios na definição dos contornos da imagem, apesar de alguns autores terem constatado a remoção de alguma informação importante de arestas.

A difusão não-linear é um filtro adaptativo, que recorre a Equações Diferenciais Parciais. A partir do cálculo de gradientes direccionais para cada pixel, relativamente à sua vizinhança, são calculados coeficientes de difusão em função dos gradientes calculados. A difusão não-linear demonstra maior eficiência na redução de ruído e na conservação de características importantes da imagem, relativamente a filtrações lineares [YEB08]. Dada a sua actuação perante arestas e zonas de grandes variações de intensidade, esta técnica revela-se útil na deteção dos limites de uma lesão em ultrasons mamários [AH11].

Os filtros máximos *a posteriori* estimam o sinal de forma a maximizar o teorema de Bayes, através de uma função de densidade de probabilidade. Em [YEB08] são testados estes filtros em BUS, aplicando janelas adaptativas. A sua aplicação demonstrou bons resultados ao nível do contraste da imagem, nomeadamente, o de Pearlman-Gauss, que utiliza uma função de densidade de probabilidade com distribuição gaussiana.

Alguns autores procuram ainda combinar diversos tipos filtros, de forma a melhorar os resultados da aplicação individual. Em [YEB08], a difusão não linear da imagem foi aplicada, juntamente com filtragem gaussiana. Enquanto a difusão não linear reduz o ruído, a filtragem gaussiana alisa as arestas, conservadas pelo primeiro método, de modo a evitar a sobre-segmentação.

Outro exemplo de filtragem híbrida, em [JYMK04], descreve a aplicação, sobre a imagem de vários filtros medianos distintos. Foram usados filtros de janela quadrada (4x4), em simultâneo com filtros de máscaras com formatos não regulares, tendo sido obtidos bons resultados na melhoria da qualidade de imagem, como o realce de arestas e o aumento do contraste da ROI, de forma a possibilitar a sua deteção através de thresholding binário.

Equalização de histograma

A equalização do histograma da imagem tem por objectivo standardizar e homogeneizar os níveis de intensidade. No caso das BUS, esta técnica é, particularmente, útil para uniformizar o contraste no caso de imagens de fontes distintas [HRL10]. Contudo, outros âmbitos de aplicação são possíveis, como a evidenciação da informação de textura da imagem. Em [SCH⁺10], os autores aplicaram um método de equalização polimodal ao histograma de BUS, obtendo bons resultados na resolução da textura da imagem.

Operações morfológicas

O uso de operações morfológicas sobre a imagem, nomeadamente a abertura e o fecho, permite a simplificação das estruturas, o que previne a sobre-segmentação. Em [CCC10] e [CCC⁺05], os autores aplicam estas operações sobre a imagem, em escala de cinzentos. Além da simplificação estrutural da imagem, as operações morfológicas conseguem bons resultados na filtragem de ruído.

Wavelet

Uma wavelet é uma onda de muito curta duração, com valor médio nulo. As suas características tornam-nas apropriadas para a análise de discontinuidades e pormenores em imagem. Numa decomposição pela transformada Wavelet, são realizadas operações consecutivas nas linhas e nas colunas da imagem, calculando os coeficientes de correlação entre zonas da imagem e a wavelet utilizada, que constituem um mapa de similaridade entre os componentes da imagem e a wavelet. Estas operações são realizadas com diferentes escalas da wavelet, ou seja, a wavelet é escalada de modo a permitir a análise de aproximações ou detalhes. A correlação das aproximações da imagem originam os coeficientes de passa-baixo, obtidos com a wavelet em alta escala. Por outro lado, os detalhes são representados pelos coeficientes de passa-alto, calculados através da wavelet em baixa escala.

Esta transformada, nomeadamente a Transformada Wavelet Digital apresenta algumas propriedades que a tornam atractiva para o processamento e análise de ultrasons. A possibilidade de decompor o sinal de forma a analisar detalhes de diferentes tamanhos nas escalas apropriadas - multiresolução - permite, através de *thresholding* dos coeficientes da passa-alto, reduzir a presença de componentes de alta frequência, como o ruído, na reconstrução do sinal. Esta técnica foi aplicada, com *thresholding* adaptativo, em [SSS07] para melhorar imagem BUS, reduzindo o ruído e conseguindo melhorias de contraste significativas.

2.2 Segmentação

A segmentação de imagem é, em geral, uma tarefa difícil, que depende de particularidades do tipo de imagem a segmentar e pode requerer uma grande quantidade de informação para que possa ser aplicada correcta e produzir resultados fiáveis. Contudo, em situações restritas, surgem casos de sucesso na segmentação de imagem. Um dos mais conhecidos é o trabalho em reconhecimento facial usando o classificador AdaBoost, realizado por Viola e Jones [VJ01].

No caso da imagem médica e, mais especificamente dos ultrasons, as características da imagem, como sejam o baixo contraste e o ruído, já referidas anteriormente, dificultam a segmentação de lesões. Por tal motivo, o desenvolvimento de procedimentos de segmentação adequados e eficazes para a ultra-sonografia tem vindo a ser alvo de bastante investigação e considerado um

campo de elevado interesse. No interesse deste trabalho, são de seguida apresentadas algumas aplicações à segmentação de lesões em ultrasons mamários.

Thresholding de histograma

O uso de thresholds sobre o histograma de intensidade da imagem é uma técnica simples e que não requer treino. Através da aplicação de limiares de intensidade ao histograma, é possível definir intervalos na escala de cinzentos, de modo a seleccionar determinadas regiões da imagem. Esta técnica demonstrou poder ser aplicada com algum sucesso na identificação de ROI e delimitação de lesões em ultrasons mamários [YEBO8, CSJ⁺10].

Contudo, o facto de a utilização do histograma de intensidade da imagem ser sensível ao ruído pode conduzir a resultados imprecisos. A aplicação de thresholding automático e adaptativo demonstra mais eficácia na presença de ruído, relativamente ao uso de thresholding simples. Este método mostrou uma grande correlação com as segmentações manuais [YCFC]. O uso de thresholds sobre o histograma apresenta limitações no caso de imagens com histogramas unimodais. Porém, esta técnica permite a delimitação simultânea de ROI múltiplas [JYMK04].

Watershed

O algoritmo watershed consiste num modelo não supervisionado, muito usado na segmentação de imagem. Este método particiona a imagem em regiões, tratando a imagem como um mapa topográfico e fazendo corresponder, a cada mínimo local M uma zona $B(M)$. Esta zona é entendida como uma porção na qual a água se acumula, escorrendo em direcção ao ponto mínimo M . As linhas que separam estas concavidades, são designadas por watersheds e correspondem a máximos de intensidade na imagem [Sar10].

Tipicamente, o algoritmo é aplicado ao gradiente da imagem, em detrimento da própria imagem. O cálculo do gradiente realça as descontinuidades na imagem, apresentando valores máximos em zonas de arestas, facilitando a deteção de contornos pelo algoritmo. Um dos principais problemas que decorrem do utilização deste método é a sobre-segmentação da imagem. Este fenómeno ocorre devido ao elevado número de mínimos locais que poderão existir. [Sar10] Em [CCC10], foi aplicado este algoritmo para a extração semi-automática dos contornos da lesão, em BUS, tendo sido obtidos resultados superiores à segmentação manual. Após a definição manual de uma ROI, os autores utilizaram uma versão modificada do algoritmo, recorrendo a operações morfológicas (abertura e fecho) sobre a imagem, para a obtenção precisa dos contornos da lesão. O uso de operações morfológicas permite prevenir a sobre-segmentação característica do watershed. O algoritmo watershed foi, também, aplicado em [ZRHL11] para deteção automática da lesão. As imagens foram pré-processadas por filtros médios e por thresholding de histograma. Os resultados apresentaram elevada acurácia, próxima da obtida manualmente.

K-means

O algoritmo K-means é um método iterativo não supervisionado, que efectua clustering de pixels em k clusters, com base em descritores que contêm informação de atributos ou características associadas a cada pixel [Sar10]. Este algoritmo é inicializado pela definição, quer de forma aleatória, quer de uma forma fixa, de K valores médios, designados centroides, que correspondem à média de cada cluster. De seguida, e considerando o caso da imagem, é calculada a distância de cada pixel a todos os centroides, sendo atribuído ao pixel o cluster com média mais próxima. Após a atribuição de um cluster a todos os pixels, as médias dos clusters são novamente calculadas e as distâncias são reavaliadas. Este algoritmo procura, portanto, minimizar uma função de distância, de modo a particionar os dados.

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

O critério de paragem poderá ser definido de modo a que o resultado final seja devolvido logo que, entre duas iterações, a constituição dos clusters permaneça inalterada ou poderá ser estabelecido um número máximo de iterações, por exemplo. A aplicação do algoritmo k-means representa a imagem em k níveis de cinzento, o que possibilita melhorar a separação entre zonas de características distintas. Um dos principais problemas poderá advir da proximidade que, normalmente, se verifica ao nível da intensidade na imagem, entre a ROI e sombras ou artefactos na imagem, o que poderá levar à inclusão, no mesmo cluster, de pixels representativos de ambas as situações. Em [BBGB98], o algoritmo k-means foi aplicado à segmentação de BUS, usando um método adaptativo, com base em informação da textura para classificar os tecidos.

Contornos activos

No âmbito da segmentação de ultrasons, os modelos de contorno activo, também designados por *snakes* têm sido bastante aplicados. Estes métodos dinâmicos baseiam-se na deformação iterativa de um contorno inicial, procurando minimizar a energia derivada das variações de intensidade na imagem ou de outras características, como por exemplo, a textura. A modificação activa do contorno inicial pretende convergir para a acomodação deste aos limites das ROI. Existem vários exemplos de parametrizações, como sejam *Balloon* ou *Gradient Vector Flow*. Em [JRIM10], estes modelos paramétricos foram aplicados à segmentação de massas em BUS, após filtragem mediana e equalização do histograma. A refinação da segmentação poderá ser conseguida através da inclusão de alguma informação obtida a-priori, como, por exemplo, a curvatura da imagem ou mesmo conhecimento empírico. A definição do critério de paragem, como o uso do gradiente direccionado, é, também, influente na segmentação final.

Level set

O modelo *level set* é, também, um modelo dinâmico, à semelhança dos contornos activos. Uma curva fechada é expressa em termos de um conjunto de superfícies planares $\tau(t)$. Cada superfície $\tau(t)$ representa a interseção do plano xy com a curva, num instante t , sendo $\phi(x, y, t)$ a expressão da curva a cada instante. A evolução de $\phi(x, y, t)$ é determinada por uma função de velocidade F , com direcção normal ao plano xy . Esta função baseia-se em parâmetros da imagem, como a intensidade, para determinar a propagação da curva, bem como parâmetros que controlam o grau de variação da forma da superfície a cada instante. Relativamente aos contornos activos, este método permite a deteção de movimentos complexos em interfaces da imagem com maior precisão. Este método foi aplicado à segmentação de lesões em BUS, em [WM08, CWM05, HJCM07]. O contorno inicial foi obtido após o uso da MCDE (difusão de curvatura modificada), para remover o ruído e realçar os contornos da imagem e *thresholding* binário automatizado. Os resultados obtidos foram superiores, em comparação com vários modelos de contorno activos, bem como com a segmentação manual das lesões.

Apesar dos resultados satisfatórios na segmentação de massas em ultrasons mamários e da baixa sensibilidade ao ruído, este tipo de modelos (contornos activos e *level set*) colocam algumas dificuldades, desde logo, por dependerem de uma definição apropriada do contorno inicial, sendo a sua definição automática complicada. Além deste facto, o processo de deformação activa poderá consumir bastante tempo e recursos computacionais, pela quantidade de informação que poderá ser necessária para a convergência do método. Outra das dificuldades deste tipo de modelos auto-adaptativos, com base na minimização de estados de energia, reside na gestão de mínimos locais da imagem.

Wavelet

Para além da utilidade no campo do pré-processamento da imagem, em termos de segmentação a transformada wavelet apresenta algumas características importantes para a deteção de arestas ou a extração de características. Coeficientes de correlação elevados correspondem a descontinuidades ou pormenores, facilitando a sua deteção. Além deste facto, as propriedades de resolução espacial da transformada possibilitam a segmentação de regiões, com precisão, através da deteção de arestas. Em [CCK⁺02a], a transformada wavelet foi aplicada para segmentar massas em BUS, com bons resultados.

2.2.1 Segmentação usando classificadores - Redes Neurais e Support Vector Machines

A segmentação de lesões em ultrasons peitorais pode ser entendida como uma tarefa de classificação dos tecidos, como sendo pertencentes, ou não, à lesão. Têm sido bastante aplicados, à segmentação de ultrasons, classificadores como as Redes Neurais (RN) e as SVM. A aplicação de classificadores requer treino e uma apropriada seleção de descritores de pixel, apresentando grandes potencialidades, quer usadas individualmente ou em conjunto com outros métodos.

Em [CCK⁺02b], uma RN foi aplicada com sucesso, em combinação com a análise wavelet da imagem para segmentação de ultrasons. A variância e a auto-correlação do contraste foram aplicadas como características de entrada para a rede, sendo a rede treinada por retropropagação do erro. O estudo realizado em [HC04] utilizou, em conjunto, a classificação com uma RN e o algoritmo watershed para extrair os contornos de tumores em ultrasons. A análise textural da imagem foi utilizada para treinar a rede e classificar as imagens.

Uma RN Bayesiana, com cinco camadas escondidas foi aplicada, em [DGH⁺02], usando informação da textura, do gradiente e informação acústica da imagem, para segmentar massas em BUS. A informação do gradiente foi utilizada para localizar pontos de interesse, em torno dos quais seria aplicado um algoritmo de crescimento de regiões para obter contornos candidatos. Finalmente, estes seriam segmentados e seleccionados pela RN. Contudo, o método revelou-se falível, especialmente, no caso de a ROI não ser compacta.

