



UAlg **FCT**

UNIVERSIDADE DO ALGARVE
FACULDADE DE CIÊNCIAS E TECNOLOGIA

Segmentação de Imagens de Elastografia Mamária

Autor:

Pedro Filipe Hortelão Beja

Dissertação

**Mestrado Integrado em
Engenharia Eletrónica e Telecomunicações**

Trabalho efetuado sob a orientação de:

Prof^a. Doutora Isabel Leiria

Prof. Doutor Wagner Pereira

2013



UAAlg FCT

UNIVERSIDADE DO ALGARVE
FACULDADE DE CIÊNCIAS E TECNOLOGIA

Segmentação de Imagens de Elastografia Mamária

Autor:

Pedro Filipe Hortelão Beja

Dissertação

Mestrado Integrado em

Engenharia Eletrónica e Telecomunicações

2013

Segmentação de Imagens de Elastografia Mamária

Declaração de Autoria

Declaro ser o autor deste trabalho, que é original e inédito. Autores e trabalhos consultados estão devidamente citados no texto e constam da listagem de referências incluída.

(assinatura)

Direitos de Cópia

Copyright ©Pedro Beja 2013

A Universidade do Algarve tem o direito, perpétuo e sem limites geográficos, de arquivar e publicitar este trabalho através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, de o divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

“First they ignore you, then they laugh at you, then they fight you, then you win.”

Mahatma Gandhi

Resumo

Na imagiologia dos dias de hoje, a elastografia é uma técnica bastante promissora para a deteção do cancro da mama. Apesar de ainda ser pouco utilizada, esta técnica representa resultados ainda mais promissores quando combinados com a ecografia, pois permite reduzir o número de biopsias desnecessárias, ter uma maior segurança nos diagnósticos das lesões, a nível de sensibilidade, especificidade e acurácia, evita que os pacientes passem por radiação ionizante e os custos são bem menores quando comparados com outras técnicas.

Este trabalho visa a caracterização dos contornos das lesões da mama, onde o contorno representa mais um fator de avaliação das imagens de elastografia. Experimentam-se vários algoritmos de segmentação a imagens de elastografia a cores e com base nos resultados é selecionado o *Elasto Region*. Na primeira parte do algoritmo é adicionado um pré-processamento de imagem através de operadores morfológicos por forma a isolar a lesão. Na segunda parte é aplicado o contorno ativo sem bordas para delimitar a lesão pretendida.

São comparados os resultados finais obtidos de forma semi-automática com o *Elasto Region*, com os contornos delimitados manualmente por um médico especialista, através da razão de superposição. Das 104 imagens de elastografia a cores recolhidas obtém-se ~37% das lesões utilizando a escala de cor RGB e ~29% utilizando a escala HSV. Tendo em conta que a razão de superposição funciona quando os contornos são fechados, retira-se o número de imagens que o algoritmo não conseguiu obter um contorno fechado, assim utilizando 83 imagens na escala RGB temos ~45% e com 63 imagens na escala HSV obtém-se ~46%. Desta forma passa-se a conhecer o desempenho do algoritmo e pode-se concluir que é necessário ramificar o algoritmo para vários grupos de imagens. Pois diversos grupos de imagens requerem diferentes pré-processamentos.

Palavras-chave: elastografia, operadores morfológicos, contorno ativo sem bordas, razão de superposição

Abstract

Nowadays the elastography technique is very promising for the detection of breast cancer. Although it is not widely used because the lack of belief. It has very promising results when combined with ultrasound images, allowing to reduce the number of unnecessary biopsies, increasing the safety of lesion's diagnosis at the level of sensitivity, specificity and accuracy, avoids patients to suffer from ionizing radiation and his costs are much lower when compared with other techniques.

The thesis aims to characterise the contours of breast lesions, where the boundary is one more factor to evaluate elastography images. Some segmentation algorithms are experienced with elastography images and based on their results the *Elasto Region* is selected. The first part of algorithm is to make a pre-processing through morphological operators in order to isolate the lesion. On the second part, it is applied the active contour without edges to bound the desired lesion.

The final results obtained by semi-automatic method (*Elasto Region*) are compared to contours manually delimited by a medical expert through the overlap ratio. The results are about $\sim 37\%$ of all lesions from 104 images using the RGB colour scale and $\sim 29\%$ using the HSV scale. Given the overlap ratio only works with closed contours, it is cut the number of images that the algorithm was unable to obtain a closed contour thus it has 83 RGB images and the results are $\sim 45\%$ and using 63 images from HSV it gets $\sim 46\%$. Therefore it is evaluated the performance of the algorithm using these two colours scales, which is now possible to accomplish that the algorithm needs some modifications to get better results or even make a new branch to work with some kind of images and several kinds of pre-processing.

Keywords: elastography, morphological operators, active contour without edges, overlap ratio

Agradecimentos

Agradeço,

Aos meus orientadores, Professora Doutora Isabel Leiria e Professor Doutor Wagner Pereira, pela orientação e transmissão de conhecimentos que me concederam ao longo do trabalho.

À Professora Doutora Teresa Figueiredo pela sua ajuda fundamental, acesso às imagens e seu tempo disponibilizado sem o seu apoio este trabalho não seria realizável. À Professora Doutora Margarida Moura pelo seu apoio e motivação dos trabalhos.

A toda a comunidade de Matlab e de \LaTeX .

Aos meus colegas de curso, principalmente ao André Santos, Valter Martins, Hélder Duarte, Gonçalo Mestre, Ozias Barros e Nuno Duarte e outros amigos pelo companheirismo, ajuda, amizade e bons momentos passados ao longo de todo o curso.

À minha cara metade que sempre me incentivou e apoiou na realização de todo o curso e do presente trabalho.

E um grande bem-haja aos meus pais e irmã que sempre demonstraram grande confiança em mim, me apoiaram, me motivaram e me proporcionaram as melhores condições para a conclusão do curso. Agradeço todo o esforço, carinho e força que me deram ao longo dos anos, pois sem eles este trabalho nunca teria sido conseguido.

Conteúdo

Resumo	v
Abstract	vi
Agradecimentos	vii
Lista de Figuras	xi
Lista de Tabelas	xiii
Lista de Abreviaturas	xiv
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.3 Organização do Trabalho	3
1.4 Contribuições do Trabalho	4
2 Enquadramento	5
2.1 Métodos de Diagnóstico Clínico	5
2.2 Processamento Digital de Imagem	6
2.3 Imagem Digital	7
2.4 Passos do Processamento Digital de Imagem	8
2.5 Operadores Morfológicos	11
2.6 Segmentação de Imagens	15
2.7 Elastografia	18

2.7.1	Aquisição de Imagens	21
2.7.2	Artefactos	22
2.7.3	Propriedades das Imagens que Ajudam ao Diagnóstico Médico	24
3	Metodologia de Investigação	26
3.1	Metodologia	26
3.1.1	Snakes: Active Contour Models	29
3.1.2	Chan-Vese Active Contours	31
3.1.3	Creaseg	32
3.1.4	DRLSE v0	34
3.1.5	RSF v0.1	35
3.1.6	My CImg Algorithm Implementation	36
3.1.7	Levelset Seg Biascorrection	38
3.2	Elasto Region	39
3.2.1	<i>Pipeline</i> de Processamento	40
3.2.2	Pré-Processamento de Imagem	42
3.2.3	Contorno Ativo sem Bordas	44
3.2.4	Sobreposição do Contorno	47
3.2.5	Principais Parâmetros de Ajustes	48
3.3	Razão de Superposição	49
3.4	Hardware e Software Utilizado	49
4	Resultados	51
4.1	Apresentação de Resultados	51
4.2	Avaliação de Contornos	60
4.3	Discussão de Resultados	63
4.4	Limitações e Problemas Encontrados	65
5	Conclusões	67
5.1	Conclusão	67
5.2	Trabalho Futuro	69

A Elasto Region.m	70
A.1 RegionBased()	72
A.2 Contourcs()	77
A.3 ContornoRS	79
Bibliografia	81

Lista de Figuras

Figura 2.1: Diagrama geral dos passos do PDI	9
Figura 2.2: Processo iterativo do operador reconstrução	14
Figura 2.3: Exemplo do operador reconstrução	14
Figura 2.4: Exemplo de imagem de elastografia na escala de cor de Itoh	20
Figura 3.1: Interface gráfico do Snakes: Active Contour Models	29
Figura 3.2: Interface gráfico do Creaseg	33
Figura 3.3: <i>Pipeline</i> de processamento do <i>Elasto Region</i>	40
Figura 3.4: Exemplo das várias fases de pré-processamento do <i>Elasto Region</i>	43
Figura 3.5: Exemplo de elemento estruturante em disco com raio de 4	44
Figura 3.6: Fases do contorno ativo sem bordas	46
Figura 3.7: Exemplo de contorno final sobre a imagem original	47
Figura 4.1: Resultado de segmentação à imagem 009	52
Figura 4.2: Resultado de segmentação à imagem 011	53
Figura 4.3: Resultado de segmentação à imagem 012	54
Figura 4.4: Resultado de segmentação à imagem 015	54
Figura 4.5: Resultado de segmentação à imagem 024	55
Figura 4.6: Resultado de segmentação à imagem 027	56
Figura 4.7: Resultado de segmentação à imagem 037	56
Figura 4.8: Resultado de segmentação à imagem 060	57
Figura 4.9: Resultado de segmentação à imagem 064	57
Figura 4.10: Resultado de segmentação à imagem 067	58
Figura 4.11: Resultado de segmentação à imagem 078	58

Figura 4.12: Resultado de segmentação à imagem 080	59
Figura 4.13: Resultado de segmentação à imagem 094	59
Figura 4.14: Resultado de segmentação à imagem 104	60

Lista de Tabelas

Tabela 3.1: Passos demonstrativos dos três tipos de métodos utilizados	41
Tabela 4.1: Resultados da razão de superposição	62
Tabela 4.2: Resultados finais comparativos dos dois sistemas de cor: RGB e HSV	64
Tabela 4.3: Resultados comparativos dos três tipos de métodos usados e do tipo de lesão das 104 imagens	65
Tabela 4.4: Resultado comparativo de 59 lesões benignas e 45 lesões malignas	65

Lista de Abreviaturas

ARFI	A coustic R adiation F orce I mpulse
CMYK	C yan M agenta Y ellow b lack
CTE	C ontrast T ransfer E fficiency
DRLSE	D istance R egularized L evel S et E volution
EE	E lemento E struturante
HSL	H ue S aturation L ightness
HSV	H ue S aturation V alue
JPG	J oint P hotographic E xperts G roup
LSE	L evel S et E volution
PDI	P rocessamento D igital de I tagem
PeI	P erímetro I nicial
PI	P rocessamento de I tagem
PNG	P ortable N etwork G raphics
PSNR	P eak S ignal to N oise R atio
MSSD	M ean S um of S quare D istance
RGB	R ed G reen B lue
ROI	R egion O f I nterest
RS	R azão de S uperposição
SWE	S hear- W ave E lastography

Capítulo 1

Introdução

Neste capítulo são apresentados a motivação, os objetivos, a organização do trabalho e a sua contribuição. Pretende-se realçar a importância da elastografia para a deteção do cancro da mama, e a necessidade de continuar os estudos e desenvolvimento das técnicas utilizadas nas imagens de elastografia para que esta técnica possa ser utilizada com maior frequência, garantindo uma maior sensibilidade e fiabilidade nos resultados.

1.1 Motivação

Havendo escassos estudos na literatura de imagiologia sobre a obtenção semi-automática de segmentação de imagens de elastografia, e sendo esta uma técnica bastante promissora para a deteção do cancro da mama, torna-se importante a investigação nesta área. Esta é uma técnica relativamente recente, que sendo uma técnica de imagiologia não utiliza radiação ionizante, é não evasiva, os resultados obtidos são rápidos e os seus custos são muito menores quando comparados com outras técnicas, pelo que faz todo sentido aprofundar o estudo de segmentação a imagens de elastografia e analisar os resultados. Conhecendo três técnicas de

imagiologia: mamografia, ecografia e elastografia utilizadas nos tecidos mamários, sabe-se hoje que a combinação das imagens de ecografia modo-B com a elastografia apresenta resultados muito promissores [1]. Face ao uso destas duas técnicas e por forma a melhorar a qualidade das mesmas pretende-se contribuir para os diagnósticos de forma mais completa e segura possível. Através das características que as imagens de elastografia apresentam e pelo contorno das lesões, pretende-se ajudar a distinguir o tipo de lesão em causa, evitando ao máximo a utilização da biopsia cujas desvantagens são conhecidas.

Um dos critérios semiológicos mais utilizados na análise de lesões em imagens de elastografia é a regularidade do contorno versus a irregularidade, mais a favor de benignidade ou malignidade. Atualmente esta avaliação é subjetiva porque depende de cada operador cujos contornos são traçados de forma manual, e se existir uma ferramenta adicional que objetive melhor o contorno, então o mesmo operador terá mais um fator de valor acrescentado na sua decisão, que por exemplo pode ser utilizado para desempatar entre pares num rastreio.

Atendendo a estes fatores tem particular interesse desenvolver e analisar métodos e algoritmos de processamento de imagem (PI) que ajudem a diagnosticar lesões mamárias em imagens de elastografia.

1.2 Objetivos

Tendo em conta a natureza das imagens de elastografia, uma abordagem natural à extração automática de informação clinicamente relevante segue-se a mesma estratégia utilizada nas imagens de ecografia mamária. No entanto a elastografia tem características específicas que levam a uma representação própria principalmente dos eventos malignos pelo que se pretende estudar técnicas de segmentação em imagens de elastografia mamária. As abordagens a seguir consistem por um lado na aplicação de técnicas de segmentação que deram bons resultados quando aplicadas

a imagens de ecografia mamária e por outro lado na extração de contornos das imagens de elastografia para ajudar a delinear a área suspeita. Assim obtém-se mais um fator de análise para os diagnósticos das imagens, caminhando para a redução do número de biopsias desnecessárias (benignas) aos pacientes com massas palpáveis ou com mamografias e ecografias inconclusivas.

Pretende-se efetuar o estudo de segmentação de lesões em imagens de elastografia a cores. Através do uso das técnicas de pré-processamento, aplicando os operadores morfológicos, às imagens de elastografia a cores pretende-se isolar a região suspeita de lesão. Após se ter a região da lesão isolada pode-se então obter o contorno da mesma com base em algoritmos de segmentação de contorno ativo.

1.3 Organização do Trabalho

O trabalho está estruturado em cinco capítulos. O primeiro capítulo é a introdução onde são apresentadas a motivação, os objetivos, a organização da dissertação e as contribuições do trabalho. O segundo capítulo é o enquadramento, este fala sobre os princípios do processamento digital de imagem (PDI), os passos que envolve e uma breve descrição de cada um deles. São explicados de forma mais detalhada alguns dos operadores morfológicos e os principais tipos de segmentação aplicáveis. É também apresentada a técnica de elastografia, realçando a sua importância, os cuidados a ter na aquisição das imagens, os artefactos conhecidos e as propriedades das imagens. O capítulo três contém a metodologia de trabalho, onde é explicado todo procedimento de estudo efetuado, as técnicas experimentadas e a razão da técnica escolhida. Esta última é explicada de forma mais detalhada, visto ser a técnica mais explorada. No capítulo quatro são apresentados, avaliados e discutidos os resultados obtidos e mencionadas algumas das limitações e problemas encontrados no algoritmo. Por último, o capítulo cinco contém as conclusões do trabalho e o trabalho futuro.

1.4 Contribuições do Trabalho

Este trabalho visa:

- Identificar técnicas de PI que possam ajudar a melhorar a identificação e classificação de lesões dos tecidos mamários em imagens de elastografia.
- Ajudar a caracterizar os tipos de lesões através dos contornos, que podem ser avaliados pela sua regularidade versus irregularidade.
- Obter mais um fator de decisão para os operadores de imagem caminhando na direção de reduzir o número de biopsias.

Capítulo 2

Enquadramento

Este capítulo assumirá a forma de uma revisão bibliográfica que permitirá situar o âmbito do trabalho aqui apresentado. Introduzem-se os métodos de diagnóstico clínico para o cancro da mama, uma breve descrição do PDI, a imagem digital, os diversos passos do PDI, alguns operadores morfológicos, os diversos tipos de segmentação de imagens e uma introdução à elastografia mamária, contendo a aquisição de imagens, os seus artefactos e algumas propriedades das imagens de elastografia que ajudam ao diagnóstico médico.

2.1 Métodos de Diagnóstico Clínico

O diagnóstico baseado em ultra-som não utiliza radiação ionizante e é não evasivo. Apresentando assim a vantagem de promover o conforto aos pacientes durante o exame, por ser não evasivo e de rápida obtenção dos resultados finais. A biopsia continua a ser o *gold standard* usado na avaliação final de lesões mamárias, sendo esta uma técnica evasiva. Os desenvolvimentos na imagiologia ainda não apresentam resultados que permitam diminuir o número de biopsias e a maioria dos sistemas de aquisição de imagens médicas envolvem radiação eletromagnética.

A ultrassonografia (ecografia) não é considerada suficientemente sensível ou específica para diagnosticar os vários tipos de lesão. Cada método tem as suas propriedades e características específicas e são usados como complemento. Em 1991 Ophir [2] introduziu um novo método de produção de imagens através do ultra-som: a elastografia. As imagens produzidas com esta técnica têm relação com a informação obtida pela palpação manual e têm sido qualificadas como capazes de representar pequenas lesões mamárias com alguma confiança. Vários relatos na bibliografia sustentam o facto de a elastografia ser um método importante na deteção de cancro de mama, e de, quando usado em conjunto com a ultrassonografia poder chegar mesmo a apresentar melhores resultados que a mamografia [1].

A extração automática de informações a partir das imagens de ultrassonografia envolve normalmente uma fase de segmentação para isolamento da área suspeita na imagem, e outra fase para análise da morfologia e textura dessa mesma área, que possam levar a um diagnóstico médico. No caso da elastografia a obtenção automática de informação está ainda pouco explorada. Além disso, a elastografia tem sido considerada de difícil interpretação, podendo haver muitos fatores causadores de artefactos que podem levar a um diagnóstico errado [3].

2.2 Processamento Digital de Imagem

Os sistemas de PI funcionam grande parte das vezes com base em testes que permitam chegar a uma solução próxima da desejável. Como tal requer-se a capacidade de criar, modificar e personalizar métodos e algoritmos para se conseguir aproximações de soluções que permitam a implementação de um sistema viável. O PI é desenvolvido consoante os objetivos pretendidos.

Existem duas áreas de aplicação do PDI, sendo a primeira o melhoramento da aparência de determinadas estruturas na imagem para uma fácil interpretação humana e a segunda o processamento de dados para armazenamento e transmissão

[4] [5]. A vasta quantidade de aplicações de PDI existentes nos dias de hoje deve-se à necessidade da mesma com o grande desenvolvimento computacional face aos desenvolvimentos de novos algoritmos e de novas técnicas para lidar com sinais multi-dimensionais. Algumas das áreas de aplicação do PDI são por exemplo: análise de recursos naturais, meteorologia via imagens de satélite, transmissão digital de sinais de televisão, análise de imagens biomédicas, radiação nuclear, aplicações em sensores visuais e robótica.

Com o objetivo de identificar zonas de interesse, as imagens capturadas pelos sistemas nas diversas partes do espectro eletromagnético, dependem maioritariamente da qualidade de representação dos dados contidos nas imagens. Contrariamente ao olho humano que tem a visão limitada a determinada banda do espectro eletromagnético ($\sim 380 \text{ nm}$ e $\sim 780 \text{ nm}$), cujo sistema visual humano e o mecanismo de perceção tridimensional podem ser iludidos facilmente, as máquinas de imagem cobrem quase todo o espectro eletromagnético, variando desde os raios gama até às ondas rádio, embora existam os artefactos que se devem ter sempre em consideração.

O PDI envolve técnicas para análise de dados multi-dimensionais adquiridos por diversos tipos de sensores. Pode-se dizer que o PDI é toda manipulação de imagem realizada por um sistema [4] [5]. Estas manipulações podem envolver diversos passos desde: pré-processamento, redução de ruído, aperfeiçoamento de contraste, afinamento da imagem, etc.

2.3 Imagem Digital

Uma imagem pode ser definida como uma representação visual de uma ideia ou de um objeto e ter várias interpretações. Pode-se definir a imagem digital como uma função bidimensional de valores discretos, $f(x, y)$, onde x e y são coordenadas espaciais num plano, e a amplitude f é a intensidade do ponto, sendo também conhecido por pixel.

Quanto menor for o pixel maior será a sua resolução [4] [5].

Para se criar uma imagem digital é preciso converter os dados contínuos detetados para formato digital. Esta conversão envolve dois processos, a amostragem e a quantização. Desta maneira é preciso discretizar a função $f(x, y)$, ou seja discretizar as suas coordenadas e as suas intensidades. A amostragem significa a digitalização dos valores das coordenadas dos pixels e a quantização a digitalização dos valores de intensidade. É com base na amostragem e na quantização que a imagem digital é uma função discreta representada por amostras medidas em intervalos regulares. Desta forma obtém-se uma matriz bidimensional, em que o intervalo de amostragem é a resolução espacial da imagem e a resolução espacial é a capacidade de distinguir os detalhes numa imagem [4] [5].

As imagens digitais a cores são formadas pela combinação de planos de imagens 2D individuais. Um bom exemplo disso é o sistema de cores, RGB (Red, Green, Blue) (Vermelho, Verde, Azul) que consiste em três componentes ou planos individuais de cor, que quando combinadas as matrizes de cada componente formam a imagem a cores. Existem vários sistemas de cor, tais como RGB, CMYK (Cyan, Magenta, Yellow, black) (Ciano, Magenta, Amarelo, Preto), HSV (Hue, Saturation, Value) (Tonalidade, Saturação, Valor) e HSL (Hue, Saturation, Lightness) (Tonalidade, Saturação, Luminosidade) sendo estes utilizados conforme as necessidades de cada aplicação.

2.4 Passos do Processamento Digital de Imagem

Existe um diagrama geral dos passos do PDI como ilustra a Figura 2.1. Em PDI transmite-se a ideia de que todas as metodologias que podem ser aplicadas às imagens são de diferentes propósitos e que possibilitam diferentes objetivos.

A **aquisição de imagem** é o primeiro passo da Figura 2.1, cuja finalidade é obter

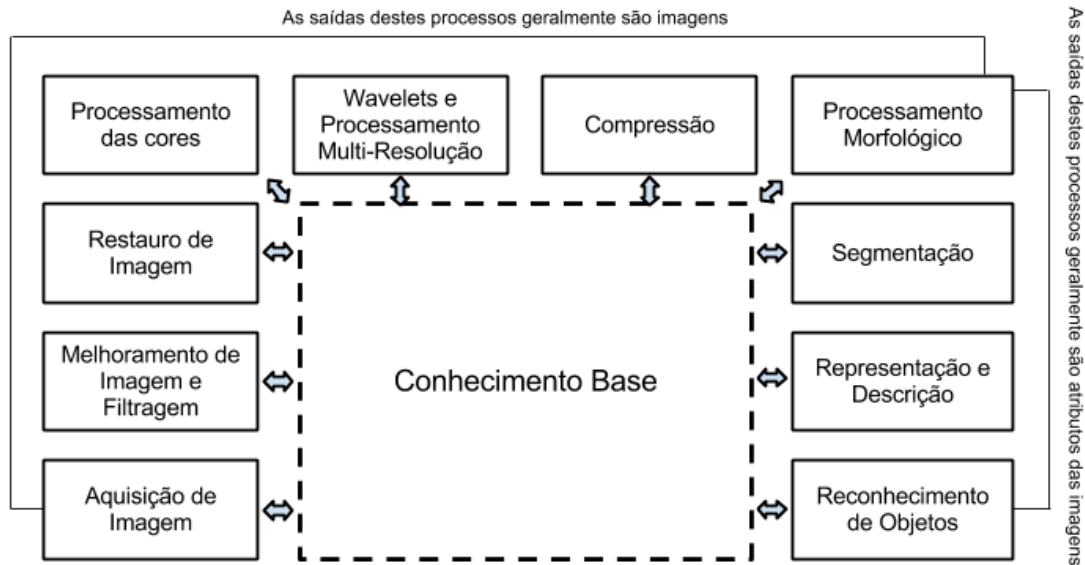


FIGURA 2.1: Diagrama geral dos passos do PDI. Figura baseada no livro Digital Image Processing [4].

uma imagem já em formato digital. A aquisição de imagem pode passar por algum tipo de pré-processamento, desde o dimensionar a imagem, realçar contrastes, remover ruídos, isolar regiões, etc. Pretende melhorar a imagem por forma a aumentar a probabilidade de sucesso nos passos seguintes.

O **melhoramento de imagem e filtragem** é o processo de manipulação de imagem que geralmente resulta num formato mais orientado a uma aplicação específica. Embora que de modo geral existam vários métodos específicos para cada tipo de imagem que se queira melhorar, não existe no entanto, nenhum padrão para o melhoramento de imagem. Quando uma imagem é processada para interpretação visual, o analista é que avalia e quantifica as melhorias obtidas pelo método, assim pode-se dizer que este processo é subjetivo.

O **restauração de imagem** é um passo que também lida com a aparência de imagem. Ao contrário do melhoramento de imagem, que é subjetivo, a restauração de imagem é um processo objetivo no sentido que as técnicas de restauração são baseadas em modelos matemáticos.

A cor é muito importante até mesmo para extrair características de interesse numa imagem. Daí o valor do **processamento da cor**.

As **wavelets** (onduletas) e o **processamento de multi-resolução** são a base para a representação de imagens em várias resoluções e também para a compressão de dados das imagens.

A **compressão** tal como o nome indica lida com técnicas para reduzir o espaço requerido de armazenamento das imagens, ou para a largura de banda necessária para a sua transmissão.

O **processamento morfológico** tem a função de extrair os componentes de uma imagem que sejam úteis para a representação e descrição das suas formas. Este é baseado em modelos matemáticos e tem grande valor para o processamento de imagem.

A **segmentação** delimita as várias regiões de uma imagem. A segmentação autónoma é uma das tarefas mais difíceis em PDI. No geral, quanto mais precisa for a segmentação melhor será o sucesso de reconhecimento dos objetos. O resultado final da segmentação é o conjunto de pixels que separam uma região da imagem de outra ou todos os pontos da própria região.

Nas fases de **representação e descrição**, convertem-se os dados para um formato adequado ao processamento computacional. Primeiro tem de se decidir se os dados são representados como fronteiras ou como regiões completas. A representação por fronteiras é apropriada quando o interesse está nas características de forma externa, tais como cantos ou pontos de inflexão, enquanto que a representação por região é apropriada quando o interesse se concentra em propriedades internas, tais como as texturas ou a forma de esqueleto.

O **reconhecimento de objetos** é o passo que atribui uma etiqueta a um objeto, baseado na informação fornecida pelo seu descritor. A interpretação envolve a atribuição de significado a um conjunto de objetos individuais reconhecidos.

É de salientar que nem todas as aplicações de PI exigem a complexidade das interações implícitas na Figura 2.1. Na maioria dos casos não é necessário realizar todos os passos descritos. Contudo, à medida que a complexidade das tarefas de PI aumenta, o número de passos necessários para resolver o problema também aumenta [4] [5].

2.5 Operadores Morfológicos

A palavra morfologia refere-se ao estudo das formas que um ente pode tomar. No contexto deste trabalho dá-se especial atenção à morfologia matemática, uma ferramenta que permite extrair componentes das imagens que possam facilitar a análise das mesmas. Este tipo de morfologia é aplicada em várias áreas de processamento e análise de imagens, com vários objetivos distintos, sendo bastante utilizada no pré e pós-processamento de imagem. Exemplos de operadores morfológicos são a erosão, dilatação, abertura, fechamento, detecção de bordas, esqueletização, afinamento, preenchimento de regiões, espessamento e poda. Os operadores morfológicos são aplicados às imagens de acordo com os objetivos pretendidos.

A linguagem da morfologia matemática é baseada na teoria dos conjuntos, que permite grandes aproximações para os diversos problemas de PI. Os conjuntos em morfologia matemática representam objetos numa imagem. Algumas funções interessantes da teoria dos conjuntos que são vulgarmente aproveitadas em morfologia matemática são a interseção, a união, a diferença ou o complemento.

A **reflexão** e a **translação** são operações muito utilizadas na morfologia. A reflexão reflete a imagem e a translação transfere a imagem de um lugar para outro. Estas operações são empregues extensivamente na morfologia para realizar operações de elemento estruturante (EE). O EE é um conjunto pequeno completamente definido utilizado como referência para percorrer a imagem com determinadas propriedades

de interesse para se obter resultados. Quando se trabalha com imagens deve-se especificar a origem do EE que geralmente é indicada com um ponto preto e colocado no seu centro. Muitas das operações morfológicas são baseadas no EE, assim a forma e o tamanho do EE deve ser adaptado face às propriedades geométricas dos objetos em estudo.

Um dos operadores morfológicos de interesse neste trabalho é o operador **complemento**. Seja A um conjunto de Z^2 e as coordenadas dos seus pixels (x, y) . Considerando $w = (x, y)$ como um elemento de A , então o complemento de A pode ser definido como dita a Equação 2.1.

$$A^c = \{w | w \notin A\} \quad (2.1)$$

O operador **erosão** reduz os objetos de uma imagem, desbasta. Tendo em conta que o uso deste operador beneficia a cor preta, ou seja, reduz os diversos objetos porque expande a cor escura. A erosão consegue dissipar componentes de ruído e os detalhes menores que o EE são filtrados ou removidos completamente da imagem. A erosão de A por B é simbolizada por $A \ominus B$, assim tendo os conjuntos A e B em Z^2 tem-se a definição matemática da erosão na Equação 2.2.

$$A \ominus B = \{z | (B)_z \cap A^c = \emptyset\} \quad (2.2)$$

Sendo A^c o complemento de A e \emptyset o conjunto vazio.

A **dilatação** acrescenta uma camada de pixels à região. Este operador dilatação realça e expande a imagem através da forma do EE utilizado, tendo em conta que este operador beneficia a cor branca, ou seja, dilata as regiões de cor clara. Como os resultados dos operadores morfológicos são sempre imagens binárias, pode-se dizer que a erosão e a dilatação são o dual um do outro, o que torna esta propriedade bastante útil quando o EE é simétrico relativamente à sua origem. A dilatação de A por B é simbolizada por $A \oplus B$. Tendo os conjuntos A e B em Z^2 tem-se a definição

matemática da dilatação na Equação 2.3.

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\} \quad (2.3)$$

Esta equação contém a reflexão do conjunto B , simbolizado por \hat{B} , sobre a sua origem e o deslocamento desta reflexão por z , em que \emptyset representa o conjunto vazio. A dilatação de A por B é o conjunto de todos os deslocamentos z , tal que \hat{B} e A sobreponham-se pelo menos a um elemento.