Em [SYWH04], os autores usaram mapas auto-organizáveis, usando informação local da textura, com o objectivo de obter um contorno inicial. Este contorno seria, posteriormente, segmentado com contornos activos, culminando num método completamente automatizado e com boa precisão.

Em [LHZ05], foi, também aplicado em classificador para a segmentação. Aplicando SVM com informação textural, os autores propuseram um método robusto e com elevada precisão para a segmentação de massas em BUS.

Apesar de o uso de classificadores para segmentar imagens de ultrasons ter vindo a apresentar resultados promissores, o treino necessário e a seleção das características adequadas para a sua aplicação podem tornar a tarefa complicada e demorada [HC04].

Capítulo 3

Descrição das metodologias

Para segmentar as massas em imagens BUS, foram aplicadas técnicas de processamento de imagem, com o objectivo de construir descritores de pixel, baseados em características multi-resolução. Sobre os descritores obtidos, foram aplicadas técnicas de classificação binária, tendo em vista a diferenciação dos tecidos. Com este método, são obtidas segmentações iniciais, onde tecidos classificados como positivos são assumidos como pertencentes a massas. De forma análoga, tecidos classificados como negativos (*background*), serão considerados como não pertencentes a massas.

Diferentes abordagens para tentar a segmentação das imagens foram definidas, combinando diferentes métodos de classificação e descritores de pixel. Nesta secção, são descritas, de um modo geral, as técnicas utilizadas, quer para a descrição da imagem, quer para a classificação. No capítulo, são esquematizadas, no seu todo, as diferentes abordagens, cujos resultados são apresentados e discutidos adiante.

3.1 Técnicas de processamento de imagem - Descriptor de pixel

3.1.1 Difusão Não-linear

A difusão não linear foi introduzida por Perona e Malik, em 1990 [PM90, VESS04]. Esta técnica permite a descrição multi-escala de imagens, assumindo modificações relativamente ao paradigma da análise multi-escala linear. No caso da difusão linear, que usualmente se processa usando filtros gaussianos, e onde o coeficiente de difusão c é uma constante, independentemente da localização espacial. A escolha de um coeficiente de difusão constante, apesar de simplificar a análise de imagem em muitos casos, permite a interação entre regiões distintas, levando à perda de informação estrutural que pode ser relevante, como sejam os limiares da imagem. Neste sentido, o objectivo da difusão não linear passa pela definição de um coeficiente $c(x, y, t)$ que permita satisfazer três condições essenciais:

- Causalidade: O aumento da escala da imagem não deverá introduzir detalhes inexistentes nas escalas anteriores. Todos os máximos e mínimos da imagem numa dada escala devem pertencer à imagem original;
- Resolução espacial: A cada escala, os limiares da imagem deverão coincidir com os limiares semânticamente significantes para essa resolução;
- Manutenção e realce dos limiares: A difusão intra-regiões deverá ocorrer preferencialmente, relativamente à difusão inter-regiões.

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

A resultante da difusão da imagem é dada pela relação seguinte:

$$I_1 = \text{div}(c(x, y, t)\nabla I) = c(x, y, t)\Delta I + \nabla c \cdot \nabla I \quad (1)$$

onde div representa o operador de divergência, ∇ o operador de gradiente e Δ o operador Laplaciano.

Os coeficientes de condução podem ser calculados, a cada iteração, usando a função de condutividade de Charbonnier:

$$g(\nabla I) = \frac{1}{1 + \left(\frac{\|\nabla I\|}{K}\right)^2} \quad (2)$$

Ou a função:

$$g(\nabla I) = e^{-(\|\nabla I\|/K)^2} \quad (3)$$

A função (2) privilegia a homogeneização intraregional, levando à conservação de regiões relativamente extensas da imagem, em detrimento de regiões menores. Por outro lado, a função (3) privilegia arestas de elevado contraste, em detrimento de arestas com contraste menor.

A constante K é calculada de um modo adaptativo, através do método de estimativa de ruído, descrito por Canny. A cada iteração, é traçado o histograma de valores absolutos do gradiente da imagem. O valor de K é fixado de modo a corresponder a uma determinada percentagem do histograma. O carácter adaptativo do cálculo dos coeficientes de difusão contribui para a definição das arestas, fomentando a manutenção da integridade das principais estruturas.

Na equação anterior, ∇I refere-se ao gradiente de intensidade, que é obtido direccionalmente para cada pixel, de acordo com as equações seguintes:

$$\nabla_{N_{i,j}} = I_{i-1,j} - I_{i,j} \quad (4)$$

$$\nabla_{S_{i,j}} = I_{i+1,j} - I_{i,j} \quad (5)$$

$$\nabla_{W_{i,j}} = I_{i,j-1} - I_{i,j} \quad (6)$$

$$\nabla_{E_{i,j}} = I_{i,j+1} - I_{i,j} \quad (7)$$

Uma vez calculadas as diferenças direccionais, os coeficientes de condução são obtidos, usando a equação de Charbonnier, já apresentada, para cada direcção do esquema numérico que seja definido (equações (4) a (7)). A escolha de um esquema baseado na utilização de 4 vizinhos de cada pixel resulta numa discretização simples do esquema de difusão contínuo, que permite, ainda assim, preservar as propriedades da mesma equação.

$$C_{N_{i,j}} = g(|\nabla_N I_{i,j}|) \quad (9)$$

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução


$$C_{S_{i,j}} = g(|\nabla_S I_{i,j}|) \quad (10)$$

$$C_{W_{i,j}} = g(|\nabla_W I_{i,j}|) \quad (11)$$


$$C_{E_{i,j}} = g(|\nabla_E I_{i,j}|) \quad (12)$$

Finalmente, a resultante da difusão I_{dif} é obtida, iterativamente, através de:

$$I_{dif}^{t+1}(i,j) = I_{dif}^t(i,j) + \lambda(\nabla_N I \cdot C_N + \nabla_S I \cdot C_S + \nabla_W I \cdot C_W + \nabla_E I \cdot C_E) \quad (13)$$



(a) Imagem original



(b) Difusão não-linear após 50 iterações

Figura 3.1: Exemplo de resultado da difusão não linear (b), relativamente à imagem original (a).

3.1.2 Filtragem Passa-banda

As filtragens passa-banda fornecem informação importante sobre limiares da imagem. Simultaneamente, estes filtros rejeitam as componentes de alta frequência, reduzindo a influência do ruído típico dos ultrasons [SPH09].

Os filtros FIR aplicados são filtros bidimensionais, obtidos de filtros FIR 1-D reais e com fase linear, de ordem N , aplicando a transformada de McClellan. Esta transformação, usando matriz de transformação T_{filter} (equação (14)) permite obter filtros bidimensionais quadrados e circularmente simétricos, de dimensão $(N + 1) \times (N + 1)$.

$$T = \begin{bmatrix} 1 & 2 & 1 \\ 2 & -4 & 2 \\ 1 & 2 & 1 \end{bmatrix} / 8 \quad (14)$$

As bandas de passagem são construídas pela combinação de filtragens passa-baixo e passa-alto, tomando a frequência de corte ω_c os valores do vector $\omega = [\omega_1 \ \omega_2 \ \omega_3]$, sabendo que $\omega_3 > \omega_2 > \omega_1$.

As filtragens de cada imagem são obtidas através da convolução, pixel a pixel, da imagem com os filtros. Para a formação das filtragens passa-banda, sobre o resultado de uma primeira filtragem passa-baixo, com uma frequência de corte $\omega_c = \omega(n + 1)$, é realizada uma filtragem passa-alto, com $\omega_c = \omega(n)$, conforme esquematizado na figura seguinte.




Figura 3.2: Esquema da filtragem passa-banda.

Na imagem 3.3, é apresentado um exemplo de resultado da filtragem passa-banda.




Figura 3.3: Exemplo de resultado das filtragens passa-banda (b), relativamente à imagem original (a).

3.1.3 Curvatura *scale-space*

Uma técnica de processamento de imagem, aplicada na constituição do descriptor de pixel, que produz características discriminatórias para os métodos de classificação utilizados é a curvatura *scale-space* [SCBP12]. Esta técnica consiste no cálculo da curvatura média da imagem, após filtragens gaussianas.

O uso da filtragem gaussiana, apesar da perda de definição espacial da imagem resultante, contrariamente ao que sucede com a resultante da difusão não-linear, é eficaz na redução de ruído de alta frequência que compromete a definição dos limites entre regiões distintas e reduz a estabilidade dentro das mesmas, dado o perfil passa-baixo dos filtros gaussianos.

Para o cálculo da curvatura no *scale-space*, as imagens são filtradas, ao longo de várias iterações, com um filtro gaussiano F_{gauss} . Este é um filtro bidimensional de dimensão 5×5 . A dimensão do filtro, bem como o seu desvio padrão σ , são mantidos constantes em todas as iterações, sendo $\sigma^2 = \sqrt{2}/2$. Cada iteração do processo de filtragem resulta num aumento da escala t da imagem.

A curvatura média destas filtragens é calculada a partir das curvaturas horizontal L_{xx} e vertical L_{yy} . Tais curvaturas representam segundas derivadas ou gradientes direcionais da imagem filtrada I_{gauss} e são obtidas numericamente. Inicialmente, as primeiras derivadas direcionais L_x e L_y são calculadas como descrito nas equações seguintes:

$$L_x(i, j) = I_{gauss}(i, j) - I_{gauss}(i + 1, j) \quad (15)$$

$$L_y(i, j) = I_{gauss}(i, j) - I_{gauss}(i, j + 1) \quad (16)$$

Tomando estes resultados, os gradientes de segunda ordem são calculados de forma similar, através de:

$$L_{xx}(i, j) = L_x(i, j) - L_x(i + 1, j) \quad (17)$$


Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

$$L_{yy}(i, j) = L_y(i, j) - L_y(i, j + 1) \quad (18)$$

O resultado final da curvatura H para cada pixel consiste na média aritmética destes gradientes (curvaturas principais). Assim, o valor da curvatura numa dada escala é dado, para cada pixel, por:

$$H = \frac{L_{xx} + L_{yy}}{2} \quad (19)$$

A curvatura média resulta numa boa representação das transições entre regiões, apresentando máximos locais em pontos de elevado gradiente, isto é, nas localizações de pontos de inflexão, onde ocorre uma grande variação dos níveis de intensidade da imagem. As massas em exames de ultrasons apresentam, normalmente, níveis médios de intensidade inferiores e díspares das regiões circundantes. A combinação desta medida com a filtragem gaussiana permite que o elevado ruído característico deste tipo de imagens tenha uma influência mínima no mapeamento destas transições.



(a) Imagem original



(b) $T = 200$

Figura 3.4: Exemplo de resultado do cálculo da curvatura no *scale-space* (b) e (c), relativamente à imagem original (a).

3.2 Métodos aplicados na segmentação de massas

3.2.1 Support Vector Machines

Uma das ferramentas de classificação mais utilizadas actualmente são as SVM. As SVM têm sido propostas para um grupo muito abrangente de aplicações, apresentando elevada eficácia na resolução de diversos problemas de classificação, para o que contribui as suas propriedades de generalização [CWM⁺03].

O conceito de classificação de dados associado às SVM consiste na definição de um hiperplano de separação óptimo, que permita a atribuição de uma classe a um conjunto de pontos, com base num espaço de características associadas a estes. As SVM são, inerentemente, desenhadas para efectuar classificação binária, do tipo positivo/negativo. O algoritmo de classificação apresentado tem por objectivo, de forma semelhante, classificar pixeis como pertencentes ou não a massas em BUS - classificação binária.

Considerando um conjunto de treino $T = \{(x_i, y_i)_{1 \leq i \leq N}\}$, tendo cada ponto $x_i \in \mathbb{R}^n$ uma classe $y_i \in \{-1, 1\}$ associada, a aplicação de uma SVM procura encontrar uma solução óptima para particionar este conjunto de treino, de modo a que todos os pontos x_i pertencentes à mesma classe y_i sejam posicionados no mesmo lado do hiperplano que separa T . Simultaneamente, a SVM procura maximizar a distância entre os pontos mais próximos de cada classe y_i e o hiperplano de separação.

No caso do conjunto de treino T ser linearmente separável, existe pelo menos um hiperplano de separação, definido por:

$$w \cdot x + b = 0 \quad (20)$$

que satisfaça a condição:

$$y_i (w \cdot x_i + b) > 0, \quad i = 1, \dots, N \quad (21)$$

A resolução do problema da separação do conjunto T reside em encontrar o par (w, b) que satisfaz a condição anterior.

Poderão existir vários hiperplanos de separação que satisfaçam esta condição. Contudo, deverá existir um hiperplano óptimo, que possibilite maximizar a distância entre o ponto mais próximo do hiperplano. Se a desigualdade (21) for redefinida como:

$$y_i (w \cdot x_i + b) \geq 1, \quad i = 1, \dots, N \quad (22)$$

a distância d para o hiperplano será $d = 1/\|w\|$. A margem, que representa uma medida da capacidade de generalização do modelo de classificação, é dada por $2/\|w\|$. A maximização destas medidas permite obter o parâmetro w da equação do hiperplano de separação óptimo. Este hiperplano é definido de forma a minimizar a ocorrência de classificações erradas no conjunto de treino e o seu cálculo recorre ao método dos multiplicadores de Lagrange. Sabendo que $\|w\|^2$ é uma função convexa e impondo a restrição da equação (22), o hiperplano óptimo é calculado pela maximização de:

$$W(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j x_i \cdot x_j \quad (23)$$

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

onde $\alpha = (\alpha_1, \dots, \alpha_N)$ representa o conjunto dos N multiplicadores de Lagrange não-negativos, associados à restrição da equação e para os quais se verifica a relação:

$$\sum_{i=1}^N \alpha_i y_i = 0. \quad (24)$$

Os pontos (x_i, y_i) do conjunto de treino que correspondem a α_i são designados por vectores de suporte. Finalmente, b pode ser determinado pelas condições de Kuhn-Tucker (ref), partindo das expressões:

$$w = \sum_{i=1}^N \alpha_i y_i x_i \quad (25)$$

que determina w e, finalmente,

$$\alpha_i (y_i (w \cdot x_i + b) - 1) = 0, \quad i = 1, 2, \dots, N. \quad (26)$$

A função de decisão do classificador, no caso de um conjunto linearmente separável e associado a apenas duas classes, será dada por:

$$f(z) = \text{sgn} \left(\sum_{i=1}^N \bar{\alpha}_i y_i x_i \cdot z + \bar{b} \right) \quad (27)$$

Quando o conjunto de treino T não é linearmente separável, o problema poderá ser solucionado de duas formas: a introdução de variáveis de tolerância no modelo linear ou a utilização de modelos não lineares para o hiperplano de separação. Permitindo uma margem de tolerância a classificações erradas, pela introdução de uma variável $\xi_i > 1$, na desigualdade (22). Deste modo, a obtenção do hiperplano de separação óptimo baseia-se na minimização da expressão:

$$\frac{1}{2} w \cdot w + C \sum_{i=1}^N \xi_i \quad (28)$$

Um aumento do parâmetro de regularização C leva à tendência da minimização do número de pontos classificados erradamente, enquanto que a sua diminuição promove a maximização da distância $d = 1/\|w\|$. A utilização da variável de tolerância ξ conduzirá, contudo, a resultados não optimizados, dado que se baseia na permissão de classificações não correctas. A utilização de modelos não-lineares para o hiperplano de separação procura otimizar a classificação de conjuntos não separáveis linearmente.

$$W(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (29)$$

Deste modo, a função de decisão para classificadores não lineares é dada por:

$$f(z) = \text{sgn} \left[\sum_{i=1}^N \alpha_i y_i K(x_i, z) + b \right] \quad (30)$$

onde $K(x_i, z)$ representa o *kernel* considerado. Uma grande variedade de *kernels* tem sido desenvolvido e aplicado para a classificação de conjuntos multidimensionais de dados. No âmbito deste trabalho, a classificação com SVM aplicou vários *kernels* distintos, de modo a maximizar

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

a priori a probabilidade de obter boa performance na classificação com o descritor de pixel pretendido. As funções testadas na classificação da base de dados de BUS foram os seguintes:

Linear:

$$K(x, z) = x \cdot z \quad (31)$$

Quadrático:

$$K(x, z) = (\gamma \cdot x \cdot z + a)^2 \quad (32)$$

Polinomial:

$$K(x, z) = (\gamma \cdot x \cdot z + a)^r \quad (33)$$

Radial Basis Function:

$$K(x, z) = \exp\left(\frac{|x - z|^2}{2\sigma^2}\right) \quad (34)$$

Multilayer Perceptron (MLP):

$$K(x, z) = \tanh(\gamma \cdot x \cdot z + coef) \quad (35)$$

3.2.2 Análise Discriminante

Os classificadores por AD analisam estatisticamente um conjunto de amostras, procurando obter uma separação dos dados em K classes [Krz88, Seb84]. Considerando o problema da classificação binária, com base num conjunto de treino $T = (X_1, Y_1), \dots, (X_n, Y_n)$, são obtidas regras discriminantes de modo a construir o classificador $C(X, L) : X \rightarrow \{1, 2\}$.

Os classificadores aplicados neste trabalho assumem, para cada classe, um distribuição de probabilidade gaussiana, caracterizada por:

$$P(X|Y = k) \sim N(\mu_k, \Sigma_k) \quad (36)$$

onde μ_k e Σ_k representam, respectivamente, o vector médio e a matrix de covariância de cada classe do conjunto de treino T .

Calculando estes parâmetros estatísticos, poderá ser inferida uma regra discriminante, que associe cada observação do conjunto de teste a uma classe. No presente trabalho, foram aplicadas várias tipologias de AD:

- Linear
- Quadrática
- Diagonal Linear
- Diagonal Quadrática

Estas tipologias distinguem-se por assumirem, para a construção da regra discriminante, diferentes cenários no que concerne às distribuições de probabilidade dos dados.

No caso da AD linear, assume-se que ambas as classes apresentam a mesma matrix de covariância Σ , sendo esta estimada pelo conjunto de treino, através de:

$$\hat{\Sigma} = \sum_k (n_k - 1) S_k / (n - K) \quad (37)$$

onde S_k é a matriz de covariância de cada classe k .

A regra discriminante para o caso linear é dada pela expressão:

$$C(X) = \operatorname{argmin}_k \{(X - \mu_k) \Sigma^{-1} (X - \mu_k)^T\} \quad (38)$$

que atribui, a cada observação X , a classe k que minimiza esta equação.

No caso quadrático, são assumidas, para cada classe, matrizes de covariância Σ_k distintas, dadas pelas próprias matrizes S_k de cada classe. Nestas condições, a regra discriminante será:

$$C(X) = \operatorname{argmin}_k \{(X - \mu_k) \Sigma_k^{-1} (X - \mu_k)^T + \log |\Sigma_k|\} \quad (39)$$

A AD diagonal é aplicável em casos em que as matrizes de covariância das classes sejam diagonais. De forma similar aos casos anteriores, se a matriz de covariância for igual para ambas as classes, e dada por:

$$\Delta_k = \operatorname{diag}(\sigma_{k_1}^2, \dots, \sigma_{k_g}^2) \quad (40)$$

o problema da definição da regra discriminante é linear. Se, por outro lado, as matrizes foram distintas, a regra discriminante é quadrática. Portanto, para o caso diagonal linear, a regra discriminante é obtida através da expressão:

$$C(x) = \operatorname{argmin}_k \sum_{i=1}^g \left\{ \frac{(x_i - \mu_{k_i})^2}{\sigma_i^2} \right\} \quad (41)$$

enquanto que, para o classificador diagonal quadrático, a regra discriminante será:

$$C(x) = \operatorname{argmin}_k \sum_{i=1}^g \left\{ \frac{(x_i - \mu_{k_i})^2}{\sigma_{k_i}^2} + \log \sigma_{k_i}^2 \right\} \quad (42)$$

Além das tipologias já descritas, é ainda testada, neste trabalho, um outro tipo de classificador, baseado na distância de Mahalanobis. De forma semelhante aos classificadores anteriores, é calculada a matriz de covariância S_k para cada classe, com base no conjunto de treino T . Obtendo, igualmente, o vector médio das classes μ_k , a distância de Mahalanobis é dada por:

$$D_M(x) = \sqrt{(x - \mu_k)^T S^{-1} (x - \mu_k)} \quad (43)$$

No caso de a matriz de covariância ser diagonal (s_k^2), esta distância passa a ser a distância euclidiana normalizada, sendo dada por:

$$D_M(x) = \sqrt{\sum_{i=1}^K \frac{(x - \mu)^2}{s_k^2}} \quad (44)$$

A cada observação x será atribuída a classe k para a qual a distância seja minimizada.

3.2.3 AdaBoost

O algoritmo de classificação AdaBoost foi introduzido por Freund e Schapire em 1995 [FS99, VJ01]. O conceito deste método baseia-se em estudar o comportamento de classificadores fracos, sobre os quais não seja expectável obter resultados muito melhores que um método aleatório, e melhorar, iterativamente, a sua performance, através de uma cascata de classificadores fracos ou de base.

Considere-se o problema da classificação binária de um conjunto de treino $S = (x_1, y_1) \dots (x_m, y_m)$, em que cada ponto x_i se encontra associado a um espaço de características X e cada classe y_i poderá tomar valores do conjunto. Ao longo de T iterações, o algoritmo define uma distribuição de pesos a atribuir aos exemplos de treino considerados. Para cada exemplo de treino (x_i, y_i) , na iteração t , o respectivo peso é dado por $D_t(i)$. Inicialmente, os pesos são distribuídos equitativamente por todos os exemplos de treino, sendo $D_1(i) = 1/m$, onde m se refere ao tamanho da amostra de treino.

Cada classificador fraco apresenta, como resultado, um conjunto de hipóteses h_t sobre a classificação dos exemplos de treino X , com base na distribuição $D_t(i)$. Em cada iteração $t = 1, \dots, T$, o erro associado à hipótese h_t , que permite avaliar a performance de cada classificador, é calculado através da própria distribuição de pesos, considerando os casos em que a hipótese dada pelo classificador não corresponde à classe y_i de cada exemplo de treino, de acordo com:

$$\varepsilon_t = Pr_{i \sim D_t} [h_t(x_i) \neq y_i] = \sum_{i: h_t(x_i) \neq y_i} D_t(i) \quad (45)$$

Após o cálculo do erro associado a h_t , é obtido um parâmetro α_t , que é determinante na adaptação da distribuição na iteração seguinte ($D_{t+1}(i)$). O cálculo de α_t depende do erro ε_t , segundo a equação:

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right) \quad (46)$$

A aplicação do parâmetro α confere ao algoritmo um carácter adaptativo, relativamente ao erro de cada iteração. Este parâmetro determina a importância atribuída a uma dada hipótese h_t , isto é, ao resultado de cada classificador de base, no contexto da decisão final $H(x)$. Atentando à variação de α_t , consoante o valor do erro de cada iteração (ε_t), é possível verificar que este parâmetro varia inversamente com o erro, assumindo valores não negativos para qualquer $\varepsilon_t \leq 1/2$. A definição de α_t permite aferir que o classificador global tende a atribuir maior importância a exemplos ambíguos ou sobre os quais seja difícil obter uma decisão. Para efeitos de classificação binária de um conjunto de teste, a função de decisão - hipótese final $H(x)$ - é definida pelo somatório dos resultados das diversas hipóteses intermédias $h_t(x)$:

$$H(x) = \text{sgn} \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (47)$$

onde o sinal do resultado da soma pesada de h_t determina a classe a atribuir a um exemplo x . A implementação do algoritmo AdaBoost utilizada neste trabalho baseia-se num classificador fraco que aplica, sobre uma determinada dimensão do conjunto de treino, uma série de limiares (*thresholds*) definidos entre os valores mínimos e máximos dessa dimensão. O objectivo é encontrar o limiar que apresente o menor erro, na separação dos pontos dessa dimensão do conjunto de treino em duas classes.

3.2.4 Contornos activos sem limiares

Os modelos de segmentação usando contornos activos baseiam-se na evolução de uma curva C , definida por um conjunto de pontos, sujeitando-a a restrições resultantes de características de uma dada imagem u_0 . Partindo de um contorno inicial definido, por exemplo, em torno de um objecto na imagem, a curva move-se segundo a normal interior e deverá parar nos limites desse objecto.

Os modelos clássicos de contornos activos [KWT87] usam detectores de limiares para parar a evolução da curva C nos limites do objecto. Tipicamente, este detector baseia-se numa função positiva $g(\nabla u_0)$, que decresce de tal forma que $\lim_{t \rightarrow \text{inf}} g(t) = 0$. Um exemplo típico deste tipo de função é:

$$g(|\nabla u_0|) = \frac{1}{1 + |\nabla G_\sigma * u_0|^2} \quad (48)$$

onde $G_\sigma * u_0$ é a convolução da imagem com um filtro gaussiano. A função $g(\nabla u_0)$ é estritamente positiva em regiões homogéneas da imagem e próxima de zero nos limiares. Deste modo, a curva C é movida usando $g(\nabla u_0)$ como factor de variação da velocidade, levando a que, perto dos limites de um objecto, a curva varie com uma velocidade menor.

Este tipo de modelos, dependentes do gradiente da imagem, apenas são aplicáveis a objectos com limiares caracterizados por um gradiente bem definido. Se a imagem u_0 apresenta ruído, o filtro gaussiano aplicado teria de ser forte, o que reduziria o ruído mas levaria a perda de definição dos limiares. As imagens de ultrasons são, intrinsecamente, ruidosas e com fraco contraste, significando que estes modelos não serão, à partida, eficientes para a sua segmentação.

O método de contornos activos aplicado neste trabalho baseia-se no procedimento descrito em [CV01], que assenta na minimização de um modelo de energia. Sendo C o contorno activo, denotam-se por c_1 e c_2 as constantes que representam os valores médios interno e externo de u_0 , respectivamente, relativamente a C . Assume-se, ainda, que a imagem u_0 se encontra dividida em duas regiões, de intensidades aproximadamente constantes localmente, de valores u_0^i e u_0^o . Considerando que o objecto de interesse tem como limite a curva X , tem-se que $u_0 \approx u_0^i$ dentro do objecto e $u_0 \approx u_0^o$ no exterior do mesmo.




Figura 3.5: Contornos activos.

Partindo destes termos, é formulada uma equação de energia, dada por:

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

$$F_1(C) + F_2(C) = \int_{C_i} |u_0 - c_1|^2 dx dy + \int_{C_o} |u_0 - c_2|^2 dx dy \quad (49)$$

A equação (49) pode incluir termos de regularização, respeitantes às características do contorno activo. Logo, esta pode ser reformulada como:

$$F(C, c_1, c_2) = \mu \cdot L(C) + v \cdot A(C) + \lambda_1 \int_{C_i} |u_0 - c_1|^2 dx dy + \lambda_2 \int_{C_o} |u_0 - c_2|^2 dx dy \quad (50)$$

onde $A(C)$ representa a área interna do contorno activo, $L(C)$ o seu comprimento e λ_1 e λ_2 são parâmetros regularizadores. O termo da área do contorno pode ser utilizado, fixando $v > 0$, forçando, deste modo, o contorno a mover-se apenas para o seu interior.