A combinação dos operadores erosão e dilatação em que a erosão é seguida da dilatação define-se o operador **abertura**. Este operador suaviza o contorno de um objeto, quebra istmos estreitos e elimina saliências finas.

O operador **fechamento** é a dilatação seguida da erosão, que também suaviza as secções de contornos, mas contrariamente à abertura, une pontas estreitas e golfos longos e finos, elimina buracos e preenche ainda certas lacunas nos contornos. Estes dois operadores são o dual um do outro. Em determinadas situações é uma ferramenta muito útil o uso de ambos os operadores no mesmo objeto da imagem.

O operador **reconstrução** faz uma transformação morfológica que envolve duas imagens e o EE. Uma imagem é o marcador que é o ponto de partida para a transformação. A outra imagem é a máscara que define a transformação. O EE define a conectividade. Se G for a máscara e F for o marcador, a reconstrução de G a partir de F , simbolizada por $R_G(F)$ é definida pelo processo iterativo representado na Figura 2.2. Devendo F ser um subconjunto de G , ou seja, $F \subseteq G$. Suponha-se um exemplo de uma imagem sintética com fundo preto e com uma figura abstrata na imagem cujo seu contorno é irregular. Tendo o contorno da figura abstrata e definindo-a como marcador, aplica-se então o operador de reconstrução e consegue-se obter toda superfície da figura abstrata. Pode-se compreender melhor esta explicação observando a Figura 2.3.

1. Inicializa h_1 para ser o marcador da imagem F .
2. Cria o EE, B .
3. Repete: $h_{k+1} = (h_k \oplus B) \cap G$ até que $h_{k+1} = h_k$.
4. $R_G(F) = h_{k+1}$.

FIGURA 2.2: Processo iterativo do operador reconstrução. Figura baseada no livro Digital Image Processing Using MATLAB [5].




FIGURA 2.3: Exemplo do operador reconstrução. Contando de cima para baixo e da esquerda para a direita, a primeira imagem é a original (máscara), a segunda é a imagem marcador, a terceira, quarta e quinta são os resultados intermédios, conforme o número de iterações, e a sexta é o resultado final. Figura retirada do MATLAB Digest, Academic Edition [6].

Existem muitos mais operadores morfológicos que se poderiam apresentar, mas apenas são referidos os mais relevantes para o estudo a efetuar. Quando se trabalha com imagens binárias o objetivo principal destes operadores morfológicos é a extração dos componentes da imagem que sejam úteis para passos seguintes, tais como a segmentação. Assim estes operadores devem ser utilizados de acordo com as necessidades pretendidas. Todas estas definições estão apresentadas e ilustradas no livro Digital Image Processing [4] de forma mais detalhada [5] [7] [8].

2.6 Segmentação de Imagens

Os algoritmos de segmentação de imagem permitem identificar e localizar regiões ou objetos de interesse nas imagens digitais de acordo com as suas características, (cor, intensidade, textura, resposta na frequência, etc.) com o objetivo de simplificar a representação da imagem para posterior análise. Através dos algoritmos implementados computacionalmente definem-se nas imagens recortes automáticos em redor dos objetos de interesse, fazendo a subdivisão da imagem em várias regiões ou em conjuntos de contornos. Entenda-se uma região como um conjunto de pixels contíguos que se espalham de forma bidirecional e que apresentam uniformidade. Deste modo é possível achar as diferenças entre dois ou mais objetos e distinguir os pixels das diferentes regiões, o que faz com que o algoritmo consiga interpretar os pixels contíguos e os agrupe em regiões. O nível de detalhe da subdivisão depende da resolução necessária ao problema, ou seja, a segmentação deve parar quando os objetos ou regiões de interesse numa aplicação tenham sido detetados.

A segmentação de imagens é útil em diversas áreas, tais como a localização de tumores, medição de volumes de estruturas anatómicas em aplicações médicas, localização de objetos, reconhecimento facial, controlo automático e visão computacional. Atualmente existem várias abordagens à segmentação, como por

exemplo a segmentação baseada em formatos, baseada nas características dos pixels, baseada em histogramas, detecção de descontinuidades, detecção de pontos, detecção de linhas, detecção de bordas, segmentação de cores e segmentação por intensidades, mas não existe uma solução geral aplicável a qualquer problema. O que normalmente acontece é uma combinação de várias técnicas de modo a adaptar a situação ao domínio do problema. Assim o problema fundamental da segmentação é particionar uma imagem em regiões de modo a que satisfaça as condições pré-definidas.

Grande parte dos algoritmos de segmentação são aplicados extensivamente à ciência e ao quotidiano. Estes algoritmos categorizam-se em **segmentação baseada em contornos**, **segmentação baseada em regiões** e segmentação de **agrupamento de dados**. Os algoritmos destas categorias são baseados em uma das propriedades de intensidade: a descontinuidade ou a similaridade.

A **segmentação baseada em contornos** baseia-se na descontinuidade, a abordagem é particionar a imagem com base em alterações abruptas de intensidade, exemplos são: a detecção de bordas e linhas ou a detecção de pontos isolados. Na descontinuidade supõe-se que as fronteiras das regiões são suficientemente diferentes uma das outras e que o seu fundo permite a detecção de contornos com base na intensidade de descontinuidade. Geralmente esta segmentação aplica-se à detecção de contornos.

A **segmentação baseada em regiões** leva em conta a abordagem da similaridade, esta abordagem particiona a imagem em regiões com base na semelhança entre os pixels partindo de um determinado critério previamente definido. A maioria dos modelos desta segmentação são baseados na suposição de intensidades homogéneas [9]. Exemplos são: a limiarização, o crescimento de regiões, a divisão e junção de regiões ou a exploração rápida. Todos estes expandem cada região pixel por pixel baseado no valor do pixel ou no nível de quantização, de modo a que cada grupo tenha uma boa relação posicional. Um dos algoritmos bastante utilizados é o

algoritmo *Watershed* cujas regiões vão crescendo.

O algoritmo *Watershed* pode ser explicado através da seguinte analogia, uma imagem com vários níveis de cinza pode ser vista como uma superfície cujos pontos têm altitudes relativas aos valores dos pixels. Quanto maior for o valor do nível de cinza correspondente maior é a altitude. As bordas dos objetos têm relevo e a superfície é formada por vales e bacias. Assim enche-se a superfície a partir dos pontos mais baixos e conforme o aumento do nível nos vales e nas bacias, estas começam a transbordar e tocam em outras bacias. Neste ponto são construídas barragens para evitar a união das mesma. No entanto, muitas vezes este método conduz à sobre segmentação e para contornar este efeito utilizam-se marcadores que servem para marcar pontos estratégicos para ajudar o algoritmo a interpretar as várias regiões de maneira diferente.

Por fim o **agrupamento de dados** baseia-se na imagem inteira e é considerado uma distância entre cada grupo. As características dos agrupamentos de dados são que cada pixel do grupo se diferencia perante os outros grupos. O método elementar do agrupamento de dados pode ser dividido de forma hierárquica e em grupos particionados.

De modo geral quanto mais precisa for a segmentação maior será o reconhecimento dos objetos. A acurácia da fase de segmentação determina o sucesso ou falha dos procedimentos de análise de imagem. Após o processo de segmentação, cada objeto é descrito através das suas propriedades geométricas e topológicas, como por exemplo o contorno, a área, a forma e a textura que podem ser extraídos dos objetos e posteriormente utilizados no processo de análise [4] [5].

2.7 Elastografia

A elastografia é uma técnica promissora não evasiva baseada em ultra-som que permite avaliar o tipo de lesões, e é descrita por Ophir [2]. Esta pode ser aplicada em diversas partes do corpo humano, mas este trabalho assenta no estudo das lesões dos tecidos mamários. A técnica utiliza o mesmo princípio da palpação, pois o tecido é comprimido por uma sonda em torno da área de interesse (ROI), sendo esta área um subconjunto selecionado de amostras dentro de um conjunto de dados identificados para um propósito específico, e a deformação do tecido resulta numa imagem, cujo instrumento de captura de imagens chama-se ultra-sonógrafo.

Atualmente existem três métodos para obter imagens de elastografia: mãos livres, onda transversal (SWE) e o impulso de força de radiação acústica (ARFI). O método mãos livres é manual e portanto mais difícil para os operadores, pois requer alguma experiência para se conseguir obter imagens com boa qualidade e que sejam interpretáveis [10]. Este método mostra imagens qualitativas que a maioria das empresas usa para diferenciar a rigidez relativa entre a lesão e o tecido mamário circundante. O método SWE é um método automático e apresenta um novo modo teoricamente independente do ultra-sonógrafo, permite informações mais quantitativas, o que é útil para caracterizar as lesões da mama. Por último o método ARFI também automático, que permite obter melhor qualidade e resolução das imagens, permite também calcular a rigidez dos tecidos mais profundos.

A técnica de elastografia consegue determinar a elasticidade dos tecidos a partir da deformação sofrida. É com base na distribuição de elasticidade dos tecidos ou dos objetos sondados que se mapeia a cor, segundo uma escala de cor padronizada, que representa a elasticidade dos tecidos. Note-se que ainda não existe uma escala de cor padronizada internacionalmente, pois as escalas variam consoante as marcas dos equipamentos [10]. Um exemplo de uma escala de cor é dos equipamentos da marca ©Hitachi, que utiliza a escala proposta por Itoh [11], e apresenta as imagens das lesões e da área circundante numa escala de gravidade de doença de 1 a 5 [11]. Os

níveis 1, 2 e 3 são considerados lesões benignas, já o 4 e 5 são considerados lesões malignas e representam um estado avançado da lesão.

Existe uma relação entre esta escala de gravidade de doença e a escala de cor: O nível 1 dita uma deformação uniforme para toda a lesão hipoecóica, sendo esta sombreada uniformemente a verde. O nível 2 apresenta uma deformação em grande parte da lesão hipoecóica, quando vista pela ultra-sonografia, com algumas zonas sem deformação, contém um padrão em mosaico de cor verde e azul. O nível 3 apresenta uma deformação na periferia da lesão hipoecóica com poupança no centro da lesão, sendo a parte periférica da lesão a verde e a parte central a azul. O nível 4 é sem deformação em toda lesão hipoecóica, toda a lesão é representada pela cor azul, mas a zona envolvente não é incluída. O nível 5 é sem deformação em toda a lesão hipoecóica ou na zona envolvente, ambas em azul.

A cor azul indica regiões com pouca elasticidade, ou seja, são regiões de tecido duro. Os tecidos malignos geralmente são mais rijos que os tecidos normais no peito e os tumores malignos geralmente são infiltrantes e invadem os tecidos adjacentes, criando na imagem contornos irregulares ou indefinidos. Desta forma analisando o contorno de uma lesão é possível iniciar uma hipótese diagnóstica que aponte a malignidade, Alvarenga [7]. Já a cor vermelha indica regiões de alta elasticidade, ou seja, tecidos macios. A Figura 2.4 representa um exemplo de uma imagem de elastografia a cores na escala de Itoh [11].

Com base no estudo de Zhi [1], que compara três técnicas de imagiologia existentes a mamografia, a ecografia e a elastografia, num universo de 296 lesões, em 232 pacientes, dos quais 87 são malignos e 209 benignos, concluiu-se que a elastografia é a mais específica (95.7%) e a que tem menor taxa de falsos-positivos (4.3%). A acurácia (88.2%) e os valores positivos preditivos (87.1%) da elastografia são maiores quando comparados com a ecografia (72.6% e 52.5%, respetivamente). Já os valores de sensibilidade, os valores negativos preditivos e a taxa de falsos-negativos são os mesmos nas três técnicas. A combinação da elastografia




FIGURA 2.4: Exemplo de imagem de elastografia na escala de cor de Itoh.

com a ecografia apresenta melhor sensibilidade (89.7%), melhor acurácia (93.9%), menor taxa de falsos-negativos (9.2%), melhor especificidade (95.7%), melhores valores positivos preditivos (89.7%) e menor taxa de falsos-positivos (4.3%). Desta forma pode-se afirmar que a combinação da elastografia com a ecografia apresenta os melhores resultados para a detecção do cancro da mama [1], onde a elastografia é sobreposta à ecografia convencional. A combinação das duas técnicas permite assim detectar o cancro mais rapidamente, reduzir o número de biopsias desnecessárias, oferecendo um maior conforto e uma menor ansiedade aos pacientes e os custos desta técnica são mais reduzidos.

A técnica de mamografia utilizada nos dias de hoje usa radiação ionizante, algo potencialmente prejudicial ao ser humano, pois pode danificar células e afetar o DNA causando doenças graves, tais como o cancro. É uma técnica que limita a sua utilização conforme a idade da pessoa e também pela frequência de utilização. Já a elastografia apresenta riscos reduzidos para os pacientes.

Na elastografia é preciso ter em conta todos os fatores que afetam a rigidez das lesões, porque há uma coincidência de elasticidade entre as lesões da mama benignas e malignas [12], o que faz ter cuidado reforçado na sua análise [1] [7].

2.7.1 Aquisição de Imagens

A elastografia requer alguns conhecimentos prévios por parte dos operadores para se ter uma maior garantia perante a classificação final das imagens, principalmente quando se utiliza o método mãos livres (manual), como acontece no presente estudo. Este método requer cuidado especial quando se rastreia a lesão, garantindo que o tecido ocupado seja no máximo um terço da área total da ROI [1]. Os sinais de eco adquiridos pela sonda são capturados por um computador externo e utilizados para calcular a deformação dos tecidos com a combinação do método de auto-correlação. Desta forma obtém-se uma medida de elasticidade qualitativa que é relativa à média de deformação dentro da ROI, sendo esta utilizada para comparar a elasticidade da lesão com os tecidos normais da mama. Ambos os tecidos devem estar contidos na ROI. Assim o tamanho da ROI é muito importante para uma avaliação correta, para os casos benignos na escala de Itoh (1-3) não tem muita influência, mas para os malignos na escala de Itoh (4-5) tem grande influência. Pois com uma ROI pequena as lesões rijas e com as elasticidades dos tecidos em volta muito diferentes destes, poderão aparecer como suaves e daí ser facilmente iludido.

O segundo cuidado a ter é o de aplicar uma pressão leve da sonda sobre a lesão. Geralmente existe um indicador de pressão no equipamento que quando atinge certo valor causa propriedades não lineares na elasticidade dos tecidos. Como consequência, a compressão, a pressão e a deformação deixam de ser proporcionais, o que pode levar a diagnósticos errados. Alterando a frequência e a amplitude de movimento não altera o aspeto da lesão para ambos os casos (benigno ou maligno), mas o grau de compressão inicial influencia significativamente o resultado final [3].

Relativamente ao tipo de secção (longitudinal ou transversal), indicando a projeção pela qual se obtém os elastogramas, geralmente para lesões benignas não existe qualquer influência do tipo de secção utilizada. Já as lesões malignas são muito influenciadas pelo tipo de secção utilizado. A secção que leva à classificação final

correta varia muito de acordo com as imagens [3].

O ângulo do transdutor usado no equipamento para emitir e recolher os ecos de ultra-som do paciente também é importante porque quando compara uma lesão maligna de uma imagem na secção estritamente perpendicular à lesão, com os resultados obtidos após a inclinação do transdutor, existe uma diminuição de elasticidade e assim é uma vez mais iludido, pois aparentava ser uma lesão benigna [3].