O problema de segmentação é resolvido pela minimização da equação anterior, sendo $F_1(X) + F_2(X)$, que representa a energia correspondente à curva limite do objecto, o termo que a minimiza. Conforme o esquema apresentado na figura 3.5, se o contorno se encontra totalmente fora dos limites do objecto, tem-se $F_1(C) > 0$ e $F_2(C) \approx 0$. Nestas condições, o contorno é forçado a mover-se para o interior, segundo a normal de cada ponto que a constitui, de forma a reduzir a energia $F_1(C)$. Por outro lado, se o contorno se encontrar completamente dentro dos limites do objecto, resulta que $F_2(C) > 0$ e $F_1(C) \approx 0$. Portanto, nestas condições, o contorno mover-se-á segundo a normal exterior, de encontro à curva X .

Capítulo 4

Segmentação de massas

Para obter a segmentação inicial das imagens, foram aplicados dois classificadores distintos - SVM e AD -, usando um descriptor de pixel comum a ambos os métodos. Este descriptor considera 5 características obtidas pelos métodos de processamento de imagem descritos anteriormente.

4.1 Base de dados




Figura 4.1: Base de dados (1).

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução




Figura 4.2: Base de dados (2).




Figura 4.3: Base de dados (3).

4.2 Treino e aplicação dos classificadores

Aplicou-se, para o descriptor de pixel, o resultado da difusão não-linear, obtido após 60 iterações, com K dinâmico, a ser definido para igualar 90% do integral do histograma do gradiente da imagem e com $\lambda = 1/8$. Foram, ainda, aplicados os textitoutputs de duas filtragens passa-banda (I_{bp1} e I_{bp2}), sendo a primeira filtragem caracterizada por $0.031\pi < \omega < 0.056\pi$, e a segunda por $0.056\pi < \omega < 0.1\pi$. Finalmente, dois cálculos da curvatura *scale-space* da imagem foram considerados, em duas escalas diferentes - $T = 200$ e $T = 300$. Para cada pixel, os valores do descriptor são obtidos partindo do pixel correspondente nas imagens resultantes de cada processamento. Na figura 4.4, são apresentados exemplos de todas as características incorporadas no descriptor de pixel, para um dado exemplo (4.4(a)).

O treino dos classificadores para a segmentação inicial foi realizado com o descriptor de pixel descrito anteriormente. Os dados do conjunto de treino foram recolhidos, de forma aleatória, de 1243 pixels seleccionados de duas imagens de ultrasons. As máscaras de segmentação manual, realizadas por um oncologista, foram usadas como referência para a distribuição espacial do treino positivo e negativo (figura 4.5(a)).

As amostras de treino foram seleccionadas em localizações próximas e em torno do limite destas máscaras. Para efectuar essa seleção, a máscara é dilatada e erodida, através de morfologia binária com elementos estruturantes de forma circular, com diferentes raios. A faixa de pixels positivos foi obtida pela diferença entre a erosão da máscara com raio 3 e com raio 5, resultando numa faixa com 2 pixels de largura, contornando o limite da máscara pelo seu interior (figura 4.5(b)). Por seu turno, a faixa de pixels negativos foi criada pela diferença entre a dilatação da máscara com raio 5 e com raio 3 (figura 4.5(c)).

Partindo destas duas faixas, foram seleccionados, aleatoriamente, 20% dos pixels pertencentes a essas zonas, resultando em 614 pixels de treino positivos e 629 negativos (figura 4.5(d)). O facto de a faixa exterior ser maior que a interior resulta num número ligeiramente superior de amostras negativas.

O treino dos classificadores foi, posteriormente, aplicado para a classificação de um conjunto de teste composto por 20 imagens de ultrasons. Nesta fase de segmentação inicial foram testados dez classificadores distintos, de acordo com os *kernels* apresentados nas secções 3.2.1 e 3.2.2:

- Support Vector Machines:
 - Linear
 - Quadrático
 - Polinomial
 - *Radial Basis Function*
 - *Multilayer Perceptron*
- Análise Discriminante:
 - Linear
 - Quadrático
 - Linear Diagonal
 - Quadrático Diagonal
 - Distância de Mahalanobis

4.3 Métodos heurísticos para a seleção da ROI

Após a segmentação inicial do conjunto de teste, são implementados alguns métodos heurísticos sobre o resultado binário dos classificadores, tendo em vista a seleção da ROI. Estes passos assumem um papel preponderante na possibilidade destas metodologias serem totalmente automatizadas, influenciando diretamente na melhoria global dos resultados da segmentação inicial. Devido à utilização de pixels em torno dos limites das massas, para a constituição do conjunto

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução




Figura 4.4: Descriptor de pixel para a segmentação inicial.

de treino dos classificadores, será expectável que a segmentação das massas possa resultar em contornos fechados, contendo falhas no interior dessas regiões. Tendo em consideração este facto, os resultados são sujeitos a uma operação de fecho morfológico, de modo a suprimir qualquer região classificada como *background* cuja vizinhança seja, na sua totalidade, composta por pixels positivos.

Estes resultados apresentam, à partida, a ROI, juntamente com regiões de pixels classificados incorrectamente como positivos, devido à semelhança de características com as massas. A presença de sombras e outros artefactos na imagem contribui, directamente, para a obtenção destas regiões. Geralmente, as sombras em exames de ultrasons situam-se na porção inferior da imagem (conforme é possível aferir em alguns casos da base de dados utilizada - figuras 4.2(d)




Figura 4.5: Seleção dos pixels de treino para a segmentação inicial com SVM e AD.

e 4.2(f)). Com base nesta constatação, e assumindo que a ROI não estará conectada aos limites da imagem, é realizada a etiquetagem de objectos na imagem, eliminando, posteriormente, quaisquer objectos que contenham pixels localizados correspondentes aos limites da imagem (figuras 4.6(b) e 4.6(c)).

Estes passos de supressão de regiões preparam a imagem para os consequentes métodos de seleção da ROI, ao eliminar regiões de dimensões consideráveis, que possam competir com a ROI e inviabilizar a automatização da seleção da mesma. Os resultados, após a aplicação da série de métodos heurísticos descritos, apresentarão a ROI, juntamente com pequenas regiões indevidamente classificadas, consideradas como ruído.

De forma a reduzir a influência deste ruído nos resultados de segmentação e finalizar a seleção automática da ROI, duas abordagens distintas foram testadas. A primeira abordagem procura reduzir a influência de pequenas áreas no resultado final. Sendo as imagens binárias, pequenos objectos respondem à operação de abertura morfológica. Os objectos da imagem foram etiquetados, antes da abertura, que se realizou, em todos os casos, usando um elemento estruturante, de dimensão fixa, com formato circular e raio 8 (figura 4.7(c)). Após esta operação, os objectos não suprimidos totalmente, onde se pressupõe a presença a ROI, foram recuperados, na




Figura 4.6: Supressão de objectos ligados aos limites da imagem.

forma original, que apresentam antes da abertura morfológica. A semelhança entre objectos não sumpridos pela abertura e os objectos correspondentes no resultado inicial é visível nas figuras 4.7(b) e 4.7(d).




Figura 4.7: Abertura com recuperação da forma original.

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

A segunda abordagem leva em consideração a elevada probabilidade de a ROI apresentar maior área, relativamente a quaisquer outras regiões classificadas como positivas. Os objectos constantes da segmentação inicial foram etiquetados, sendo depois recuperado, para o resultado final, o objecto com maior área (figuras 4.8(b) e 4.8(c)).




Figura 4.8: Seleção de regiões com a maior área.

Capítulo 5

Refinação da segmentação

A segunda fase do método de segmentação proposto neste trabalho procura melhorar a resolução espacial da segmentação inicial, obtida através da classificação de pixels com SVM e AD. Para a refinação da segmentação, foram aplicados dois métodos distintos: classificação de pixels usando AdaBoost e a aplicação do método de contornos activos, também já descrito anteriormente. Para a aplicação de ambos os métodos, são utilizados os resultados da seleção da maior área, relativamente aos métodos de segmentação inicial. No capítulo seguinte encontra-se a comparação dos métodos de seleção da ROI, aplicados na etapa anterior, onde são discutidas as vantagens do método da maior área, relativamente ao método da abertura morfológica.

As máscaras resultantes são usadas como pontos de iniciação e regulação da aplicação destes métodos. No caso específico dos resultados das SVM, dado que são aplicados diversos *kernels*, foi definido um critério para a seleção de resultados, com o objectivo de simplificar a análise da eficácia dos algoritmos de segmentação fina. Dentro do grupo de resultados das SVM para cada imagem, é escolhido o resultado com maior acurácia.

5.1 Segmentação fina usando o algoritmo AdaBoost

Um dos métodos aplicados na segmentação fina da ROI aplica o algoritmo AdaBoost, de forma similar ao realizado na fase anterior. O algoritmo é aplicado numa região resultante da dilatação dos resultados da segmentação inicial. Apenas os pixels pertencentes a esta região são classificados com o AdaBoost, sendo todos os pixels externos considerados automaticamente com *background*.

O algoritmo AdaBoost aplicado baseia-se num classificador simples, que define um limiar para cada dimensão do espaço de características da imagem, individualmente, que separa a informação em duas classes. Na fase de treino, este classificador fraco é chamado iterativamente, adaptando o limiar de cada dimensão de forma a minimizar o erro de classificação do conjunto de treino. O treino do algoritmo resulta numa estrutura que armazena os limiares aplicados a cada dimensão do espaço de características que minimizam aquele erro.

O descriptor de pixel usado para a segmentação fina utiliza algumas características similares às aplicadas na primeira fase. Contudo, tendo como objectivo a melhoria da resolução espacial dos resultados, a parametrização do processamento de imagem para a extração de características é alterada. Para além desta necessidade, a limitação da área sujeita à classificação de pixels reduz, directamente, a presença de ruído e de outras regiões com características semelhantes à ROI, que possam competir com a mesma no processo de classificação. Deste modo, o descriptor de pixel é construído com informação resultante da curvatura *scale-space* e da difusão não linear em baixa escala, com base na melhor resolução espacial que apresentam, quando comparadas com escalas mais altas.

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

O conjunto de treino aplicado ao algoritmo AdaBoost foram obtidos com base na máscara da segmentação manual. O conjunto de treino negativo é constituído por 50% dos pixels localizados numa faixa definida em torno da máscara, obtida pela diferença de duas regiões, resultantes da dilatação da máscara com dois elementos estruturantes circulares de raios distintos, sendo um de 12 e outro de 8 pixels (figura 5.1(b)). Para constituir o conjunto de treino positivo, foram recolhidos 20% dos pixels interiores ao limite da mesma máscara (figura 5.1(a)).




Figura 5.1: Seleção dos pixels de treino para a segmentação fina com AdaBoost.

Do conjunto de treino usado para o algoritmo AdaBoost constam 2429 pontos, dos quais 1392 são positivos e 1037 negativos. O classificador foi treinado e aplicado ao conjunto de imagens usando 200 iterações. O descriptor de pixel foi formado com os resultados da curvatura *scale-space* obtidos nas escalas $t = 20$ e $t = 30$, juntamente com a difusão não linear da imagem, após 30 iterações usando a equação de condutividade de Charbonnier, sendo $\lambda = 1/8$ e K dinâmico, definido para igualar 90% do integral do histograma do gradiente da imagem original. Para a classificação do conjunto de teste, as áreas a classificar foram definidas pela dilatação dos resultados da segmentação inicial, usando um elemento estruturante circular de raio 8 (figuras ?? e ??). O raio do elemento estruturante foi definido, após experimentação, de forma a manter um compromisso entre a seleção da maior área possível e o foco na ROI, evitando a exposição a regiões passíveis de influir na segmentação.

À semelhança dos resultados da segmentação inicial, o resultado binário do classificador AdaBoost é sujeito a uma operação de preenchimento e, posteriormente, à seleção da maior área, de modo a eliminar algum ruído que possa provir da classificação da imagem, para produzir a segmentação final.

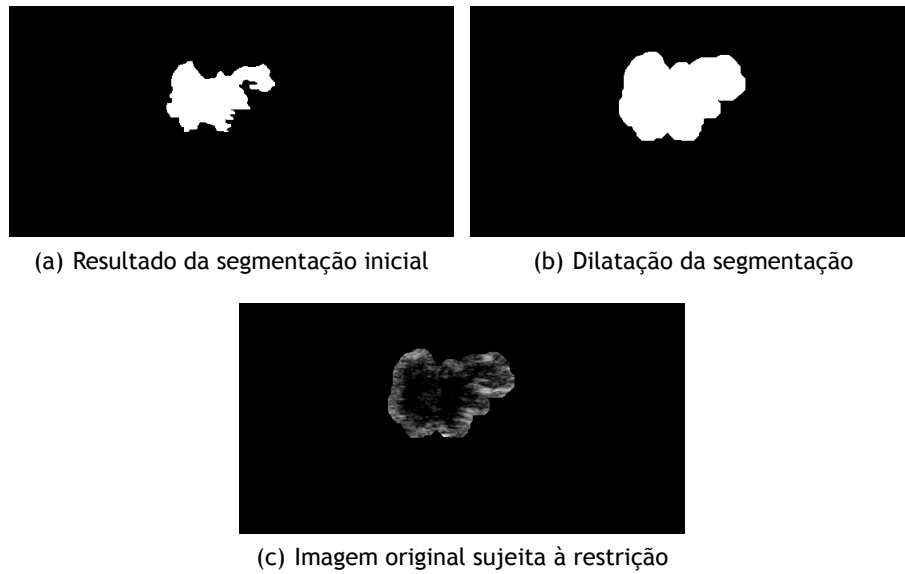


Figura 5.2: Restrição da área da classificação com o algoritmo AdaBoost.

5.2 Segmentação fina usando Contornos Activos

O outro método aplicado para a segmentação fina das massas em ultrasons baseia-se na utilização de contornos activos, através do método descrito na secção 3.2.4.