É preciso ter em consideração as características da lesão pois é mais fácil estimar o resultado correto para pequenas lesões quando estas são rodeadas por grandes quantidades de tecidos saudáveis, do que grandes lesões que ocupam todo o ROI. A classificação é mais precisa quando avaliada para lesões à superfície do que para aquelas mais profundas, pois também quanto mais profunda estiver a lesão maior é a probabilidade de ocorrência de artefactos para além da dissipação do ultra-som. Durante a análise das imagens deve-se ter em consideração os possíveis artefactos existentes, que em algumas situações até facilitam a interpretação das imagens.

2.7.2 Artefactos

A maioria das lesões malignas da mama apresenta um formato irregular e espiculado, já as lesões benignas são regulares e arredondadas. No entanto, algumas lesões malignas podem apresentar formas regulares e algumas lesões benignas podem ter formatos irregulares. Uma lesão pode ter uma aparência irregular de uma determinada projeção e ter uma aparência regular de outra projeção, tal como foi falado na secção 2.7.1. Como em qualquer modalidade de imagiologia, na elastografia existe uma variedade de artefactos. Estes artefactos de elastografia podem ser divididos em três categorias principais: **artefactos mecânicos**, **acústicos** e de **processamento de sinal**.

Os **artefactos mecânicos** são aqueles em que as deformações dos tecidos não dependem apenas da distribuição do tecido mas também das condições de

contornos. Os artefactos mecânicos representam significativamente as variações das deformações, cujos elastogramas podem representar concentrações de pressão ou de depressão dos tecidos devido às condições de contornos [13]. Estes artefactos são provocados por a lesão ser rija e devido às limitações da eficiência de transferência de contraste (CTE) [13]. À partida consegue-se minorar o efeito destes artefactos se for aplicado o modelo de reconstrução, sendo este um modelo para elastograma [13]. Por vezes os artefactos mecânicos beneficiam e facilitam os diagnósticos destacando os alvos de interesse.

Os **artefactos acústicos** podem ser introduzidos através do transdutor utilizado para recolher os dados e podem condicionar significativamente a estimação da deformação. Os parâmetros tais como o grande contraste acústico, as mudanças do emissor, a reverberação e as anomalias de fase podem introduzir erros nos elastogramas [13]. A elastografia é convencionalmente um método baseado na medição diferencial mas como os sinais de pré-compressão e de pós-compressão geralmente sofrem degradação idêntica, tende-se a minimizar os artefactos acústicos [13].

A elastografia na sua presente forma de desenvolvimento tem dois principais **artefactos de processamento de sinal**, chamados *zebras* e *worms*. Podem introduzir-se erros de polarização cíclicos se o deslocamento estimado também apresentar um erro cíclico obtido pelo gradiente de deslocamento [13]. Então a imagem irá conter um erro cíclico, que pode ser contornado por uma operação não linear. Este erro manifesta-se com bandas horizontais que alternam entre linhas brancas e pretas ao longo da imagem no elastograma. A frequência espacial desta tendência aumenta conforme o aumento da deformação. Assim este artefacto depende da deformação e é chamado de artefacto *zebra*.

Os artefactos de processamento de sinal *worms* aparecem quando ocorrem grandes sobreposições de sinais, produzindo padrões de ruídos correlacionados [13]. Este artefacto também aparece como estruturas horizontais como as *zebras*. Mas existem

grandes diferenças entre eles, pois as estruturas dos *worms* geralmente são muito mais finas verticalmente e menores horizontalmente, não abrangem toda a imagem e são deformações independentes.

Os elastogramas também são afetados por várias formas de ruído, embora atualmente se consiga suprimir grande parte do ruído utilizando uma filtragem mediana de cinco pontos nas imagens finais e diminuindo a resolução espacial das imagens. Para reduzir ainda mais o ruído começou-se a adquirir os dados utilizando compressões múltiplas [13]. Mais melhoramentos tais como o alongamento de sinal deve reduzir o ruído e permitir que se obtenha uma maior resolução espacial [3] [13].

Para além dos artefactos ainda existem outros como os bioefeitos desde efeitos físicos nos tecidos, efeitos térmicos, efeitos não-térmicos.

2.7.3 Propriedades das Imagens que Ajudam ao Diagnóstico Médico

A combinação da elastografia com a ecografia permite a deteção de características morfológicas e de rigidez nas lesões. As características nas imagens que fornecem pistas conducentes ao diagnóstico são por exemplo: as formas (redonda, oval, lobular ou irregular), as margens (bem ou mal definidas), a ecogenicidade¹ interna (anecóico, hipoecóico, isoecóico, complexo ou hiperecóico), a distribuição de ecotextura, as alterações acústicas posteriores (reforço acústico, sombreamento acústico ou combinação do reforço com o sombreamento), o sinal de reflexão bilateral, a orientação do eixo principal da lesão relativamente à superfície cutânea (paralelo ou perpendicular), a textura interna (homogénea ou heterogénea), o tecido circundante (intacto, deslocado ou interrompido), a compressibilidade, a mobilidade, a morfologia (grosseiras, amorfas, monomórficas ou pleomórficas), a distribuição (agrupadas, lineares, segmentares, regionais ou difusas), a escala bi-rads (1, 2, 3, 4 ou 5), os

¹ **Ecogenicidade** é a capacidade de gerar ecos.

contornos (regulares, irregulares, circunscritos, parcialmente obscurecidos, microlobulados, indistintos ou espiculados) e a tripla camada de cor situada na parte debaixo da lesão. Estas propriedades têm mostrado um grande valor para o diagnóstico final, pois é com a ajuda destas que se classificam os tumores como benignos ou malignos.

Nas imagens de elastografia e de forma geral quanto mais moles forem os tecidos, mais elásticos são sendo esse comportamento normalmente associado à benignidade e quanto mais rijos forem os tecidos menor é a elasticidade, o que geralmente é associado à malignidade. As áreas rijas representam um menor deslocamento dos tecidos e são representadas por regiões mais escuras, já as áreas moles representam um maior deslocamento dos tecidos. Nódulos de formato redondo, liso e bem definido (suave) estão normalmente associados à benignidade. Já os indícios da malignidade estão associados a contornos irregulares ou indefinidos, que infiltram e invadem os tecidos adjacentes, existência de microcalcificações e rigidez. Nas lesões sólidas o contorno é muito importante, já nas lesões quísticas a cor é mais importante porque a tripla camada de cor confirma a benignidade e o carácter quístico.

Conhecendo os tópicos abordados neste capítulo, consegue-se interpretar melhor a técnica de elastografia para segmentar as devidas lesões em imagens de elastografia. Tendo em conta as características das imagens de elastografia, tal como os artefactos contidos nas mesmas, o ponto branco que ocorre dentro da lesão, a tripla camada de cor em baixo da lesão e a zona mais escura da imagem, pela qual o médico especialista identifica a lesão com o auxílio das imagens de ecografia modo-B, reconhecesse mais facilmente as lesões nas imagens de elastografia. Atendendo ao poder dos operadores morfológicos sobre as imagens e às devidas técnicas de segmentação de imagem pretende-se desta forma obter os contornos das lesões nas imagens de elastografia.

Capítulo 3

Metodologia de Investigação

Neste capítulo são apresentadas e experimentadas várias técnicas de pré-processamento e de segmentação às imagens de ecografia modo-B e de elastografia a cores. Através dos resultados finais apresentados é selecionado o algoritmo *Region Based*. Este algoritmo é modificado para incluir um pré-processamento que procura isolar as lesões, e aplica o contorno ativo sem bordas de modo a conseguir obter os contornos dessas lesões. Face a estas modificações e adaptações o algoritmo passa-se a chamar de *Elasto Region*. É apresentado o estudo completo do funcionamento desta técnica contendo a *pipeline* de processamento, o pré-processamento, o contorno ativo sem bordas, a sobreposição de contorno e alguns dos seus parâmetros de ajuste. É também apresentada a razão de superposição que permite comparar os contornos e é descrito o hardware e o software utilizado em todo o processamento.

3.1 Metodologia

As imagens de elastografia são geradas mediante uma compressão uniforme dos tecidos que é induzida através de um transdutor perpendicular ou paralelo à lesão. O

transdutor utilizado é o mesmo para as imagens de elastografia e de ecografia que são recolhidas no exame. Mais tarde a imagem de elastografia é sobreposta à imagem de ecografia, de modo a se conseguir ter uma melhor perceção da lesão. Para este estudo as imagens foram adquiridas no Hospital de Faro E.P.E. pelo equipamento da ©GE Healthcare, modelo Logic 9 e no Hospital Santa Maria de Faro pelo equipamento da ©Siemens, modelo Acuson Antares, através do método de mãos livres. As imagens foram obtidas através da autorização das pacientes provenientes do Programa de Rastreio de Cancro da Mama, e das pacientes do HPP Santa Maria de Faro, ao abrigo do Projecto de Investigação submetido pela Universidade do Algarve, Faculdade de Engenharia à FCT, sobre elastografia.

Uma pesquisa sobre os tipos de implementações de algoritmos de segmentação que já se encontram disponíveis levou à identificação de implementações do *Normalized Cut*, *Watershed*, *Region Based*, etc. As implementações encontradas são maioritariamente em ©Matlab. Cada uma destas acompanha uma breve explicação e um ficheiro de demonstração com algumas imagens exemplo, reais e sintéticas, por forma a clarificar o seu funcionamento. Posto isto estas foram experimentadas em imagens de ecografia modo-B e de elastografia a cores e avaliadas pelo seu desempenho e de forma visual. Dos algoritmos encontrados, foram experimentados:

- *Snakes: Active Contour Models*
- *Chan-Vese Active Contours*
- *Creaseg*
- *DRLSE v0*
- *RSF v0.1*
- *My CImg Algorithm Implementation*
- *Levelset Seg Biascorrection*
- *Region Based (Elasto Region)*

Após uma breve experiência exploratória em diversas imagens para confirmar o funcionamento dos algoritmos e analisar o seu comportamento na segmentação, foram escolhidas duas imagens de teste: uma de elastografia a cores e outra de ecografia modo-B, que contêm um nódulo bem definido e cujos limites são regulares

e de fácil identificação o que permite avaliar o desempenho dos métodos. Em ambos os casos (elastografia e ecografia modo-B) foram analisadas a imagem original e a imagem original pré-processada. Este pré-processamento efetuado vai desde converter a imagem para a escala de cinza, a utilizar filtros para suavizar a imagem e a aplicar operadores morfológicos. Desta forma analisam-se os resultados de cada um dos algoritmos, e com base no comportamento destes, desde a maneira como o contorno ativo evolui perante as lesões, do pré-processamento efetuado, do tipo de segmentação aplicado e na observação dos resultados finais de cada um, quando comparado visualmente com os contornos delineados pelo médico especialista, optou-se por escolher o *Region Based*. Com poucos ajustes (ver secção 3.2.3) o algoritmo demonstra resultados aceitáveis quando comparados visualmente com a lesão delimitada pelo médico especialista, pois o contorno é adaptado corretamente sendo muito sensível às extremidades das regiões e das lesões e razoavelmente rápido. Mais tarde passou-se a chamar *Elasto Region* ao algoritmo *Region Based* modificado e adaptado às imagens de elastografia. Descreve-se mais detalhadamente este algoritmo na secção 3.2.

Tendo o algoritmo escolhido foram estudadas as técnicas de pré-processamento para se conseguir incrementar os resultados. Foi também adicionado um modo de manipular o contorno final para que mais tarde se consiga sobrepô-lo à imagem original. Após ter o *Elasto Region* completo e adaptado às necessidades foram então processadas as imagens de elastografia a cores para se conseguir obter os contornos das lesões de forma semi-automática.

As imagens são recolhidas dos equipamentos dos hospitais no formato DICOM, sendo depois convertidas para PNG através da aplicação de imagem *mogrify* [14]. Após a conversão recortou-se a imagem de modo a ficar apenas com a imagem de elastografia a cores. A partir desta fase as imagens estão prontas para serem processadas com o *Elasto Region*.

Com o *Elasto Region* as imagens a processar devem encontrar-se no formato de

imagem PNG, pois este formato consegue uma compressão de dados sem perdas e assim conseguem-se isolar mais facilmente as lesões.

Descrevem-se em seguida os algoritmos:

3.1.1 Snakes: Active Contour Models

O algoritmo “Snakes: Active Contour Models” está implementado e disponibilizado à comunidade em código ©Matlab por Ritwik Kumar [15], com base no artigo científico “Snakes: Active Contour Models” [16]. A sua implementação contém um interface gráfico que permite ao utilizador carregar a imagem para a aplicação, que como está implementado requer que a imagem esteja na escala de cinza, suaviza-se a imagem com a aplicação de um filtro gaussiano e indica-se o perímetro inicial (PeI) que depois evolui para uma *snake*. A Figura 3.1 representa o interface gráfico.

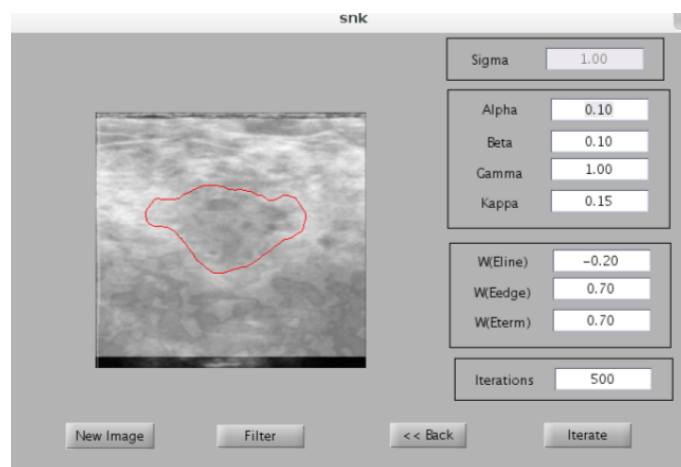


FIGURA 3.1: Interface gráfico do Snakes: Active Contour Models.

Este algoritmo recorre à técnica de contorno ativo ou *snake* (ver secção 3.2) para ajustar um modelo deformável a uma imagem ou contorno baseado num processo de minimização de energia.

Para facilitar o processo de ajustamento o método considera a suavização da imagem

através de um filtro gaussiano dado por:

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.1)$$

em que x e y são os parâmetros de localização e σ é o parâmetro que define a quantidade de suavização, permitindo assim aplicar o efeito *blur* às imagens, remover os detalhes e o ruído, que é o pré-processamento efetuado por esta implementação. Seja $v(s) = (x(s), y(s))$ a representação de cada um dos pontos da *snake* a ajustar. A energia total da *snake*, que se quer minimizar, é dada por:

$$E_{snake} = \int_0^1 E_{snake}(v(s)) ds \quad (3.2)$$

$$= \int_0^1 E_{int}(v(s)) + E_{imagem}(v(s)) + E_{con}(v(s)) ds \quad (3.3)$$

Onde E_{int} representa a energia interna da *spline* face à curva, E_{imagem} gera as forças da imagem, e E_{con} gera as forças de restrição externas. A energia interna da *snake* é dada por:

$$E_{int} = (\alpha(s)|v_s(s)|^2 + \beta(s)|v_{ss}(s)|^2)/2 \quad (3.4)$$

em que o valor α especifica a elasticidade da estrutura representada pelo contorno, controlando a tensão da estrutura combinado com os termos da primeira derivada ($v_s(s)$); o valor β que especifica a rigidez do contorno combinado com os termos da segunda derivada ($v_{ss}(s)$).