A máscara resultante da segmentação inicial é directamente utilizada como contorno inicial para o algoritmo de contornos activos. O algoritmo foi aplicado em 200 iterações e o resultado final, no forma de contorno, é convertido em máscara binária. Os pixels interiores ao contorno são classificados como positivos, enquanto os exteriores são definidos como negativos.

O resultado da segmentação foi, finalmente, sujeito à seleção do objecto com maior área, de modo a eliminar quaisquer objectos que possam resultar de eventuais desfragmentações do contorno principal.

Capítulo 6

Resultados

6.1 Segmentação inicial

Na figura 4.6 são apresentados exemplos comparativos de resultados da segmentação inicial e da supressão de objectos ligados aos limites da imagem. Torna-se evidente, com o exemplo apresentado, que este procedimento simples traz grande eficiência ao algoritmo, ao eliminar directamente grandes áreas erradamente classificadas como positivas. Na sua generalidade, estas regiões resultam, como foi discutido anteriormente, de sombras e outros artefactos da imagem.

Os resultados dos métodos de seleção da ROI, usados para finalizar a etapa da segmentação inicial podem ser analisados através das tabelas 6.1, 6.2 e 6.3. O método da seleção da maior área, apesar de apresentar perdas na deteção de positivos verdadeiros - o que advém de casos com ROI múltiplas -, melhora a precisão em 49.7%. Por seu turno, o método da abertura regista uma melhoria de apenas 4,1%, o que é justificado pelas regiões de falsos positivos que não são suprimidos pelo elemento estruturante escolhido (figura 4.7(d)). O uso de um elemento estruturante maior poderia melhorar os resultados deste método correndo o risco, porém, de eliminar ROI de pequenas dimensões.

Tabela 6.1: Resultados segmentação inicial.

Imagem	Acurácia	Sensibilidade	Precisão
1	0.9660	0.9234	0.7289
2	0.8662	0.7994	0.1534
3	0.9384	0.7901	0.4820
4	0.9063	0.5837	0.3325
5	0.8783	0.7834	0.2342
6	0.9150	0.5580	0.3119
7	0.9334	0.7728	0.4607
8	0.9295	0.7797	0.2256
9	0.9257	0.7782	0.5665
10	0.8490	0.9463	0.2029
11	0.8318	0.6847	0.5307
12	0.9055	0.7839	0.3402
13	0.9375	0.7784	0.4147
14	0.8788	0.6987	0.2806
15	0.9237	0.7693	0.3095
16	0.9489	0.7922	0.6780
17	0.9065	0.6712	0.3701
18	0.9264	0.6523	0.3281
19	0.8226	0.5575	0.1532
20	0.8865	0.7774	0.6143
	0.9038	0.7440	0.3859

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

Tabela 6.2: Resultados seleção maior área.

Imagem	Acurácia	Sensibilidade	Precisão
1	0.9862	0.9183	0.9183
2	0.9843	0.7619	0.7619
3	0.9805	0.7765	0.7765
4	0.9524	0.3501	0.3501
5	0.9812	0.6091	0.6091
6	0.9693	0.4422	0.4422
7	0.9835	0.7258	0.7258
8	0.9881	0.5139	0.5139
9	0.9610	0.6115	0.6115
10	0.9732	0.9182	0.9182
11	0.9351	0.6447	0.6447
12	0.9881	0.7839	0.7839
13	0.9863	0.7784	0.7784
14	0.9704	0.6983	0.6983
15	0.9862	0.6548	0.6548
16	0.9686	0.6818	0.6818
17	0.9762	0.6645	0.6645
18	0.9848	0.6523	0.6523
19	0.9527	0.4905	0.4905
20	0.9459	0.6707	0.6707
	0.9727	0.6674	0.8830

Tabela 6.3: Resultados abertura

Imagem	Acurácia	Sensibilidade	Precisão
1	0.9680	0.9234	0.7434
2	0.8786	0.7994	0.1672
3	0.9400	0.7901	0.4900
4	0.9437	0.5837	0.5203
5	0.8898	0.7834	0.2541
6	0.9200	0.5527	0.3292
7	0.9354	0.7728	0.4705
8	0.9070	0.7756	0.1775
9	0.9366	0.7782	0.6205
10	0.8664	0.9463	0.2237
11	0.8594	0.6482	0.6079
12	0.9246	0.7839	0.4011
13	0.9480	0.7784	0.4702
14	0.9034	0.6983	0.3382
15	0.8986	0.7470	0.2424
16	0.9647	0.7922	0.8022
17	0.9303	0.6645	0.4661
18	0.9443	0.6523	0.4132
19	0.8454	0.5319	0.1696
20	0.8925	0.7766	0.6330
	0.9148	0.7389	0.4270

Estes resultados revelam que o método da seleção da maior área apresenta maior potencial para a automatização do método, ao eliminar muito mais regiões erradamente classificadas. O desvio da precisão, no caso deste método, assenta em alguns exemplos do conjunto de teste, cuja segmentação inicial do objecto de interesse se encontra ligada a outras regiões indesejadas, que não poderão ser, deste modo, eliminadas pelo método.

A etapa de segmentação inicial assume a importância de definir a localização correcta da ROI, que permanece inalterada na etapa seguinte. Analisando a tabela 6.1, é possível verificar que, para todos os casos do conjunto de teste, a ROI é correctamente localizada, com maior ou menor resolução dos seus contornos. Para o aumento da resolução espacial da segmentação, foram aplicados os métodos de segmentação fina já descritos e cujos resultados são apresentados e discutidos de seguida.

6.2 Segmentação fina

Na tabela 6.4 são apresentados os resultados globais das segmentações finais, quer usando o AdaBoost, quer usando os contornos activos, relativamente ao resultado seleccionado do conjunto de segmentações iniciais, com SVM e AD, apresentados anteriormente.

Atentando aos resultados globais para a segmentação inicial, o primeiro facto a ressaltar prende-se com a sensibilidade algo baixa. Estes valores ficar-se-ão a dever a vários factores, sendo que o de maior influencia será o critério de seleção da maior área, utilizado para a escolha de exemplos de teste para a segunda fase do método de segmentação proposto. A aplicação deste critério reduz, directamente, a eficácia do processo no caso de imagens que contenham ROI múltiplas, como é o caso de algumas imagens que integram a base de dados usada no trabalho (figura 6.2). Deste modo, os algoritmos de segmentação fina, apesar de serem ambos aplicáveis a múltiplas regiões de uma mesma imagem, em simultâneo, encontram-se também limitados à partida.

Tabela 6.4: Resultados globais dos métodos de segmentação fina.

	Inicial	AdaBoost	Contornos activos
Acurácia	0.9727	0.9758	0.9770
Sensibilidade	0.6674	0.7646	0.7540
Precisão	0.8830	0.8726	0.8751

Outro dos factores que afectam os resultados da segmentação inicial relaciona-se, intrinsecamente, com as propriedades do descriptor de pixel usado para os classificadores. O uso da curvatura e da difusão não-linear em escalas mais altas causa a perda de definição espacial na segmentação, levando a que, na generalidade, os contornos obtidos sejam menores do que o pretendido. Contudo, o uso de escalas mais baixas para a segmentação inicial levaria a um aumento do ruído, pela segmentação de um maior número de áreas não relacionadas com as massas. A aplicação da seleção da maior área sobre as segmentações iniciais poderia atenuar estas consequências, sob pena, contudo, de expor os resultados a uma maior probabilidade de perder a localização correcta da ROI, no caso de existirem área com área superior a esta região. Finalmente, um outro factor afecta, globalmente, a sensibilidade do método de segmentação

proposto, tendo em conta que os resultados são avaliados relativamente a máscaras resultantes da segmentação manual, efectuada por um oncologista. Normalmente, devido ao fraco contraste dos ultrasons no que respeita aos limiares da imagem, a segmentação manual tende a definir contornos um pouco maiores, o que terá influência directa, ainda que não muito acentuada, na avaliação da qualidade das segmentações obtidas.

Analisando a tabela 6.4 e os exemplos de resultados obtidos pelos métodos de segmentação fina - AdaBoost (figura 6.1(c)) e contornos activos (figura 6.1(d)) - é possível confirmar que a sensibilidade é superior, relativamente à segmentação inicial (figura 6.1(b)). Estes resultados permitem afirmar que a resolução espacial das massas detectadas na primeira fase de segmentação é melhorada pela utilização de ambos os métodos de segmentação fina. Comparando os dois métodos, o algoritmo AdaBoost obtém uma melhoria de 9.7% na sensibilidade, enquanto os contornos activos permitem uma melhoria de 8.7%. Apesar do número superior de deteções de verdadeiros positivos, expressa na sensibilidade mais elevada, o método de contornos activos revelou, na generalidade, uma melhor definição dos contornos, após análise visual dos resultados (figuras 6.1(c) e 6.1(d)).

Em alguns casos, o resultado da segmentação inicial apresentam áreas muito inferiores às máscaras da segmentação manual. Por este motivo, alguns exemplos de aplicação do algoritmo AdaBoost são afectados, devido ao raio fixo do elemento estruturante usado para criar a região a classificar, levando a que não seja possível obter uma segmentação de toda a ROI (figura 6.4(c)). No entanto, evitando uma dilatação excessiva do resultado inicial, é reduzida a exposição a outras regiões que competem directamente com a massa a segmentar. Esta limitação poderia ser ultrapassada, com a definição de vários ciclos de segmentação, dilatando sequencialmente os resultados do AdaBoost. Contudo, seria necessária a definição de um critério de paragem, de forma a prevenir o afastamento da ROI.

No caso do contornos activos, estes ajustam-se aos contornos das massas desde o interior, relembrando que o contorno inicial é definido pelo resultado da segmentação inicial e, portanto, menos que o contorno ideal da ROI. Contudo, em alguns exemplos em que o contorno inicial seja afectado pela presença de falsos positivos, o contorno poderá afastar-se dos limiares da ROI, por influência do baixo contraste dos contornos da imagem e da falta da definição de uma restrição, que permite o alcance de sombras que estejam junto à massa a segmentar (figura 6.3(d)). O desvio do contorno activo da ROI aumenta o número de falsos positivos e pode levar à deformação do contorno, o que, em alguns casos, pode baixar a sensibilidade. A redução do número de iterações do algoritmo ajuda a reduzir a probabilidade de o contorno se desviar da ROI. Porém, reduziria igualmente a área segmentada, afectando também a sensibilidade do método.




Figura 6.1: Exemplo de resultados (1).




Figura 6.2: Exemplo de resultados (2).

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução




Figura 6.3: Exemplo de resultados (3).




Figura 6.4: Exemplo de resultados (4).

Capítulo 7

Considerações finais

Na presente dissertação foi proposta a aplicação de uma série de metodologias, tendo como objectivo a obtenção de um processo automatizado de segmentação de massas em imagens de ultrasons peitorais. Os métodos desenvolvidos foram testados numa base de dados de ultrasons, sendo que todos os exemplos utilizados continham massas - o objectivo central do trabalho consistia na definição dos contornos das massas, em detrimento da segmentação manual das mesmas, e não a criação de um sistema que detecte lesões caso existam.

De uma forma sumariada, o método proposto contempla duas fases distintas. Numa primeira fase, são constituídos descritores de pixel, com características multi-resolução:

- Difusão não-linear;
- Curvatura *scale-space*;
- Filtragem FIR passa-banda;

Usando este descriptor de pixel, foram testados classificadores binários - SVM e AD -, com o intuito de classificar os pixels de cada imagem como sendo positivos (pertencentes a massas) ou negativos. Os resultados destes classificadores foram submetidos a uma série de métodos heurísticos, para a melhoria de resultados e seleção da ROI.

Numa segunda fase, foram utilizados dois métodos distintos para a segmentação fina da área obtida inicialmente. O algoritmo AdaBoost, usando um descriptor de pixel, com características semelhantes às utilizadas na primeira segmentação mas obtidas em escalas mais baixas (Difusão não-linear e curvatura) e um algoritmo de contornos activos foram aplicados.

Os resultados experimentais revelam que a metodologia proposta é promissora para a segmentação de massas em ultrasons peitorais, podendo vir a ser aplicada como apoio na caracterização e no diagnóstico deste tipo de lesões. Conforme fora descrito anteriormente, as características das imagens de ultrasons dificultam a análise da imagem, desde logo, no estabelecimento de um processo totalmente automatizado. Os métodos aplicados revelam-se adequados na resposta às particularidades das imagens, tendo conseguido localizar correctamente, em todos os exemplos do conjunto de teste, as massas existentes.

Ainda assim, o trabalho realizado no âmbito desta dissertação deixa espaço a trabalho futuro, tendo como objectivo a melhoria dos resultados do método proposto. Em primeiro lugar, o alargamento da aplicação a uma base de dados mais extensa é necessária para uma melhor avaliação dos resultados apresentados neste trabalho.

Relativamente à fase de segmentação inicial, um estudo aprofundado sobre a *performance* de cada classificador seria importante, de modo a poder dispensar a bateria de classificadores testados neste trabalho. Juntamente com esta avaliação, um estudo sobre novas características da imagem que possam ser incluídas no descriptor de pixel e, ainda, a adaptação dos características já utilizadas poderão trazer melhorias para a etapa inicial de segmentação que, conforme sustentam os resultados apresentados neste trabalho, funciona como principal factor limitador

do método.

Em termos de definição dos contornos das massas, o procedimento proposto neste trabalho revelou algumas dificuldades. Apesar de, após análise visual aos resultados e por comparação com as máscaras de segmentação manual, a maioria dos casos revelar boa resolução espacial, em outros exemplos não foi possível contornar a totalidade das massas, devido a limitações derivadas da forma como a aplicação dos métodos da segunda fase foi definida. Porém, tais restrições e problemas de funcionamento são mais influenciadas pelos resultados da primeira fase do que pela metodologia implementada na segunda.