A energia total da imagem pode ser expressa como uma função ponderada de três funções de energia: E_{line} , E_{edge} e E_{term} , dada por:

$$E_{imagem} = \mathcal{W}_{line}E_{line} + \mathcal{W}_{edge}E_{edge} + \mathcal{W}_{term}E_{term} \quad (3.5)$$

em que E_{line} representa a energia da linha, E_{edge} a energia do contorno e E_{term} a energia dos segmentos de reta e das curvaturas, sendo W_{line} , W_{edge} e W_{term} os respectivos ponderadores. Onde $E_{line} = I(x, y)$, $E_{edge} = -|\nabla I(x, y)|^2$, ∇ representa o gradiente, $C(x, y) = G_\sigma(x, y) * I(x, y)$ uma versão ligeiramente suavizada da imagem, $\theta = \tan^{-1}(C_y/C_x)$ o gradiente do ângulo, $n = (\cos\theta, \sin\theta)$ e $n_\perp = (-\sin\theta, \cos\theta)$ vetores unitários ao longo e perpendiculares à direção do gradiente. Assim a curvatura do nível de contorno $C(x, y)$ pode ser equacionada por

$$E_{term} = \frac{\partial\theta}{\partial n_\perp} \quad (3.6)$$

$$= \frac{\partial^2 C / \partial n_\perp^2}{\partial C / \partial n} \quad (3.7)$$

$$= \frac{C_{yy}C_x^2 - 2C_{xy}C_xC_y + C_{xx}C_y^2}{(C_x^2 + C_y^2)^{3/2}} \quad (3.8)$$

Através dos resultados de segmentação obtidos com este algoritmo concluiu-se que é preciso ter cuidado na escolha do Pel pois a evolução do contorno ativo é pouco sensível. Se o Pel for iniciado muito longe dos limites do objeto o contorno não irá convergir para esse objeto. Aumentando o número de iterações não se consegue obter um melhor resultado, mas indicando o Pel com vários pontos em redor do objeto de interesse obtém-se uma melhor segmentação, apesar de em modo geral este falhar por ultrapassar os limites das regiões. Tendo em conta os resultados que esta implementação do algoritmo demonstrou, pode-se concluir que este funciona para imagens com poucos detalhes e deve ser aplicado apenas a imagens que tenham regiões e limites regulares e bem definidos porque a sua segmentação é muito suave.

3.1.2 Chan-Vese Active Contours

Este algoritmo foi implementado e disponibilizado em código ©Matlab por Yue Wu [17], com base nos artigos científicos de Chan e Vese “Active Contours Without Edges” [18],

“Active Contours Without Edges for Vectorvalued Image” [19] e “A Multiphase Level Set Framework for Image Segmentation using the Mumford and Shah Model” [20]. Utiliza três métodos distintos para imagens na escala de cinza, para imagens vetoriais e para imagens que contenham mais que duas cores. As expressões matemáticas deste algoritmo poderão ser consultadas na secção 3.2.3.

Este funciona corretamente caso se tenham os nódulos isolados, ou seja, que se consiga isolar as lesões das restantes regiões, assim requer que seja adicionado um bom pré-processamento antes de o utilizar. No entanto é preciso ter em consideração a escolha correta do Pel de modo a que a curva não disperse demais.

3.1.3 Creaseg

O ©Creaseg Software [21] é um projeto Open Source que contém vários algoritmos de segmentação de imagem. Está implementado em código ©Matlab, por Olivier Bernard [22] e outros [21], baseado nos artigos científicos de Caselles [23], Chan e Vese [18], Lankton [24], Bernard [25], Li [26] e Shi [27]. Através da sua interface gráfica é possível indicar o algoritmo que se pretende utilizar, pois dá acesso à implementação de seis métodos de conjuntos de níveis diferentes, de modo a abranger uma vasta gama de conjuntos de níveis e de dados. Estes podem ser contornos ou regiões. A Figura 3.2 representa o seu interface gráfico.

Permite ainda comparar o desempenho dos diferentes métodos, cujo desempenho pode ser calculado visualmente ou através de medidas de semelhança, desde utilizar o coeficiente de Sørensen–Dice, o valor de PSNR (Peak Signal-to-Noise Ratio), a distância de Hausdorff ou a medida MSSD (Mean Sum of Square Distance) entre a referência e os resultados de segmentação.

No carregamento da imagem na aplicação, esta é automaticamente convertida para a escala de cinza, e consoante o algoritmo escolhido existem diversos parâmetros de configuração para determinar os contornos. Neste software experimentaram-se os

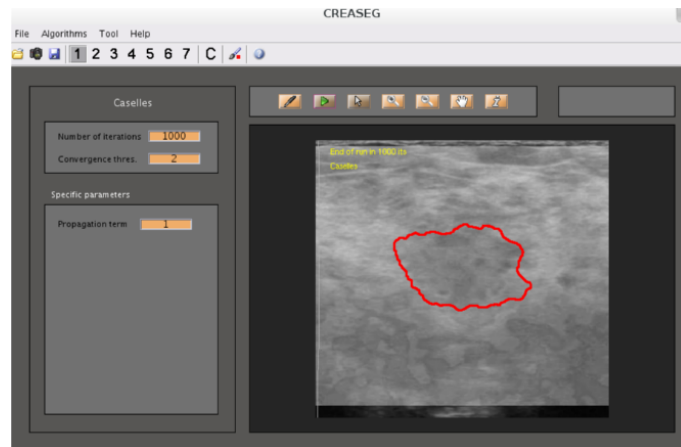


FIGURA 3.2: Interface gráfico do Creaseg.

sete métodos mas nenhum deu resultados sensíveis quando comparados com as delimitações efetuadas pelo médico especialista. É de realçar o método seis da aplicação, método Shi [27], sendo o que apresentou melhores resultados e sendo um algoritmo baseado nas aproximações dos conjuntos de níveis com base na evolução de curva. Este método lida com pontos interiores, pontos interiores adjacentes para a evolução da curva, pontos exteriores adjacentes para a evolução da curva e com pontos exteriores.

Denota-se o conjunto de pontos de grelha fechado por C como a região do objeto ω e o conjunto de pontos $D \setminus \Omega$ como a região de fundo. O objetivo é usar a evolução de curva para classificar cada ponto da grelha em qualquer objeto ou região de fundo. Define-se a lista de vizinhos interiores dos pontos da grelha L_{in} e vizinhos exteriores dos pontos da grelha por L_{out} para o objeto da região ω como:

$$L_{in} = \{x | x \in \Omega \exists y \in N(x) \text{ tal que } y \in D \setminus \Omega\} \quad (3.9)$$

$$L_{out} = \{x | x \in D \setminus \Omega \exists y \in N(x) \text{ tal que } y \in \Omega\} \quad (3.10)$$

onde,

$$N(x) = \{y \in D | \sum_{k=1}^K |y_k - x_k| = 1\} \quad (3.11)$$

representa a vizinhança discreta de x . A evolução da curva é baseada na equação:

$$\frac{dC}{dt} = F\vec{N} \quad (3.12)$$

que evolui a curva com base no campo velocidade F na direção normal \vec{N} . O conjunto de nível da evolução é conseguido pela resolução da expressão reguladora de grelha:

$$\frac{d\varphi}{dt} + F|\nabla\varphi| = 0 \quad (3.13)$$

onde φ é a função conjunto de nível.

3.1.4 DRLSE v0

Este algoritmo está implementado em código ©Matlab por Chunming Li [28], com base no artigo científico "Distance Regularized Level Set Evolution and Its Application to Image Segmentation" [29]. Permite calcular o contorno através de um modelo de contorno ativo baseado nas bordas como uma aplicação de "Distance Regularized Level Set Evolution" (DRLSE). O contorno ativo deste algoritmo utiliza a informação da imagem com base nas bordas para definir a energia externa. Sendo I uma imagem num domínio Ω define-se uma função indicadora de borda g por:

$$g \triangleq \frac{1}{1 + |\nabla G_\sigma * I|^2} \quad (3.14)$$

onde G_σ é a gaussiana de desvio-padrão σ . A função g geralmente assume valores menores nos limites do objeto do que outras localizações. Para uma função de conjunto de nível $\phi : \Omega \rightarrow \mathfrak{R}$, define-se a função de energia $\mathcal{E}(\phi)$ por:

$$\mathcal{E}(\phi) = \mu\mathcal{R}_p(\phi) + \lambda\mathcal{L}_g(\phi) + \alpha\mathcal{A}_g(\phi) \quad (3.15)$$

onde $\mu > 0$, $\lambda > 0$ e $\alpha \in \Re$ são os coeficientes de energia funcionais, $\mathcal{R}_p(\phi)$, $\mathcal{L}_g(\phi)$ e $\mathcal{A}_g(\phi)$ são definidos por:

$$\mathcal{R}_p(\phi) \triangleq \int_{\Omega} p(|\nabla\phi|)dx \quad (3.16)$$

sendo a função p reguladora de distância: $p \triangleq \frac{1}{2}(s - 1)^2$;

$$\mathcal{L}_g(\phi) \triangleq \int_{\Omega} g\delta(\phi)|\nabla\phi|dx \quad (3.17)$$

e

$$\mathcal{A}_g(\phi) \triangleq \int_{\Omega} gH(-\phi)dx \quad (3.18)$$

sendo δ a função delta de Dirac e H a função degrau unitário. A energia $\mathcal{L}_g(\phi)$ é mínima quando o nível do contorno zero de ϕ está localizado nos limites do objeto. A energia $\mathcal{A}_g(\phi)$ serve para aumentar a velocidade de movimento do nível do contorno zero no processo dos conjuntos de níveis, que é necessário quando o contorno inicial é colocado longe dos limites do objeto. Os resultados de segmentação obtidos são demasiado suaves.

3.1.5 RSF v0.1

O algoritmo está escrito em código ©Matlab por Chunming Li [28], com base no artigo científico "Minimization of Region-Scalable Fitting Energy for Image Segmentation" [26]. É baseado na minimização de energia de Chan e Vese (ver secção 3.2.3) e utiliza a suavização da gaussiana como representado na Equação 3.1 sendo o valor de $\sigma=3$ sensível e apropriado para iniciar a função de conjunto de nível, pois pretende-se assim remover os detalhes da imagem e algum ruído. O

algoritmo é baseado nas intensidades das regiões de escala controlada. Sendo a função núcleo $K : \mathfrak{R}^n \rightarrow [0, +\infty)$ com as seguintes propriedades: $K(-u) = K(u)$; $K(u) \geq K(v)$, se $|u| < |v|$, e $\lim_{|u| \rightarrow \infty} K(u) = 0$; $\int K(x)dx = 1$. Dado o vetor imagem $I : \Omega \rightarrow \mathfrak{R}^d$, onde $\Omega \subset \mathfrak{R}^n$ é o domínio da imagem e $d \geq 1$ sendo este a dimensão do vetor $I(x)$. Se $d = 1$ representa imagens de cinza, se $d = 3$ representa imagens a cores. Sendo C o contorno fechado no domínio da imagem Ω , que separa Ω em duas regiões: Ω_1 e Ω_2 , sendo que uma parte é a exterior ao contorno e outra é interior ao contorno. A energia de ajuste das intensidade locais para um ponto $x \in \Omega$ é dada por:

$$\mathcal{E}_x^{Fit}(C, f_1(x), f_2(x)) = \sum_{i=1}^2 \lambda_i \int_{\Omega_i} K(x-y)|I(y) - f_i(x)|^2 dy, \lambda_1 \text{ e } \lambda_2 \text{ são constantes positivas, } f_1(x) \text{ e } f_2(x) \text{ são dois valores que aproximam as intensidades da imagem em } \Omega_1 \text{ e } \Omega_2.$$

As intensidades $I(y)$ são as regiões locais centradas no ponto x , cujo tamanho é controlado pela função núcleo K . A função núcleo K utilizada é uma gaussiana: $K_\sigma(u) = \frac{1}{(2\pi)^{n/2}\sigma^n} e^{-|u|^2/2\sigma^2}$ com $\sigma > 0$. A energia de ajuste \mathcal{E}_x^{Fit} é dominada pelas intensidades $I(y)$ dos pontos y numa vizinhança de x , esta energia é minimizada quando o contorno C está exatamente nos limites do objeto e os valores de ajuste f_1 e f_2 aproximam-se das intensidades locais da imagem nos dois lados do contorno C . Para se trabalhar com as alterações topológicas utilizam-se os conjuntos de níveis representado por ϕ . Desta forma obtém-se:

$$\mathcal{E}(\phi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \int \left(\int K_\sigma(x-y)|I(y) - f_i(x)|^2 M_i(\phi(y)) dy \right) dx + \nu \int |\nabla H(\phi(x))| dx \quad (3.19)$$

onde, H é a função degrau unitário, $M_1(\phi) = H(\phi)$; $M_2(\phi) = 1 - H(\phi)$ e $\int |\nabla H(\phi(x))| dx$ calcula o comprimento do contorno de nível zero de ϕ .

3.1.6 My CImg Algorithm Implementation

O algoritmo está escrito em código C++ por Rafal Petryniak [30], e este utiliza a biblioteca CImg [31]. É utilizado o algoritmo *Watershed* para realizar a segmentação,

cujo código fonte está disponível em [32]. Tendo diversos conjuntos M_1, M_2, \dots, M_R que significam as coordenadas dos pontos de uma região mínima de uma imagem $g(x, y)$ e sendo $C(M_i)$ as coordenadas dos pontos de *watershed* que estão associados a regiões mínimas de M_i . Sendo

$$T[n] = \{(s, t) | g(s, t) < n\} \quad (3.20)$$

onde $T[n]$ representa o conjunto de coordenadas (s, t) para qual $g(s, t) < n$. Por analogia à topografia vai-se inundando de forma incremental através de: $n = \min + 1$ até $n = \max + 1$. A cada passo n da inundação precisa-se saber o número de pontos que pertence à profundidade. E

$$C_n(M_i) = C(M_i) \cap T[n] \quad (3.21)$$

onde $C_n(M_i)$ representa o conjunto de coordenadas dos pontos do *watershed* associados ao mínimo M_i que é inundado na fase n , ou seja, $C_n(M_i) = 1$ em (x, y) caso $(x, y) \in C(M_i)$ e $(x, y) \in T[n]$, caso contrário $C_n(M_i) = 0$. Sendo $C[n]$ a representação da união inundada no *watershed* na fase n :

$$C[n] = \bigcup_{i=1}^R C_n(M_i) \quad (3.22)$$

E

$$C[\max + 1] = \bigcup_{i=1}^R C(M_i) \quad (3.23)$$

a união de todos os *watersheds*.

Para se calcular as linhas de *watershed* é inicializado $C[\min + 1] = T[\min + 1]$. O algoritmo calcula de forma recursiva $C[n]$ de $C[n - 1]$, como tal, Q indica o conjunto de componentes ligados em $T[n]$ que para cada componente ligado $q \in Q[n]$ existem as seguintes possibilidades: $q \cap C[n - 1]$ está vazio; $q \cap C[n - 1]$ contém um componente

ligado a $C[n - 1]$; $q \cap C[n - 1]$ contém mais do que um componente ligado a $C[n - 1]$.

Para o estudo de imagens de elastografia esta implementação não consegue ser suficientemente sensível para se conseguir delimitar as lesões em causa, a menos que seja adicionado um pré-processamento às imagens, de modo a se isolar as regiões para que posteriormente se conseguir delimitá-las.