Finalizando, o trabalho realizado constitui uma boa base de trabalho para desenvolvimentos futuros, em direcção à criação de métodos simples e eficazes para o apoio ao diagnóstico do cancro da mama, usando a ultra-sonografia. A adequação destes métodos às imagens de ultrasons deixa em aberto a possibilidade da sua extensão a outro tipo de lesões ou outros tecidos.

Bibliografia

- [AH11] A. Abdelrahman and O. Hamid. Lesion boundary detection in ultrasound breast images. In *Biomedical Engineering (MECBME), 1st Middle East Conference on*, page 320. 2011. 6
- [BBGB98] D. Boukerroui, O. Basset, N. Guerin, and A. Baskurt. Multiresolution texture based adaptive clustering algorithm for breast lesion segmentation. *European Journal of Ultrasound*, 8(2):135-144, 1998. 9
- [BMCB⁺02] C. Balu-Maestro, C. Chapellier, A. Bleuse, I. Chanalet, C. Chauvel, and R. Largillier. Imaging in evaluation of response to neoadjuvant breast cancer treatment benefits of mri. *Breast Cancer Research and Treatment*, 72(2):145-152, 2002. 3
- [BSGRH04] N. Bouhlef, S. Sevestre-Ghalila, H. Rajhi, and R. Hamza. New markov random field model based on k-distribution for textured ultrasound image. *Medical imaging*, pages 363-372, 2004. 3
- [CCC⁺05] D. R. Chen, R. F. Chang, C. J. Chen, M. F. Ho, S. J. Kuo, S. T. Chen, S. J. Hung, and W. Moon. Classification of breast ultrasound images using fractal feature. *Clinical Imaging*, 29(4):235-245, 2005. 3, 7
- [CCC10] W. L. Chang, C. C. Chang, and W. M. Chen. Computer-aided diagnosis system for variance estimation of 3d ultrasonography based on gabor filter. In *Biomedical Engineering and Computer Science (ICBECS), 2010 International Conference on*, pages 1-4. 2010. 7, 8
- [CCCM03] D. R. Chen, R. F. Chang, W. M. Chen, and W. K. Moon. Computeraided diagnosis for 3-dimensional breast ultrasonography. *Arch Surg*, 138(3):296-302, 2003. 3
- [CCK⁺02a] D. R. Chen, R. F. Chang, W. J. Kuo, M. C. Chen, and Y. L. Huang. Diagnosis of breast tumors with sonographic texture analysis using wavelet transform and neural networks. *Ultrasound in Medicine and Biology*, 28(10):1301-1310, 2002. 10
- [CCK⁺02b] D. R. Chen, R. F. Chang, W. J. Kuo, M. C. Chen, and Y. L. Huang. *Diagnosis of breast tumors with sonographic texture analysis using wavelet transform and neural networks*. *Ultrasound in Medicine and Biology* 28 (10), 2002. 10
- [CCK⁺05] W. M. Chen, R. F. Chang, S. J. Kuo, C. S. Chang, W. Moon, S. T. Chen, and D. R. Chen. 3-d ultrasound texture classification using run difference matrix. *Ultrasound in Medicine and Biology*, 31(6):763-770, 2005. 3
- [CKC⁺02] D. R. Chen, W. J. Kuo, R. F. Chang, W. K. Moon, and C. C. Lee. Use of the bootstrap technique with small training sets for computer-aided diagnosis in breast ultrasound. *Ultrasound in Medicine and Biology*, 28(7):897-902, 2002. 3
- [CSJ⁺10] D. Cheng, J. Shan, W. Ju, Y. Guo, and L. Zhang. Automated breast cancer detection and classification using ultrasound images: A survey. *Pattern Recognition*, 43(1):299-317, 2010. 8
- [CV01] T.F. Chan and L.A. Vese. Active contours without edges. *Image Processing, IEEE Transactions on*, 10(2):266 -277, feb 2001. 22

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

- [CWM⁺03] R. Chang, W. Wu, W. K. Moon, Y. Chou, and D. Chen. Support vector machines for diagnosis of breast tumors on US images. *Academic Radiology*, Vol, 10, February 2003. 1, 17
- [CWMC05] R. F. Chang, W. J. Wu, K. Moon, and D. R. Chen. Automatic ultrasound segmentation and morphology based diagnosis of solid breast tumors. *Breast Cancer Research and Treatment*, 89(2):179-185, 2005. 3, 9
- [DCSJ10] C. DeSantis, M. M. Center, R. Siegel, and A. Jemal. *Breast cancer facts and figures 2009-2010*. American Cancer Society, 2010. 1
- [DGH⁺02] K. Drukker, M. L. Giger, K. Horsch, M. A. Kupinski, C. J. Vyborny, and E. B. Mendelson. *Computerized lesion detection on breast ultrasound*. *Medical Physics* 29(7), 2002. 10
- [ES08] D. Ensminger and F. B. Stulen. *Ultrasonics: Data, equations, and their practical uses*. January 2008. 1
- [FS99] Y. Freund and R. E. Schapire. A short introduction to boosting. *Journal of Japanese Society for Artificial Intelligence*, 14(5):771-780, 1999. 21
- [FSSH82] V. Frost, J. Stiles, K. Shanmugan, and J. Holtzman. A model for radar images and its application to adaptive digital filtering of multiplicative noise. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 4(2):157-166, 1982. 6
- [HC04] Y. L. Huang and D. R. Chen. *Watershed segmentation for breast tumor in 2-D sonography*. *Ultrasound in Medicine and Biology* 30, 2004. 10
- [HJCM07] Y. L. Huang, Y. R. Jiang, D. R. Chen, and W. Moon. Level set contouring for breast tumor in sonography. *Journal of Digital Imaging*, 20:238-247, 2007. 3, 9
- [HR02] W. R. Hendee and E. R. Ritenour. *Medical imaging physics*. January 2002. 1
- [HRL10] Y. L. Huang, C. D. R., and Y. K. Liu. Breast cancer diagnosis using image retrieval for different ultrasonic systems. In *International Conference on Image Processing*, volume 5, pages 2957-2960. 2010. 7
- [IG98] E. Izquierdo and M. Ghanbari. Texture smoothing and object segmentation using feature-adaptive weighted gaussian filtering. In *ITS Proceedings. SBT/IEEE International*, volume 2, pages 650 -655 vol.2, aug 1998. 6
- [JRIM10] A. Jumaat, W. Rahman, A. Ibrahim, and R. Mahmud. Comparison of balloon snake and gvf snake in segmenting masses from breast ultrasound images. In *Computer Research and Development*, page 505. 2010. 9
- [JYMK04] S. Joo, Y. S. Yang, W. K. Moon, and H. C. Kim. Computer-aided diagnosis of solid breast nodules: use of an artificial neural network based on multiple sonographic features. *Medical Imaging, IEEE Transactions on*, 23(10):1292-1300, 2004. 6, 8
- [Krz88] W. J. Krzanowski. *Principles of Multivariate Analysis: A User's Perspective*. New York: Oxford University Press, 1988. 19
- [KSSC85] D. Kuan, A. Sawchuk, T. Strand, and P. Chavel. Adaptive noise smoothing filter for images with signal-dependent noise. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 7(2):165-177, 1985. 6

Segmentação de Massas em Ultrasons Peitorais usando Técnicas Multiresolução

- [KWT87] M. Kass, A. Witkin, and D. Terzopoulos. Snakes - active contour models. *International Journal of Computer Vision*, 1987. 22
- [LBL+05] F. Levi, C. Bosetti, F. Lucchini, E. Negri, and C. La Vecchia. Monitoring the decrease in breast cancer mortality in europe. *European Journal Cancer Prev.*, 14(6):497-502, 2005. 1
- [Lee80] J. Lee. Digital image enhancement and noise filtering by use of local statistics. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2(2):165-168, 1980. 6
- [LHZ05] Xu Liu, Zhimin Huo, and Jiwu Zhang. Automated segmentation of breast lesions in ultrasound images. In *27th IEEE-EMBS.*, pages 7433 -7435, jan. 2005. 10
- [LMF+00] F. Lefebvre, M. Meunier, T. F., P. Laugier, and G. Berger. Computerized ultrasound b-scan characterization of breast nodules. *Ultrasound in Medicine and Biology*, 26(9):1421-1428, 2000. 3
- [PM90] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(7):629-639, jul 1990. 11
- [SaMRH+04] B. Sahiner, H. P. Chan abd M. Roubidoux, M. Helvie, L. Hadjiiski, A. Ramachandran, C. Paramagul, G. LeCarpentier, A. Nees, and C. Blane. Computerized characterization of breast masses on three-dimensional ultrasound volumes. *Medical Physics*, 31(4):744-754, 2004. 3
- [Sar10] A.-I. Sarpe. Image segmentation with clustering k-means and watershed transform. In *Advances in Multimedia (MMEDIA), 2010 Second International Conferences on*, pages 13 -17, june 2010. 8
- [SCBP12] I. Soares, M. Castelo-Branco, and A.M.G. Pinheiro. Curvature detection and segmentation of retinal exudates. In *ISBI 2012*, may 2012. 15
- [SCH+10] X. Shi, H. Cheng, L. Hu, W. Ju, and J. Tian. Detection and classification of masses in breast ultrasound images. *Digital Signal Processing*, 20(3):824-836, 2010. 7
- [Seb84] G. A. F. Seber. *Multivariate Observations*. Hoboken, NJ: John Wiley and Sons, Inc., 1984. 19
- [SFC+06] M. Sant, S. Francisci, R. Capocaccia, A. Verdecchia, C. Allemani, and F. Berrino. Time trends of breast cancer survival in europe in relation to incidence and mortality. *International journal of cancer*, 119(10):2417-2422, 2006. 1
- [SPH09] Jong-Jy Shyu, Soo-Chang Pei, and Yun-Da Huang. Design of variable two-dimensional fir digital filters by mccllellan transformation. *Circuits and Systems I: Regular Papers, IEEE Transactions on*, 56(3):574 -582, march 2009. 14
- [SSS07] S. Sudha, G.R. Suresh, and R. Sukanesh. Wavelet based image denoising using adaptive thresholding. In *Conference on Computational Intelligence and Multimedia Applications, 2007. International Conference on*, volume 3, pages 296 -300, dec. 2007. 7

- [SYWH04] J. Segyeong, S. Y. Yoon, K. M. Woo, and C. K. Hee. Computer-aided diagnosis of solid breast nodules: use of an artificial neural network based on multiple sonographic features. *IEEE Transactions on Medical Imaging* 23(10), 1292-1300., 2004. 10
- [TLC+10] P. H. Tsui, Y. Y. Liao, C. C. Chang, W. H. Kuo, K. J. Chang, and C. K. Yeh. Classification of benign and malignant breast tumors by 2-d analysis based on contour description and scatterer characterization. *Medical Imaging, IEEE Transactions on*, 29(2):513-522, 2010. 3
- [VESS04] F. Voci, S. Eiho, N. Sugimoto, and H. Sekibuchi. Estimating the gradient in the perona-malik equation. *Signal Processing Magazine, IEEE*, 21(3):39 - 65, may 2004. 11
- [VJ01] P. Viola and M. Jones. Rapid object detection using a boosted cascade of simple features. In *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*, volume 1, pages I-511 - I-518 vol.1, 2001. 7, 21
- [WM08] W. J. Wu and W. Moon. Ultrasound breast tumor image computeraided diagnosis with texture and morphological features. *Academic Radiology*, 15(7):873-880, 2008. 9
- [YCFC] C. K. Yeh, Y. S. Chen, W. Z. Fan, and W. S. Chen. A novel method for automatic contour extraction of ultrasonic breast lesions. In *Ultrasonics Symposium*, volume 2, pages 1384-1387. 8
- [YEB08] M. Yap, E. Edirisinghe, and H. Bez. A novel algorithm for initial lesion detection in ultrasound breast images. *Journal of applied clinical medical physics American College of Medical Physics*, 9(4):2741, 2008. 6, 8
- [ZLL+07] L. Zhong, J. Lin, D. Li, T. Wang, Y. Peng, and Y. Luo. Classification of breast tumors on ultrasound images using a hybrid neural network. In *Bioinformatics and Biomedical Engineering, ICBBE 2007, The 1st International Conference on*, pages 574-576. 2007. 3
- [ZRHL11] Ling Zhang, Yuping Ren, Chencheng Huang, and Fushan Liu. A novel automatic tumor detection for breast cancer ultrasound images. In *FSKD, Eighth International Conference on*, volume 1, pages 401 -404, july 2011. 8

Apêndice A

Anexos

R. Rodrigues, A.M.G. Pinheiro, M. Pereira, R. Braz, and J. Moutinho. *Towards breast ultrasound image segmentation using multi-resolution pixel descriptors*. In Pattern Recognition (ICPR), 2012 21st International Conference on, Tsukuba, Japan, nov, 2012.

R. Rodrigues and A.M.G. Pinheiro. *A Two-stage Mass Segmentation Method for Breast Ultrasound Images*. In 18th Portuguese Conference on Pattern Recognition (RecPad 2012), Coimbra, Portugal, oct 2012.

Towards Breast Ultrasound Image Segmentation using Multi-resolution Pixel Descriptors

Rafael Rodrigues, António Pinheiro
Remote Sensing Unit
a19635@ubi.pt, pinheiro@ubi.pt

Rui Braz, Manuela Pereira
Inst. de Telecomunicações

J. Moutinho
Fac. Ciências Saúde

Universidade da Beira Interior - Portugal

Abstract

Breast ultrasound images are an important diagnostic factor for breast cancer detection. However, ultrasound imaging is intrinsically degraded by noise, resulting in a difficult detection of masses or nodules, and, most importantly, the evaluation of their size and shape. Computer-aided diagnosis figures as a major help factor, when it comes to analyzing this type of medical imaging. A fully automated and computationally efficient method for breast ultrasound segmentation is proposed. The algorithm classifies the images, with Support Vector Machines and Discriminant Analysis classifiers, based on a pixel descriptor formed with the information from anisotropic diffusion, band-pass filtering and scale-space curvature. The final segmentation results after the application of a set of heuristic rules for the selection of the classifiers' result, based on the ultrasound image characteristics. The final segmentation results yielded good overall accuracy, precision and also recall rates.

1. INTRODUCTION

Breast cancer is one of the major mortality causes among women, with special incidence in developed countries. Early detection of masses and nodules can help to reduce the mortality rate [1, 9]. Thus, imaging techniques are an important step towards breast cancer diagnosis. Different techniques are used by radiologists including mammography, magnetic resonance imaging and ultrasound imaging. Being practically harmless and due to its non-invasiveness, real-time diagnosis capabilities and cost effectiveness, breast ultrasound imaging has been emphasized as a valuable method for early cancer detection and diagnosis [1, 9]. Typically ultra-

sound images contain a large amount of high-frequency noise that is intrinsic to the imaging acquisition process. Moreover, the appearance of shadows and other artefacts that degrade the image quality are common in this type of technique. The presence of noise and artefacts can result in a difficult breast ultrasound images analysis, requiring experienced radiologists [1, 9].

For this reason, the introduction of computer-aided diagnosis became an important helping factor for radiologists. Several image segmentation methods have been proposed to respond to this problem [1, 3, 4, 9]. However, many of them require manual selection of the region of interest (ROI), not being fully automated and depending the mass location and segmentation on the initial region selection [9]. Furthermore, the characteristics of ultrasound images often cause problems when applying image processing methods. Thus, the features selection becomes an important factor, when trying to classify breast cancer images.

In this paper, we describe the application of a fully automatic mass segmentation method to classify breast ultrasound images, using Support Vector Machines (SVM) or Discriminant Analysis. The features used to classify the image pixels result from a set of multi-resolution image processing methods. Those methods will create a pixel descriptor obtained from band-pass FIR filtering [6], scale-space curvature [7] and non-linear diffusion [5] of the image.

2. METHODS

2.1. Image processing

In order to classify the Ultrasound images, Support Vector Machines (SVM) and Discriminant Analysis methods were applied, using a pixel descriptor with 5 different features. The features considered were

the non-linear diffusion [5] result after 60 iterations, 2 band-pass FIR filter [6] outputs with band pass intervals of $0.031\pi < \omega_1 < 0.056\pi$ and $0.056\pi < \omega_2 < 0.1\pi$ respectively of the original image, and 2 different mean curvature measures, taken from Gaussian smoothing of the original image on scales $t = 200$ and $t = 300$ [2, 7].

The non-linear diffusion of the images I_{dif} was obtained through the method described by Perona and Malik, using an adaptive constant K computation for each iteration [5]. The histogram of the absolute values of the gradient in every iteration is computed K was set to 90% of its integral. The conduction coefficients were computed using the Charbonier conductivity function [8]:

$$g(\nabla I) = \frac{1}{1 + \left(\frac{\|\nabla I\|}{K}\right)^2} \quad (1)$$

where ∇I refers to the intensity gradient. This diffusivity function privileges the conservation of wide regions, promoting intraregion smoothing and thus reducing the influence of noise.

The non-linear diffusion images incorporated in the pixel descriptors were obtained with 60 iterations and the constant $\lambda = 1/8$ (figure 1(b)).

Moreover, considering the original image, band-pass FIR filtering of the images was performed, obtaining two different results, both used as descriptors: I_{bp1} , a lower band-pass ($0.031\pi < \omega < 0.056\pi$) and I_{bp2} , a higher band-pass filtering ($0.056\pi < \omega < 0.1\pi$) (figures 1(c) and 1(d)). The filter was obtained using the McClellan transformation over a 1-D FIR filter with $N = 150$ [6]. Both band-pass filters provide valuable information on region transitions, while rejecting most of the high-frequency noise components.

Another image processing technique that produces effective features for the proposed classification method is the scale space curvature. It consists on computing the mean curvature of Gaussian filtered image [7]. Despite having poor spatial definition, unlike the non-linear diffusion, Gaussian smoothing also reduces directly the presence of high frequency components that compromise the definition of edges between regions of the image and deteriorate the stability within those regions [2]. Firstly, Gaussian smoothing was performed on the original image, over a series of iterations. The Gaussian filter F_{gauss} consisted on a 5×5 square matrix. Filter size and standard deviation σ were constant on all iterations, being $\sigma^2 = \frac{\sqrt{2}}{2}$.

Two curvature scales were used. The first one with 200 iterations. The second, with 300 iterations (figures 1(e) and 1(f)). Considering these Gaussian smoothing results, the principal curvatures L_{xx} and L_{yy} were computed. The use of Gaussian smoothing, prior to the

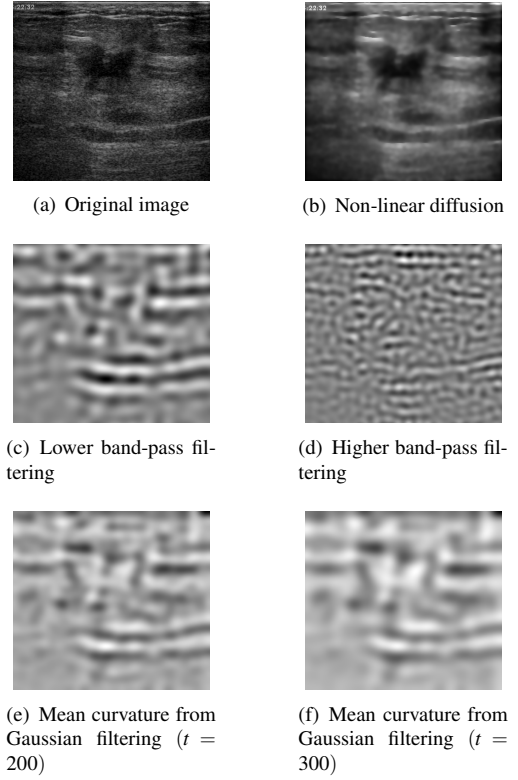


Figure 1. Original image and pixel descriptor components.

computation of the mean curvature, seeks to reduce the influence of noise, which would degrade the curvature results as it represents a mapping of the intensity variation on the image [7]. L_{xx} and L_{yy} are second order directional derivatives of the Gaussian smoothed image I_{gauss} . These derivatives were obtained numerically by calculating initially the gradients L_x and L_y as shown in the following equations:

$$L_x(i, j) = I_{gauss}(i, j) - I_{gauss}(i + 1, j) \quad (3)$$

$$L_y(i, j) = I_{gauss}(i, j) - I_{gauss}(i, j + 1) \quad (4)$$

Then, the second order gradients were calculated in a similar manner:

$$L_{xx}(i, j) = L_x(i, j) - L_x(i + 1, j) \quad (5)$$

$$L_{yy}(i, j) = L_y(i, j) - L_y(i, j + 1) \quad (6)$$

Finally, the mean curvature H was calculated computing the arithmetic mean of the principal curvatures [7]. Considering that the principal curvatures k_1 and k_2 correspond to L_{xx} and L_{yy} , the mean curvature expression can be reformulated:




Figure 2. Example of outputs: SVM classifier (POLY-SVM), Image border cleaning and Morphological opening.

$$H = \frac{L_{xx} + L_{yy}}{2} \quad (7)$$

The mean curvature of the images has local *maxima* in the inflexion points localizations. In these points, a pronounced variation of the intensity occurs. Therefore, the curvature yields a good representation of region transitions.

2.2. SVM and Discriminant Analysis training

The SVM and Discriminant Analysis classifiers training dataset consisted on the aforementioned descriptors' information, retrieved from 654 pixels randomly selected from 2 ultrasound images. The respective binary mask images containing the image segmentations have been manually segmented by a oncologist. The training samples were selected close to the mask border. For that, the mask was dilated and eroded using morphological operations with different sized circular structuring elements. These operations resulted in the creation of a strip of positive pixels and another of negative pixels surrounding the true edge pixels from the mask. From those two strips 20% pixels locations were randomly selected for the two training sets, resulting in 313 positive pixels and 341 negative pixels (the strip outside the mask is larger, resulting in a larger number of negative samples).

2.3. SVM and Discriminant Analysis classification

The image processing methods were applied to define the pixels descriptors of a database of 10 grayscale ultrasound images. Those descriptors were classified with a SVM classifier using the Linear, Quadratic, Polynomial, Radial Basis Function and the Multilayer Perceptron kernels, and also the Discriminant Analysis classification using the types Linear, Quadratic, Diagonal Linear, Diagonal Quadratic and Mahalanobis Distance.

Table 1. Specificity results for every classifier and different ROI definition method.

Classifier	Opening Selection	Largest Area
LIN-SVM	48,21%	48,06%
QUAD-SVM	60,53%	49,88%
POLY-SVM	64,38%	64,19%
RBF-SVM	49,72%	44,36%
MLP-SVM	37,12%	26,37%
LIN-DA	58,64%	56,11%
QUAD-DA	51,58%	40,98%
DIAGLIN-DA	0%	1,86%
DIAGQUAD-DA	10,16%	10,01%
MHLN-DA	18,98%	15,05%

2.4. ROI selection

After the SVM and Discriminant Analysis image pixel classification, a filling operation was performed. This step took into consideration the fact that the training dataset was composed by edge pixels. Therefore, it was expected that some segmentation results presented closed edges, containing holes inside segmented objects. Afterwards, several methods were applied to those binary images, as an approach to improve the results. Object labelling was first applied to the classifiers output. Then, any foreground region connected to the borders of the images was suppressed, assuming that they were not part of the ROI. Most of these objects result from artefacts or shadows in the ultrasound images that tend to be considered as ROI, because of their similar grayscale intensity values. This object suppressing operation yielded binary images containing the ROI and, in most cases, small misclassified isolated objects that were considered as noise.

To reduce the influence of these small objects in the final results, different approaches were considered. The first of these approaches implied the execution of morphological opening over the images, using an eight pixel radius circular structuring element (figure 2(c)). For the final segmentation results, regions that were not suppressed by the opening operation were retrieved, maintaining the original shape, prior to the morphological operation (figure 3(b)). Suppressed regions were removed from the final results. The second approach consisted on selecting only the largest area region. Both methods considered that the ROIs have a larger area than misclassified objects.

3. RESULTS AND DISCUSSION

In this section, we present an overview of the image processing and final segmentation results. Moreover the classification performance measures are also reported.

Table 2. Recall, Accuracy and Precision rate.

Classifier	Recall		Accuracy		Precision	
	Opening Selection	Largest Area	Opening Selection	Largest Area	Opening Selection	Largest Area
LIN-SVM	97,77%	98,31%	94,04%	94,53%	95,91%	95,92%
QUAD-SVM	95,97%	98,48%	92,79%	94,06%	96,26%	95,30%
POLY-SVM	95,78%	99,03%	93,15%	96,14%	96,78%	96,86%
RBF-SVM	95,98%	98,87%	91,85%	93,94%	95,23%	94,83%
LIN-DA	95,67%	97,59%	92,42%	93,88%	96,10%	95,93%


Figure 1 shows an example of pixel descriptor components, for the original image in 1(a). In figure 2 both the initial classification results and the result of the image border cleaning operation are shown. It is evident that this simple step brings great effectiveness to the algorithm, eliminating a great area of shadow and artefacts related to misclassified regions. The initial classification step assumes the importance of defining the contour of the ROI, which remains unaltered through the following steps.

Specificity results for every SVM and Discriminant Analysis classifier are shown in table 1. Low specificity results are an indication of the influence of misclassified isolated regions, present in some segmentation results.

Table 2 presents the recall rate, accuracy and precision of the 5 classifiers that achieved better global specificity results, considering the two ROI selection operations. These values indicate that, globally, the proposed method correctly locates the ROI. However, all classifiers yielded a slightly smaller segmented region when compared to manual segmentation masks. Hence, these measures diverge lightly from its possible maximum values. Using new descriptor features extracted in low scales, as well as tuning the features used in the present algorithm may help to improve these results.

Figure 3 shows an example of the final segmentation results, obtained using the SVM classifier with the Polynomial kernel and both ROI selection methods. It is possible to conclude that the largest area selection gives the best overall results (figure 3(c)). However the selection of the largest area will miss a second ROI area, in case it exists. Using only the selection from the morphological opening yields misclassified areas in the final result, as shown in figure 3(b). If a larger structuring element is used, fewer areas will result. However, ROI small areas may also be suppressed.

The proposed method results in an effective and reliable solution mass segmentation in breast ultrasound images. These methods yield a fully automated process, that relies on a set of image features applied to a classification method and some heuristic rules. Presently, a larger Ultrasound images database is being collected, which might allow the extension of the algorithm application to a larger database in the near future.

**Figure 3. Final segmentation results.**

References

- [1] H. Cheng, J. Shan, W. Ju, and et al. Automated breast cancer detection and classification using ultrasound images: A survey. *Pattern Recognition*, 43(1):299 – 317, 2010.
- [2] E. Izquierdo and M. Ghanbari. Texture smoothing and object segmentation using feature-adaptive weighted gaussian filtering. In *ITS Proceedings. SBT/IEEE International*, volume 2, pages 650 –655 vol.2, aug 1998.
- [3] A. Jumaat, W. Rahman, A. Ibrahim, and R. Mahmud. Segmentation and characterization of masses in breast ultrasound images using active contour. In *IEEE ICSIPA*, pages 404 –409, nov. 2011.
- [4] X. Liu, Z. Huo, and J. Zhang. Automated segmentation of breast lesions in ultrasound images. In *27th IEEE-EMBS.*, pages 7433 –7435, jan. 2005.
- [5] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(7):629–639, jul 1990.
- [6] J.-J. Shyu, S.-C. Pei, and Y.-D. Huang. Design of variable two-dimensional fir digital filters by mcllellan transformation. *Circuits and Systems I: Regular Papers, IEEE Transactions on*, 56(3):574 –582, march 2009.
- [7] I. Soares, M. Castelo-Branco, and A. Pinheiro. Curvature detection and segmentation of retinal exudates. In *ISBI 2012*, may 2012.
- [8] F. Voci, S. Eiho, N. Sugimoto, and H. Sekibuchi. Estimating the gradient in the perona-malik equation. *Signal Processing Magazine, IEEE*, 21(3):39 – 65, may 2004.
- [9] L. Zhang, Y. Ren, C. Huang, and F. Liu. A novel automatic tumor detection for breast cancer ultrasound images. In *FSKD, Eighth International Conference on*, volume 1, pages 401 –404, july 2011.