3.1.7 Levelset Seg Biascorrection

Este algoritmo está implementado em código ©Matlab por Chunming Li [28], baseado no artigo científico "A Level Set Method for Image Segmentation in the Presence of Intensity Inhomogeneities with Application to MRI" [9]. O algoritmo apresenta a evolução de conjuntos de níveis, LSE (Level Set Evolution), e a estimação do campo de polarização. Representa a formulação em duas fases que utilizam sinais das funções de conjuntos de níveis para representar duas regiões disjuntas, deste modo é utilizado para segmentar uma região em duas.

Este apresenta resultados muito bons, o contorno ativo chega a todos os lugares da imagem sem se ter muito cuidado com a localização dos pontos do Pel. Consegue delimitar todas as regiões corretamente, embora seja necessário um bom pré-processamento de modo a isolar as regiões pretendidas.

Sendo Ω o domínio da imagem e $I : \Omega \rightarrow \mathbb{R}$ uma imagem na escala de cinza. Calcula-se o contorno que separa o domínio da imagem em duas regiões Ω_1 e Ω_2 . Sendo ϕ a função de conjunto de nível, onde o contorno de nível zero $C = \{x : \phi(x) = 0\}$ separa as duas regiões, tem-se $\Omega_1 = \{x : \phi(x) > 0\}$ e $\Omega_2 = \{x : \phi(x) < 0\}$. Estas duas regiões podem ser representadas por $M_1(\phi) = H(\phi)$ e $M_2(\phi) = 1 - H(\phi)$, onde H é a função de degrau unitário. Desta forma a energia do contorno é dada por

$$\mathcal{E}(\phi, c, b) = \int \sum_{i=1}^N e_i(x) M_i(\phi(x)) dx \quad (3.24)$$

sendo e_i definido por: $e_i(x) = \int K(y-x)|I(x) - b(y)c_i|^2 dy$, em que K é a função núcleo e gaussiana definida por:

$$K(u) = \begin{cases} \frac{1}{a}e^{-|u|^2/2\sigma^2}, & \text{para } |u| \leq \rho \\ 0, & \text{outros casos} \end{cases} \quad (3.25)$$

os c_i são constantes e o b é o campo de viés, que define o que seria a imagem original e a imagem obtida pelo equipamento que se está a tratar. Desta forma a energia é minimizada com relação às variáveis c , b e ϕ .

3.2 Elasto Region

Sendo o algoritmo *Elasto Region* escolhido para se trabalhar as imagens de elastografia na escala de cor, segue-se todo o estudo e funcionamento do mesmo. O *Elasto Region* é baseado no *Region Based* que por sua vez é baseado na segmentação de Chan e Vese, do artigo científico “Active Contours Without Edges” [18], e é implementado em código ©Matlab por Shawn Lankton [33]. Este algoritmo foi modificado para incluir alguns procedimentos face à natureza das imagens de elastografia, tais como as técnicas de pré-processamento com a ajuda dos operadores morfológicos, a seleção do Pel, o modo de como manipular o contorno final e a maneira de se sobrepor o contorno final à imagem original. Estas alterações foram implementadas com o objetivo de facilitar e originar a melhor segmentação semi-automática possível. Ao implementar estas modificações no algoritmo, é-lhe atribuído o nome de *Elasto Region*.

3.2.1 Pipeline de Processamento

Como se observa na Figura 3.3, o algoritmo divide-se em duas partes. Na primeira parte são executadas técnicas de pré-processamento através do uso de operadores morfológicos, de modo a que se consiga isolar a lesão. Na segunda parte do algoritmo é aplicado o contorno ativo sem bordas para se obter o contorno da lesão. Desta maneira consegue-se obter o contorno final para que posteriormente possa-se sobrepor à imagem original, obtendo-se assim uma melhor percepção dos limites da lesão.

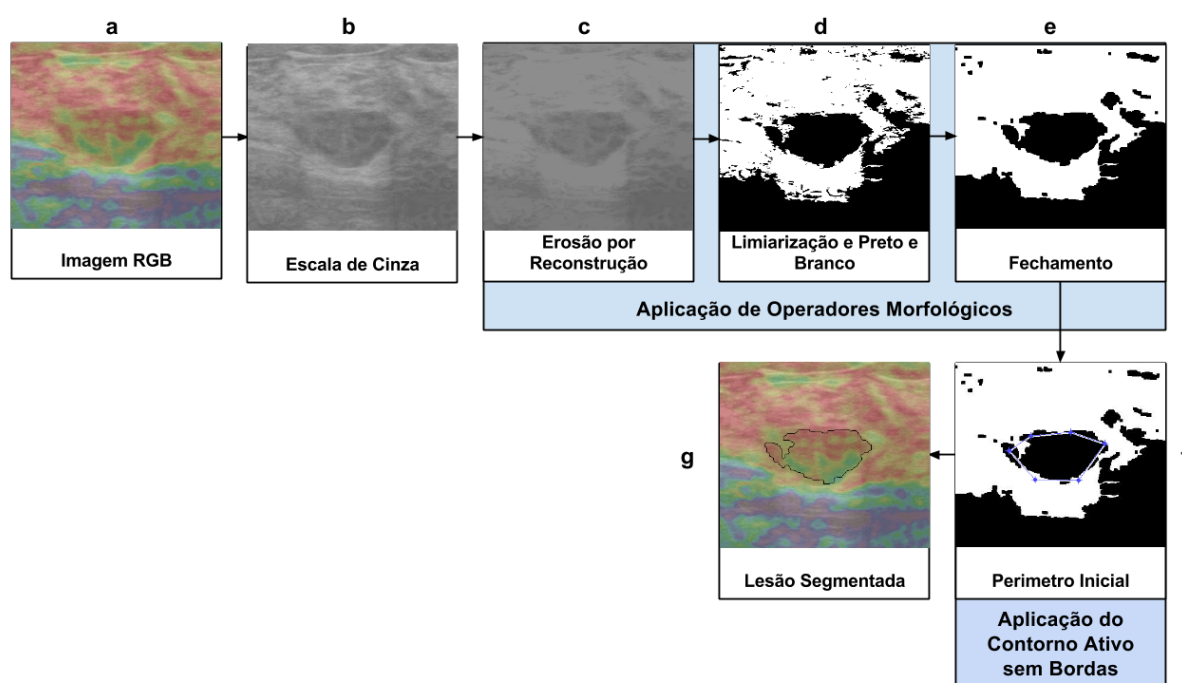


FIGURA 3.3: Pipeline de processamento do *Elasto Region*.

Face aos primeiros resultados de contornos calculados e à natureza de cada imagem de elastografia, chegou-se à conclusão de que é necessário fazer ajustes à *pipeline* de processamento original, pois há determinadas imagens onde o cálculo automático do valor de limiarização falha relativamente à lesão. Assim é necessário aplicar um valor de limiarização manual entre 0 e 1 para que se consiga ficar com a lesão na imagem (com o valor de limiarização determinado automaticamente a lesão pode não

ser identificada). Outra situação que pode requerer algum ajuste em algumas imagens, é originado ao aplicar os operadores erosão e reconstrução o que pode levar à perda da noção da lesão. Para evitar isto aplica-se o contorno ativo sem bordas diretamente à imagem na escala de cinza. Foram considerados três métodos distintos de processamento: o **método A** ou método Automático, o **método M** ou método Manual (de limiarização) e o **método C** ou método de Cinza.

O **método A** indica que é processado conforme a *pipeline* representada na Figura 3.3. O **método M** requer a indicação pelo utilizador do valor para a limiarização, d da Figura 3.3, para que se isole a lesão e mais tarde se indique o Pel. Os restantes passos seguem a *pipeline* da Figura 3.3. Por último o **método C**, requer que a aplicação do Pel e o contorno ativo sem bordas seja aplicado diretamente à imagem na escala de cinza sem se efetuar mais nenhum pré-processamento. Deve-se referir ainda que se recorreu ao método manual ou o método de cinza porque os anteriores falham, e que as razões que levaram a estas escolhas foi a inspeção visual, de cada imagem ao longo do processamento com o objetivo de conseguir uma melhor segmentação das lesões. Na prática o método automático é um método que apenas se indica o Pel, que após indicação do mesmo o algoritmo comporta-se de forma automática até obter o contorno final da lesão. O método manual requer que se indique de forma manual o valor de limiarização de imagem, por forma a isolar a lesão, e de seguida indicar o Pel, este evolui de forma automática até se obter o contorno final da lesão. Já o método de cinza requer que se indique o Pel, e de seguida evolui também de forma automática até obter o contorno final da lesão. A Tabela 3.1 representada tem como base a Figura 3.3.

Método A	$a \rightarrow b \rightarrow c \rightarrow \underline{d} \rightarrow e \rightarrow f \rightarrow g$
Método M	$a \rightarrow b \rightarrow c \rightarrow \underline{d} \rightarrow e \rightarrow f \rightarrow g$
Método C	$a \rightarrow b \rightarrow f \rightarrow g$

TABELA 3.1: Passos demonstrativos dos três tipos de métodos utilizados.

Estudam-se outros métodos alternativos tais como a separação de cores da imagem

RGB, que utiliza planos de cor em que a lesão esteja mais definida na componente de cor. Nesse plano aplica-se diretamente o contorno ativo sem bordas visto que em alguns casos na separação de cores já se consegue isolar e diferenciar as lesões. Mas na opinião do médico especialista, a cor não é o elemento mais importante para traçar os contornos; mais relevante é a quantidade de zonas escuras (menor brilho) da imagem. Passou-se a processar também as imagens no sistema de cor HSV. Aqui é feita a separação para a componente V, sendo esta a componente de luminosidade. Assim utilizaram-se duas estratégias para esta *pipeline*, uma foi utilizando a imagem na escala de cinza, a outra utilizando a componente V, do HSV. O médico especialista com base nas imagens de ecografia modo-B e elastografia a cores, traçou o contorno das lesões às 104 imagens de elastografia a cores de forma manual. Assim é possível fazer-se a comparação de contornos através da razão de superposição (ver secção 3.3), obtendo-se mais um elemento de avaliação dos contornos calculados.

De modo geral, quando na imagem de elastografia a cores se consegue identificar facilmente o nódulo e este apresenta uma dimensão razoável, recorre-se à *pipeline* original pois esta apresenta os melhores resultados neste tipo de imagens. Quando existe alguma dificuldade em identificar a lesão na imagem original ou quando a lesão é pequena, aí sim é necessário efetuar os ajustes, método manual ou cinza.

3.2.2 Pré-Processamento de Imagem

O pré-processamento de imagem é fundamental para que se possa trabalhar as imagens nas melhores condições. É neste processo que se prepara a imagem, se removem os ruídos, se aplicam os operadores morfológicos, se dimensiona a imagem, se realçam os contrastes e brilhos, se removem os marcadores, etc. No caso em estudo é ainda mais relevante visto ser nesta fase que se isolam os nódulos nas imagens. É com base num bom pré-processamento de imagem que se aumenta a probabilidade de sucesso na identificação dos contornos das lesões.




FIGURA 3.4: Exemplo das várias fases de pré-processamento do *Elasto Region*: *a*- imagem original de elastografia a cores; *b*- imagem original na escala de cinza; *c*- aplicado operador de erosão, de EE em disco e raio de 20, e reconstrução; *d*- aplicado a limiarização de forma automática e convertido para preto e branco; *e*- aplicado o operador de fechamento, de EE 5x5 com valores 1.

As fases de pré-processamento usadas neste estudo estão demonstradas na Figura 3.4 através de uma imagem de elastografia a cores: a imagem de elastografia a cores RGB é carregada (Figura 3.4 *a*), é convertida para a escala de cinza através da média dos 3 planos RGB calculada para cada pixel (Figura 3.4 *b*). É criado um EE em forma de disco com um raio de 20. A Figura 3.5 exemplifica um EE em disco com raio de 4. Com o EE em disco e de raio de 20 é aplicado o operador de erosão à imagem na escala de cinza, e o resultado é utilizado como marcador na aplicação do operador de reconstrução, sendo a imagem na escala de cinza utilizada como máscara. O resultado está ilustrado na Figura 3.4 *c*. Na imagem resultante aplica-se a limiarização global de forma automática através do método de Otsu e converte-se para preto e branco obtendo o resultado ilustrado na Figura 3.4 *d*. O método de Otsu assume que a imagem contém duas classes de pixels onde calcula a limiarização óptima separando

EE =	0	0	1	1	1	0	0
	0	1	1	1	1	1	0
	1	1	1	1	1	1	1
	1	1	1	1	1	1	1
	1	1	1	1	1	1	1
	0	1	1	1	1	1	0
	0	0	1	1	1	0	0

FIGURA 3.5: Exemplo de elemento estruturante em disco com raio de 4.

essas duas classes de modo a que a variação de intra-classes seja mínima. Este valor varia entre 0 e 1. Por último e para obter a lesão isolada e suavizada da Figura 3.4 e, aplica-se o operador morfológico de fechamento, com o auxílio de um novo EE de forma quadrada e de dimensão 5x5 com valores 1. O código ©Matlab desta sequência de procedimento encontra-se no Anexo A.

3.2.3 Contorno Ativo sem Bordas

O método de segmentação de contorno ativo sem bordas [18] de Chan e Vese vem de um problema formulado por Mumford e Shah [34] sobre as técnicas de evolução de curva e dos conjuntos de níveis.

A ideia dos modelos de contornos ativos ou de *snakes* é fazer evoluir um Pel sujeito a determinadas restrições de uma dada imagem. Começa-se com o Pel em torno do objeto de interesse que se pretende delimitar, este move-se na direção do objeto (convergindo) e tem de parar sobre os seus limites obtendo-se assim os contornos dos objetos. Isto é, tendo o Pel, é definido um custo para o perímetro com base nas propriedades geométricas e nos dados associados à imagem. O custo baseado na geometria é previsto para manter o perímetro suave, e o custo baseado nos dados da imagem é intencionado para atrair o contorno aos limites do objeto. Assim o perímetro é deformado de modo a diminuir este custo, movendo-se em direção à posição onde o custo é um mínimo local. O modelo de Chan e Vese [18] difere dos modelos clássicos pois não é baseado no gradiente da imagem para o processo de

paragem, e assim consegue detetar objetos cujos limites não são necessariamente definidos pelo gradiente. O critério de paragem do contorno ativo é baseado nas funções de Mumford e Shah [34]. Assim consegue-se um modelo que pode detetar vários casos, com ou sem gradiente, objetos com os limites suaves, espigados, rugosos ou até mesmo com limites não contínuos.

A definição do método de energia de Chan e Vese é apresentada na Equação 3.26 e 3.27.

$$E_{ChanVese} = F_1(C) + F_2(C) \quad (3.26)$$

$$= \int_{interna(C)} |u(x, y) - c_1|^2 dx dy + \int_{externa(C)} |u(x, y) - c_2|^2 dx dy \quad (3.27)$$

É com base nesta equação que é calculada a minimização de energia, onde $u(x, y)$ representa a localização do pixel em (x, y) numa imagem u a duas dimensões. O c_1 é o valor médio de tudo que é interno ao contorno C e o c_2 é o valor médio de tudo que é externo ao contorno C , ou seja, são as médias das regiões interiores e exteriores. Os dois termos das Equações 3.26 e 3.27 podem ser interpretados como duas forças, sendo baseadas no erro médio. O primeiro termo é a força para encolher o contorno e o segundo termo é a força para expandir o contorno. Estas duas forças estão equilibradas quando o contorno atinge os limites do objeto de interesse. No final tem-se o contorno C onde a energia $E_{ChanVese}$ é mínima. Esta energia é muito semelhante à do método de Otsu pois a limiarização de Otsu e o contorno C de Chan Vese fazem a mesma coisa. O método de Otsu tenta resolver o problema achando o mínimo global ao passo que o método de Chan Vese tenta resolver o problema achando o mínimo local.