A Two-stage Mass Segmentation Method for Breast Ultrasound Images

Rafael Rodrigues
jrafael.ubi@gmail.com

António M.G. Pinheiro
pinheiro@ubi.pt

Unidade de Detecção Remota
Universidade da Beira Interior
Covilhã, Portugal

Abstract

Breast ultrasound images offer several attractive properties which make them suitable and an interesting tool for breast cancer detection. However, due to their intrinsic high noise rate and low contrast properties, mass detection and segmentation becomes a challenging task. In this paper, a semi-automated two-stage breast mass segmentation method is proposed. Initially, ultrasound images are segmented using Support Vector Machines or Discriminant Analysis with a multi-resolution pixel descriptor extracted using non-linear diffusion, band-pass filtering and scale-space curvature. A set of heuristic rules complements the initial segmentation task, selecting the ROI in a fully automated manner. In the second segmentation stage, two different methods are used to attempt a refined segmentation of the area retrieved in the first stage. The first uses an AdaBoost algorithm, using curvature measures and non-linear diffusion of the original image at lower scales, and in the second active contours are applied to improve the spatial resolution of the ROI.

1 Introduction

Breast cancer is one of the major mortality causes among women, with special incidence in developed countries. Early detection and diagnosis of masses and nodules is crucial to reduce the mortality rate [2, 10]. Imaging techniques are an important aid for breast cancer diagnosis. Several different techniques are commonly used by radiologists including ultrasound images, mammography and magnetic resonance. Ultrasound imaging is a harmless, non-invasive and cost effective diagnosis method that offers real-time diagnosis capabilities. For its attractive properties it has been emphasized as a valuable tool for early breast cancer detection and diagnosis [2].

Due to the image acquisition process, ultrasound images typically contain a large amount of high-frequency noise rates and low contrast properties. In addition, this type of image commonly present shadows and other artefacts that result in a difficult analysis of the exam, even for experienced radiologists [2]. Thus, computer-aided diagnosis becomes an important help factor for radiologists. Several image segmentation methods have been proposed to respond to this problem [2, 3, 4, 10]. Nevertheless, many segmentation methods require manual selection of the region of interest (ROI) and typical ultrasound image characteristics make the segmentation of masses a difficult task.

The proposed framework implements a two-step automated method, depending the selection of the final result on human decision. The first stage uses Support Vector Machines (SVM) or Discriminant Analysis (DA) to obtain an initial segmentation. A second approach based on the initial segmentation uses AdaBoost classifiers or active contour segmentation to improve spatial resolution.

2 Methods

2.1 Initial segmentation

The ultrasound images were initially segmented with the method described in [7], applying SVM or DA with several multi-resolution features. The features included in the pixel descriptor were the non-linear diffusion [5] of the original image after 60 iterations using the Charbonnier conductivity equation, with $\lambda = 1/8$ and using an adaptive K set to match 90% of the integral of the gradient histogram, two band-pass FIR filter outputs [8] obtained with two different passbands - $0.031\pi < \omega_1 < 0.056\pi$ and $0.056\pi < \omega_2 < 0.1\pi$ - and two different mean curvature measures of the gaussian smoothing outputs [9], at scales $t = 200$ and $t = 300$. These features are classified with a SVM classifier [6] using the Linear, Quadratic,

Polynomial, Radial Basis Function and the Multilayer Perceptron kernels and a DA classifier using the types Linear, Quadratic, Diagonal Linear, Diagonal Quadratic and Mahalanobis Distance. The SVM and DA training dataset consisted on the aforementioned descriptors' information, retrieved from 654 pixels randomly selected from 2 ultrasound images. The respective binary segmentation masks have been manually segmented by an oncologist. The training dataset was formed with 323 positive pixels and 331 negative pixels, retrieved from two strips around the mask edge. This segmentation step was performed in a set of 20 ultrasound images containing masses. Considering the results of the initial segmentation task, heuristic methods were applied to those results as an attempt to select the ROI and eliminate misclassified regions. Objects connected to the image borders were suppressed and the output of this operation was subjected to a binary filling operation, closing holes inside regions. In order to retrieve a ROI for subsequent segmentation tasks it is desirable to select only one region among all regions classified as foreground. Thus, the largest area object was selected which is used as a starting point for the refining segmentation stage.

2.2 Refined ROI segmentation

The second stage of the proposed segmentation method attempts to improve the spatial resolution of the initial segmentation. For that purpose, two distinct methods were applied. In both methods, the results from the largest area selection performed in the first stage are used as starting points, indicating the ROI location. Considering that several SVM and DA kernels were tested in the initial segmentation of the images, yielding a set of 10 results for each image, a simple selection criteria was imposed to simplify the analysis of the refined segmentation performance. Only results with better accuracy were used.

2.2.1 Segmentation using AdaBoost

One of the methods applied to refined segmentation of the ROI uses an AdaBoost classifier [6] on a dilated region around the initial segmented area. The AdaBoost algorithm relies on a simple weak classifier, that establishes a threshold for each feature or data dimension individually, which divides data samples in two classes. This classifier is called iteratively, adapting the threshold in each data dimension to minimize the classification error. The training phase yields a model that stores the sequence of data dimensions and thresholds that minimize the training error. The pixel descriptor used for this segmentation step was constructed with features similar to some of those applied to the classifiers in the initial stage. However, different parametrization was used allowing the improvement of the spatial resolution of the output. Moreover, focusing on smaller areas around the masses directly reduces the presence of noise and other objects that competed directly with the ROI on the initial segmentation. Thus, lower scale curvature measures and non-linear diffusion outputs were chosen, based on their better spatial resolution when compared to the scales used previously.

The AdaBoost training samples were retrieved based on the true segmentation mask of the training image. The negative training dataset retrieved 50% of the pixels located in a strip defined around the segmentation mask. The positive training dataset was formed using 20% of true positive mask pixels. The training dataset contained 2429 points, from which 1392 were positive samples and 1037 were negative. The classifier was trained and applied to the images with 200 iterations. The features included in the pixel descriptor were scale-space curvature measures at scales $t = 20$ and $t = 30$ and non-linear diffusion of the original image after 30 iterations using the Charbonnier conductivity equation, with $\lambda = 1/8$ and adaptive K set to match 90% of the integral of the gradient histogram. In the clas-

sifying phase, the initial segmentation masks were dilated with a circular shaped structuring element with radius 8. This value was defined after experimentation, to maintain a trade-off between the selection of the biggest possible area without losing focus on the ROI. Only the pixels inside the dilated region were considered as inputs to the AdaBoost classifier, while pixels outside this area were automatically considered as background.

2.2.2 Segmentation using Active Contours

The other method applied for segmentation refining of the masses relies on active contours without edges. The algorithm implements the method described in [1]. Similarly to the AdaBoost methods, results from the SVM and DA segmentation were selected using the maximum accuracy criteria. The initial ROI segmentation was used to define the initial contour for the algorithm.

Active contours were applied with 200 iterations. The output of the algorithm was submitted to the selection of the largest area object, in order to eliminate any objects resulting from the defragmentation of the main contour, to produce the final segmentation.

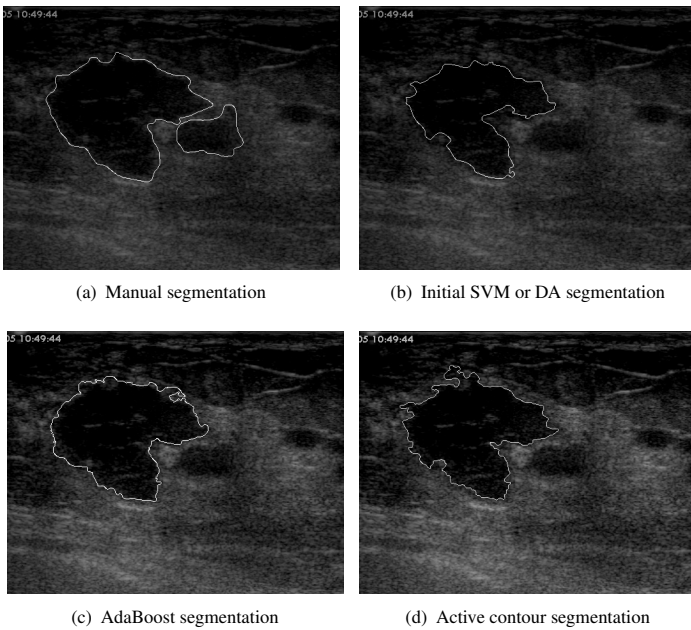


Figure 1: Example of segmentation outputs.

3 Results

In table 1 are presented the overall segmentation performance measures. The somewhat low recall rates are due to two major factors. Firstly, the largest area criteria used to select the ROI directly reduces the efficiency of the algorithm in cases with multiple ROI. In this database, some of the images present two masses. Although the refined segmentation methods are applicable to more than one region simultaneously, further application results would be limited *a priori* (figure 1(a), 1(b)). Another factor, directly related to the properties of the initial segmentation algorithm, is the loss of spatial resolution resulting from high non-linear diffusion and curvature scales. Nevertheless, using lower scales on the entire image could result in the loss of ROI detection and increase the segmentation noise. For this reason, the segmentation refining methods are applied. Furthermore, human segmentation masks used to evaluate segmentation performance tend to define larger contours, due to poor edge definition of the images, which also has an influence on recall rates.

Both AdaBoost and active contour methods achieve higher overall recall rates than the initial segmentation algorithm using SVM or DA, indicating that the spatial resolution of the detected masses is improved (figure 1(b), 1(c), 1(d)). Comparing directly the two refined segmentation methods, AdaBoost improves the recall rate in 9.7%, while active contours improve this measure in 8.7%.

In some cases, the initial segmentation outputs are much smaller than true positive masks. This affects some AdaBoost segmentations due to the fixed size of the structuring element that dilates the initial mask, meaning that it may not be possible to obtain a full segmentation of the ROI. This

	Initial	AdaBoost	Active Contour
Accuracy	0.9727	0.9758	0.9770
Recall	0.6674	0.7646	0.7540
Precision	0.8830	0.8726	0.8751

Table 1: Segmentation performance measures.

shortcoming of the AdaBoost method might be improved, defining several segmentation cycles sequentially dilating the output of the previous segmentation. However, a stopping criteria would be necessary to prevent deviation from the ROI. On the other hand, this constriction focuses the AdaBoost on the ROI detected initially by the SVM or the DA classifiers, meaning that other image regions that might compete with the mass are out of reach.

When using active contours, these are adjusted to the mass contour from the inside, considering the properties of most initial segmentations. However, in some examples, where the initial contour is influenced by false positives in the initial segmentation, the contour can depart from the ROI, due to low contrast resolution in edges and the lack of a limiting region, exposing the active contour to shadows nearby the ROI (figure 1(d)). This deviation directly increases false positive occurrences and can lower recall rates due to the deformation of the contour.

Both proposed pathways achieve promising segmentation results, however, with some drawbacks, mainly regarding the overall recall rates. These could influence the clinical decision, leading to inaccurate diagnosis in terms of tumor size and shape. Although the refinement of the segmentation boosts the final results, the improvement of the training samples in the first stage (SVM or DA classification) or the introduction of new features may help to further reduce this limitation of the proposed methods.

References

- [1] T.F. Chan and L.A. Vese. Active contours without edges. *Image Processing, IEEE Transactions on*, 10(2):266–277, feb 2001.
- [2] H.D. Cheng, Juan Shan, Wen Ju, and et al. Automated breast cancer detection and classification using ultrasound images: A survey. *Pattern Recognition*, 43(1):299–317, 2010. ISSN 0031-3203.
- [3] A.K. Jumaat, W.E.Z.W.A. Rahman, A. Ibrahim, and R. Mahmud. Segmentation and characterization of masses in breast ultrasound images using active contour. In *IEEE ICSIPA*, pages 404–409, nov. 2011.
- [4] Xu Liu, Zhimin Huo, and Jiwu Zhang. Automated segmentation of breast lesions in ultrasound images. In *27th IEEE-EMBS.*, pages 7433–7435, jan. 2005.
- [5] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(7):629–639, jul 1990.
- [6] A. Quddus, P. Fieguth, and O. Basir. Adaboost and support vector machines for white matter lesion segmentation in mr images. In *Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the*, pages 463–466, 2005.
- [7] R. Rodrigues, A.M.G. Pinheiro, M. Pereira, R. Braz, and J. Moutinho. Towards breast ultrasound image segmentation using multi-resolution pixel descriptors. In *Pattern Recognition (ICPR), 2012 21st International Conference on*, nov. 2012.
- [8] Jong-Jy Shyu, Soo-Chang Pei, and Yun-Da Huang. Design of variable two-dimensional fir digital filters by mcellellan transformation. *Circuits and Systems I: Regular Papers, IEEE Transactions on*, 56(3):574–582, march 2009.
- [9] I. Soares, M. Castelo-Branco, and A.M.G. Pinheiro. Curvature detection and segmentation of retinal exudates. In *ISBI 2012*, may 2012.
- [10] Ling Zhang, Yuping Ren, Chencheng Huang, and Fushan Liu. A novel automatic tumor detection for breast cancer ultrasound images. In *FSKD, Eighth International Conference on*, volume 1, pages 401–404, july 2011.