Utilizando as variações dos cálculos é possível aproveitar a derivada da energia atendendo à forma do próprio perímetro. Assim encontra-se o caminho para deformar o perímetro tal que esta energia é sempre decrescente. Decrescendo a energia de forma iterativa, redefine-se continuamente as suposições para o caminho correto até

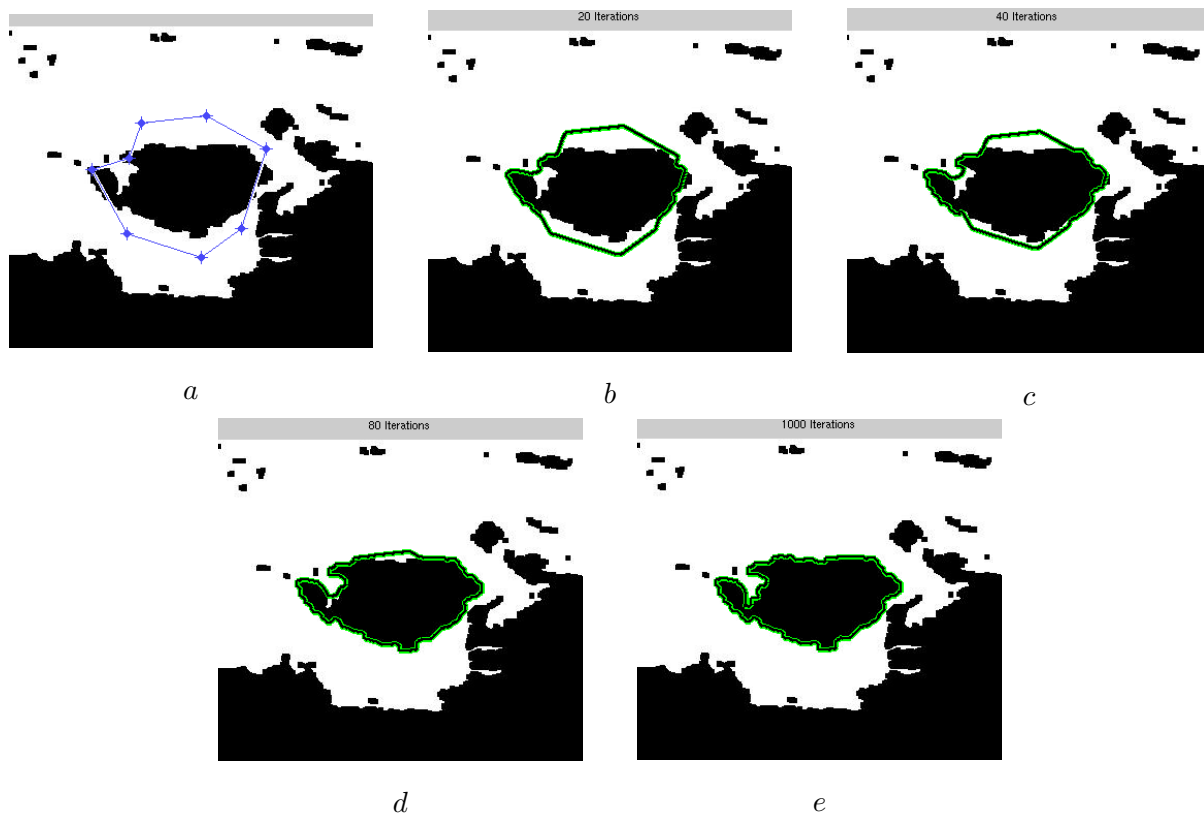


FIGURA 3.6: Fases do contorno ativo sem bordas do algoritmo *Elasto Region*: *a*- escolha do Pel; *b*- 20 iterações; *c*- 40 iterações; *d*- 80 iterações; *e*- 1000 iterações.

que finalmente se converge para uma solução de mínimo local.

O método baseia-se na segmentação dos conjuntos de níveis padronizados, o que faz com que os contornos interiores sejam automaticamente detetados e que o Pel (ou curva) possa ser colocado em qualquer parte da imagem. O método otimiza as diferentes energias e utiliza estatísticas globais, visando a minimização de energia que serve para delimitar os objetos ou regiões a partir de um Pel.

O funcionamento do contorno ativo sem bordas do algoritmo em estudo, é demonstrado na Figura 3.6. A imagem de elastografia é pré-processada de maneira a que a lesão fique isolada.

Em suma o método passa por deformar um Pel que move cada ponto do perímetro com base nas médias das regiões locais internas e externas. Este método apresenta bons resultados quando existe uma diferença entre essas médias das regiões. No

procedimento é definido um P_{el} , as linhas do perímetro representam a curva inicial que vai sendo calculada através de um processo iterativo que vai transformando o P_{el} num contorno ativo, adaptando-se cada vez mais em torno da região pretendida. No fim têm-se as regiões separadas e devidamente delineadas pelo contorno. Por defeito são utilizadas 1000 iterações, este valor foi definido de forma empírica a partir dos resultados das segmentações. Deste modo o algoritmo consegue ter alguma margem de conforto e obter o contorno com algum nível de sensibilidade e adaptado a todas as partes das lesões. O código ©Matlab pode ser consultado no Anexo A.

3.2.4 Sobreposição do Contorno

Após se obter o contorno final da lesão e por forma a ter uma maior perceção da lesão é representado o contorno final sobre a imagem original como ilustra a Figura 3.7. Uma vez mais o código ©Matlab deste pode ser consultado no Anexo A.




FIGURA 3.7: Exemplo de contorno final sobre a imagem original.

3.2.5 Principais Parâmetros de Ajustes

Existem alguns parâmetros que poderão ser ajustados no algoritmo. Tal como já mencionado antes, em algumas imagens é necessário ajustar o valor de limiarização para que se consigam isolar da melhor forma as lesões. Por defeito este valor é calculado automaticamente através da função *graythresh()* do ©Matlab, mas por vezes falha e a lesão não fica suficientemente visível. Nesse caso ajusta-se o valor de limiarização com o método manual. Outro parâmetro de ajuste possível é a escolha da dimensão dos EEs, mas de um modo geral os valores por defeito funcionam corretamente. O número de iterações a calcular também pode ser modificado, embora não seja recomendado, pois o valor por defeito é suficiente.

Perante os parâmetros de ajuste do contorno ativo sem bordas, não é recomendado que se façam grandes ajustes pois na maioria dos casos testados quando estes são alterados os resultados pioram. Os principais parâmetros são: o passo temporal (time step), o coeficiente de termo de comprimento e a dimensão da imagem de entrada. O passo temporal normalmente é muito pequeno, pois caso contrário as soluções das equações diferenciais vão divergir e a evolução do contorno pode expandir-se não fazendo qualquer sentido devido ao erro de propagação. O coeficiente do termo de comprimento não trará grandes mudanças mas permite alguma flexibilidade com alguns descuidos perante pequenos buracos. A dimensão da imagem de entrada porque quanto menor for a imagem mais rápida será a sua segmentação devido à atualização dos conjuntos de níveis.

3.3 Razão de Superposição

A razão de superposição (RS) [35] é um método que permite comparar dois contornos, cuja sua definição é apresentada na Equação 3.28,

$$RS = \frac{Area(S_r \cap S_o)}{Area(S_r \cup S_o)} \quad (3.28)$$

onde S_r é o contorno de referência e S_o o contorno obtido. O símbolo \cap representa a interseção e \cup representa a união. Caso $RS = 1$ os contornos são iguais.

Tendo as imagens com os contornos traçados pelo médico, e os calculados pelo algoritmo, é então possível utilizar a RS como critério de comparação de ambos os contornos. É necessário que ambos os contornos estejam fechados e assim pegando na componente de cor pela qual o contorno é traçado, aplica-se o operador de limiarização de valor 0.01 ou 0.99 (respetivamente para a imagem em RGB ou em HSV) e o operador preto e branco. A este resultado aplica-se o operador de preenchimento do tipo buracos, por forma a preencher a região dentro do contorno. Faz-se o mesmo para a imagem calculada pelo algoritmo, e pegando em ambos os resultados aplica-se a Equação 3.28. Na implementação computacional dessa equação utilizam-se as funções de interseção, união e *bwarea* do ©Matlab. No final aplica-se a média aritmética arredondada a 4 casas decimais e a respetiva percentagem arredondada por excesso. O código ©Matlab desta implementação poderá ser consultada também no Anexo A.

3.4 Hardware e Software Utilizado

Todo PI foi efetuado utilizando o seguinte *hardware* e *software*:

- **Processador:** 4x Intel(R) Core(TM) i5 CPU M 430 @ 2.27GHz;

- **Memória RAM:** 3920MB;
- **Placa Gráfica:** GeForce GT 330M/PCIe/SSE2;
- **Sistema Operativo:** Debian GNU/Linux (sid);
- **Matlab** R2013a;
- **ImageMagick** (mogrify) 6.7.7-10;
- **GNOME-screenshot** 3.8.3-1.

Capítulo 4

Resultados

Neste capítulo são apresentados, avaliados e discutidos os resultados finais dos contornos das lesões. São também indicadas algumas das limitações do algoritmo de estudo e dos diversos problemas encontrados ao longo da sua implementação.

4.1 Apresentação de Resultados

No total foram recolhidas 646 imagens mamárias de aproximadamente 40 pacientes, das quais 542 são de ecografia modo-B e 104 de elastografia a cores. Das 104 imagens de elastografia a cores, 59 são de lesões benignas e 45 de lesões malignas. O presente estudo trabalha só com as imagens de elastografia a cores, e as imagens de ecografia são apenas de auxílio para identificar e distinguir as lesões.

Processando as 104 imagens de elastografia a cores com o algoritmo *Elasto Region*, consegue-se uma segmentação utilizando os três métodos distintos (automático, manual e cinza). Utilizando o sistema de cor RGB que depois é convertido para a escala de cinza, tal como demonstra a Figura 3.3, e avaliando de forma visual, obtiveram-se 60 contornos considerados próximos do contorno de referência, nas imagens de elastografia a cores com o método automático, 32 contornos através do

método manual e 12 com o método de cinza. Utilizando o sistema de cor HSV, com a componente V, ou seja na *pipeline*, Figura 3.3, ao invés de se utilizar a imagem na escala de cinza substitui-se esta pela componente V da imagem em causa, chega-se aos resultados de 68 imagens obtidas pelo método automático e 36 pelo método manual, também avaliados de forma visual. Com a componente V do sistema de cor HSV, não se utiliza o método de cinza atendendo às propriedades desta componente. Aparentemente pode-se concluir que utilizando o sistema de cor HSV se consegue melhores resultados quando comparado com o sistema de cor RGB. No entanto atendendo à Tabela 4.1, perceber-se que o sistema de cor RGB é mais eficaz, porque quando se utiliza a razão de superposição, o RGB demonstra melhores resultados percentuais. Antes de se chegar à *pipeline* da Figura 3.3, tentou-se efetuar um outro pré-processamento, utilizando outros operadores morfológicos, como a dilatação, o complemento e outras reconstruções por forma a suavizar mais as imagens das lesões antes de se aplicar o operador de limiarização, mas face aos resultados obtidos deste pré-processamento, concluiu-se que a sua aplicação era excessiva piorando os resultados, pelo que se optou por manter a *pipeline* da Figura 3.3.

Exemplos de alguns resultados de contornos obtidos por ambos os métodos:




FIGURA 4.1: Imagem 009-A de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.1 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.698. O *Elasto Region* capturou a parte mais escura da imagem. A diferença entre os dois contornos (*b* e *c*) deve-se à imagem de elastografia representar uma área escura maior do que a lesão propriamente dita, no entanto o algoritmo comporta-se de forma pretendida.




FIGURA 4.2: Imagem 011-A de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contornos manuais das lesões feitos pelo médico especialista; *c*- contornos das lesões calculados pelo algoritmo *Elasto Region* via RGB.

A Figura 4.2 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.1045. O *Elasto Region* capturou as zonas mais escuras da imagem. A diferença entre os contornos (*b* e *c*) deve-se à imagem de elastografia representar uma das lesões como zona mais escura, embora que a imagem seja de aglomerados de microquistos e que a elastografia para este tipo de lesões ainda não seja a mais indicada. No entanto uma das lesões está ligeiramente ao lado conforme se confirma em *b*. O algoritmo comporta-se de forma pretendida capturando as zonas mais escuras da imagem.




FIGURA 4.3: Imagem 012-A de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.3 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.5894. O *Elasto Region* capturou a parte mais escura da imagem. A diferença entre os dois contornos (*b* e *c*) deve-se à imagem de elastografia representar a parte de baixo da lesão com maior brilho, o que no cálculo da limiarização esta zona é perdida. No entanto o algoritmo comporta-se como pretendido procurando a zona mais escura. Esta lesão contém um ponto branco no seu centro que o algoritmo o contorna, este ponto tem grande valor para os diagnósticos médicos.




FIGURA 4.4: Imagem 015-A de lesão maligna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.4 é de uma lesão maligna cujo valor da RS entre os dois contornos é de 0.1955. Esta imagem representa duas lesões, sendo uma dentro de outra. O contorno calculado pelo *Elasto Region* perde-se completamente, pois é difícil identificar e delimitar estas lesões. No resultado do pré-processamento efetuado à imagem sabe-se que a lesão não foi isolada corretamente daí falhar a suposta segmentação. Foi processada pelos três métodos mas nenhum deles conseguiu qualquer resultado próximo do traçado pelo médico especialista. De notar que o contorno calculado pelo algoritmo ficou aberto.




FIGURA 4.5: Imagem 024-A de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contornos manuais das lesões feitos pelo médico especialista; *c*- contornos das lesões calculadas pelo algoritmo *Elasto Region* via RGB.

A Figura 4.5 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.6392. O *Elasto Region* capturou as partes mais escuras da imagem. Existem umas diferenças entre os contornos (*b* e *c*) no entanto os contornos calculados pelo algoritmo estão próximos dos contornos de *b*.




FIGURA 4.6: Imagem 027-A de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.6 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.5818. O *Elasto Region* capturou grande parte da lesão quando comparado com *b*. Uma vez mais, as diferenças devem-se ao valor de limiarização calculado automaticamente pelo algoritmo que ultrapassa um pouco a lesão.




FIGURA 4.7: Imagem 037-A de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contornos manuais das lesões feitos pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.7 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.4138. O *Elasto Region* capturou a lesão como uma só. As diferenças entre

os contornos (*b* e *c*) devem-se sobretudo à representação das lesões na imagem de elastografia pois as lesões têm outras propriedades e não estão bem definidas através da zona mais escura.

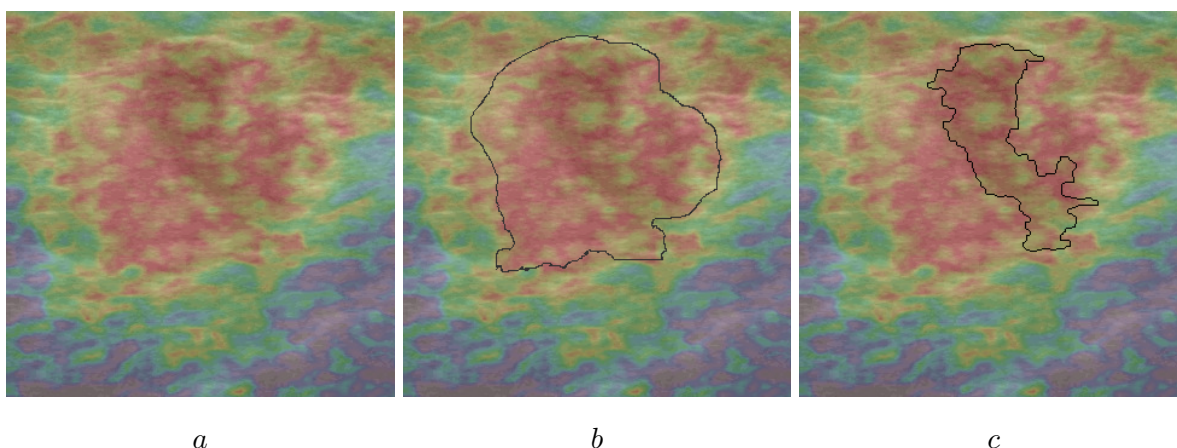


FIGURA 4.8: Imagem 060-M0.63 de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via plano V do HSV.

A Figura 4.8 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.3187. O *Elasto Region* capturou a zona mais escura da imagem. A diferença entre os dois contornos (*b* e *c*) deve-se à imagem de elastografia conter uma zona mais escura dentro da lesão. No entanto o algoritmo comporta-se como pretendido procurando a zona mais escura.




FIGURA 4.9: Imagem 064-M0.35 de lesão benigna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via plano V do HSV.

A Figura 4.9 é de uma lesão benigna cujo valor da RS entre os dois contornos é de 0.6088. O *Elasto Region* capturou a zona mais escura da imagem. A diferença entre

os dois contornos (b e c) é pequena podendo dizer-se que o algoritmo comporta-se como pretendido.




FIGURA 4.10: Imagem 067-A de lesão maligna, a - imagem de elastografia a cores original; b - contorno manual da lesão feito pelo médico especialista; c - contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.10 é de uma lesão maligna cujo valor da RS entre os dois contornos é de 0.4358. O *Elasto Region* capturou a parte mais escura da imagem. A diferença entre os dois contornos (b e c) deve-se à imagem de elastografia representar a parte de cima da lesão com maior brilho. No entanto o algoritmo comporta-se como pretendido procurando a zona mais escura.




FIGURA 4.11: Imagem 078-A de lesão maligna, a - imagem de elastografia a cores original; b - contorno manual da lesão feito pelo médico especialista; c - contorno da lesão calculado pelo algoritmo *Elasto Region* via plano V do HSV.

A Figura 4.11 é de uma lesão maligna cujo valor da RS entre os dois contornos é de 0.1295. O *Elasto Region* capturou a zona mais escura da imagem, que nesta imagem não representa a lesão. A segmentação feita pelo algoritmo falha a identificar a lesão tal como c demonstra.




FIGURA 4.12: Imagem 080-M0.2 de lesão maligna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.12 é de uma lesão maligna cujo valor da RS entre os dois contornos é de 0.0373. O *Elasto Region* capturou a parte mais escura da imagem. A diferença entre os dois contornos (*b* e *c*) deve-se à imagem de elastografia conter na sua parte inferior uma grande sombra o que perturba a isolar a zona mais escura da imagem.




FIGURA 4.13: Imagem 094-M0.31 de lesão maligna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.13 é de uma lesão maligna cujo valor da RS entre os dois contornos é de 0.3021. O *Elasto Region* capturou a zona mais escura da imagem. A diferença entre os dois contornos (*b* e *c*) deve-se à imagem de elastografia conter uma zona mais escura dentro da lesão, que representa o início da lesão embora seja o tamanho da lesão representado em *b*. No entanto o algoritmo comporta-se como pretendido procurando a zona mais escura.

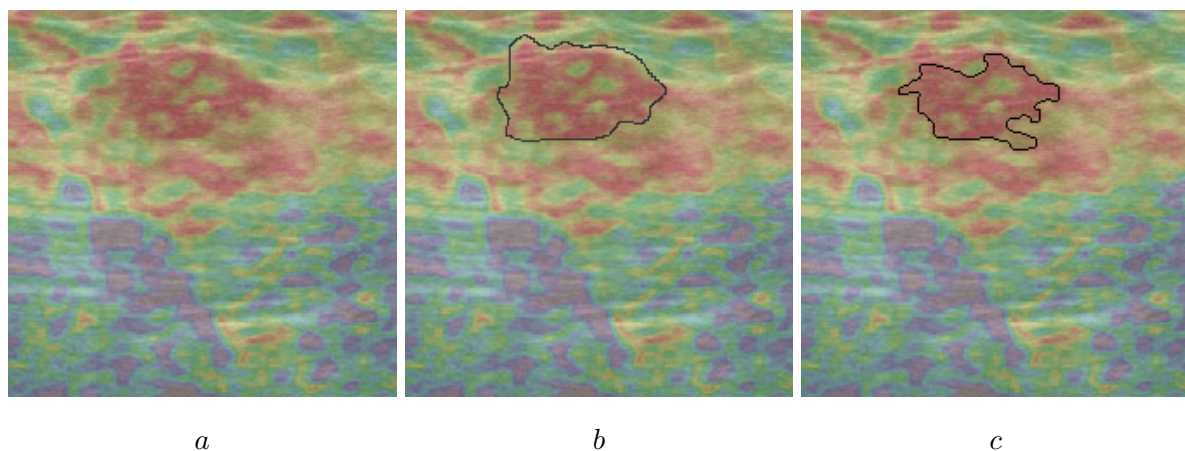


FIGURA 4.14: Imagem 104-A de lesão maligna, *a*- imagem de elastografia a cores original; *b*- contorno manual da lesão feito pelo médico especialista; *c*- contorno da lesão calculado pelo algoritmo *Elasto Region* via RGB.

A Figura 4.14 é de uma lesão maligna cujo valor da RS entre os dois contornos é de 0.6081. O *Elasto Region* capturou a zona mais escura da imagem.

4.2 Avaliação de Contornos

A Tabela 4.1 ilustra os valores da RS que dá a diferença entre os contornos: o contorno feito pelo médico especialista de forma manual, utilizado como referência, e o calculado pelo algoritmo. Os valores de RS variam entre 0 e 1 e são valores adimensionais. Caso se obtivesse o valor 1 seria o caso ideal em que o contorno feito pelo médico e o contorno calculado seriam exatamente iguais. A tabela apresenta também os valores dos dois sistemas de cor utilizados RGB e HSV, e o método pelo qual o contorno foi calculado, apresentado no nome da imagem, cujo método manual indica o valor de limiarização utilizado.

Para adquirir alguma sensibilidade aos dados e face ao valor da média aritmética 0.3690 da Tabela 4.1 ter sido pequeno, calculou-se uma vez mais a média aritmética (média2 da Tabela 4.1), mas agora com a diferença que são removidas todas as imagens na qual o algoritmo não conseguiu sequer obter 10% do contorno de

referência. As linhas da RS que têm uma cor de fundo acinzentado significam que foram estas as imagens que não se obteve 10% do contorno de referência. Desta maneira o resultado é especialmente significativo no caso de HSV. No entanto por não ser uma comparação justa, pois utilizam-se diferentes imagens para este segundo cálculo, não se considera na conclusão final esta experiência.

RGB	RS [0-1]	HSV	RS [0-1]	LESÃO
001-A.png	0.4015	001-M0.61.png	0.2591	maligna
002-M0.49.png	0.3504	002-M0.595.png	0.0978	maligna
003-C.png	0.6525	003-A.png	0.0725	benigna
004-C.png	0.3821	004-M0.625.png	0.0504	maligna
005-M0.49.png	0.6002	005-A.png	0	maligna
006-C.png	0.8331	006-A.png	0.6306	benigna
007-M0.53.png	0.5916	007-A.png	0.5823	benigna
008-M0.51.png	0.4846	008-A.png	0.6165	benigna
009-A.png	0.698	009-A.png	0.6556	benigna
010-A.png	0.7173	010-A.png	0.4951	benigna
011-A.png	0.1045	011-A.png	0.198	benigna
012-A.png	0.5894	012-A.png	0.6192	benigna
013-M0.49.png	0.4793	013-A.png	0.3906	benigna
014-M0.49.png	0.3321	014-A.png	0.3514	benigna
015-A.png	0.1955	015-M0.64.png	0.3128	maligna
016-C.png	0.0141	016-A.png	0.0159	maligna
017-M0.53.png	0.4882	017-M0.64.png	0.3864	benigna
018-M0.53.png	0.6684	018-M0.64.png	0.4765	benigna
019-A.png	0.6235	019-A.png	0.6587	maligna
020-A.png	0.1293	020-A.png	0.0495	benigna
021-M0.45.png	0.1831	021-A.png	0.0084	maligna
022-M0.45.png	0.328	022-A.png	0.0148	maligna
023-A.png	0.6725	023-A.png	0.6793	benigna
024-A.png	0.6392	024-A.png	0.4708	benigna
025-M0.48.png	0.725	025-A.png	0.5783	benigna
026-M0.49.png	0.6522	026-M0.59.png	0.7251	benigna
027-A.png	0.5818	027-A.png	0.4988	benigna
028-A.png	0.3328	028-A.png	0.5335	benigna
029-C.png	0.2196	029-A.png	0.178	benigna
030-A.png	0.491	030-A.png	0	benigna
031-C.png	0.0608	031-A.png	0.0012	maligna
032-M0.529.png	0.6477	032-A.png	0.5236	benigna
033-A.png	0.4307	033-A.png	0.3099	benigna
034-A.png	0.5936	034-A.png	0.4156	benigna
035-A.png	0.7604	035-A.png	0.8091	benigna
036-M0.47.png	0.7291	036-M0.58.png	0.0253	benigna
037-A.png	0.4138	037-A.png	0.2015	benigna
038-A.png	0.3563	038-A.png	0.075	benigna
039-A.png	0.5412	039-A.png	0.649	benigna
040-A.png	0.4046	040-A.png	0.3028	benigna
041-A.png	0.3704	041-A.png	0.3574	benigna
042-A.png	0.3135	042-A.png	0.2696	benigna
043-M0.55.png	0.2713	043-M0.65.png	0.2765	benigna
044-C.png	0.1246	044-A.png	0.0082	benigna
045-C.png	0.0119	045-A.png	0	benigna
046-C.png	0.2353	046-M0.635.png	0.3846	benigna
047-C.png	0.0096	047-A.png	0.0038	benigna
048-C.png	0.1434	048-A.png	0.0096	benigna
049-A.png	0.3261	049-M0.64.png	0.0877	benigna
050-A.png	0.1317	050-A.png	0.0911	benigna
051-A.png	0.4245	051-M0.62.png	0.3701	benigna
052-M0.47.png	0.5408	052-A.png	0.0632	benigna
053-A.png	0.2264	053-M0.64.png	0.2172	benigna

054-A.png	0.5605	054-M0.64.png	0.2509	benigna
055-M0.508.png	0.5451	055-A.png	0	maligna
056-A.png	0.4924	056-M0.635.png	0.253	maligna
057-C.png	0.4595	057-M0.62.png	0.2507	maligna
058-A.png	0.1112	058-A.png	0.0096	maligna
059-A.png	0.3009	059-M0.6.png	0.0542	maligna
060-A.png	0.3006	060-M0.63.png	0.3187	benigna
061-A.png	0.3154	061-M0.6.png	0.186	benigna
062-A.png	0.3929	062-M0.619.png	0.3508	benigna
063-M0.2.png	0.6062	063-M0.35.png	0.6251	benigna
064-M0.2.png	0.5713	064-M0.35.png	0.6088	benigna
065-M0.2.png	0.6971	065-M0.35.png	0.7685	benigna
066-M0.2.png	0.5952	066-M0.33.png	0.4875	benigna
067-A.png	0.4358	067-A.png	0.4166	maligna
068-A.png	0.5446	068-A.png	0.5476	maligna
069-A.png	0.0242	069-A.png	0.0346	maligna
070-A.png	0.0255	070-A.png	0.0274	maligna
071-A.png	0.6366	071-A.png	0.7218	maligna
072-A.png	0.1063	072-A.png	0.3592	maligna
073-A.png	0.1809	073-A.png	0.4119	maligna
074-A.png	0.0198	074-A.png	0.3914	maligna
075-A.png	0.0553	075-A.png	0.0272	maligna
076-M0.2.png	0.0437	076-M0.33.png	0.049	maligna
077-A.png	0.096	077-A.png	0.2082	maligna
078-A.png	0.1093	078-A.png	0.1295	maligna
079-A.png	0.1415	079-A.png	0.1672	maligna
080-M0.2.png	0.0373	080-M0.35.png	0.5116	maligna
081-M0.19.png	0.387	081-M0.35.png	0.5318	maligna
082-A.png	0.3648	082-A.png	0.5155	maligna
083-A.png	0.009	083-A.png	0.0033	maligna
084-A.png	0.0261	084-A.png	0.0329	benigna
085-A.png	0.0245	085-M0.34.png	0.628	benigna
086-M0.21.png	0.5748	086-M0.33.png	0.5758	benigna
087-M0.21.png	0.4779	087-M0.36.png	0.5474	benigna
088-A.png	0.7467	088-M0.4.png	0.8382	benigna
089-A.png	0.867	089-M0.35.png	0.7782	benigna
090-A.png	0.7293	090-A.png	0.7636	maligna
091-M0.2.png	0.0412	091-A.png	0.0462	maligna
092-M0.3.png	0.0267	092-A.png	0.0448	maligna
093-A.png	0.0242	093-M0.4.png	0.0259	maligna
094-M0.31.png	0.3021	094-M0.47.png	0.0266	maligna
095-A.png	0.0475	095-M0.47.png	0.0556	maligna
096-A.png	0.0603	096-A.png	0.0445	maligna
097-A.png	0.5572	097-A.png	0.0443	maligna
098-A.png	0.3276	098-A.png	0.061	maligna
099-A.png	0.6923	099-A.png	0.5927	benigna
100-M0.27.png	0.4585	100-A.png	0.0432	benigna
101-M0.475.png	0.0048	101-A.png	0.0039	maligna
102-A.png	0.3354	102-M0.599.png	0.0753	maligna
103-M0.52.png	0.0521	103-A.png	0.0344	maligna
104-A.png	0.6081	104-A.png	0	maligna
MÉDIA	0.3690		0.2936	
MÉDIA (%)	37%		29%	
DESVIO PADRÃO	0.24		0.25	
MÉDIA2 (%)	45%		46%	

TABELA 4.1: Resultados da razão de superposição, entre o contorno do médico (referência) e o calculado.

4.3 Discussão de Resultados

Face aos resultados obtidos de forma quantitativa (através da RS) pode-se concluir que os contornos correspondentes a resultados próximos dos esperados não chegam a metade das lesões abrangidas, ou seja, das 104 imagens não se conseguiu obter 50% das lesões. Ao recalculer o valor da média aritmética (média² da Tabela 4.1), ou seja, sem as imagens cujo resultado não abranja 10% da lesão, sobe-se o valor da média, apesar de não se utilizar as 104 imagens. O facto pelo qual não se conseguir obter 10% do contorno de referência em determinadas imagens deve-se sobretudo ao contorno calculado não ter sido fechado, ou seja, o contorno obtido não foi uma área fechada, este dispersou pela imagem e não se obteve um contorno fechado, exemplo ver Figura 4.4 c. Daí os valores da RS em determinadas imagens serem muito pequenos.

Para algumas imagens os resultados foram razoáveis, para outras foram maus. Isto deve-se principalmente às características de cada imagem e às limitações do algoritmo. Naquelas que se consegue identificar facilmente a lesão e estão bem definidas o algoritmo com a *pipeline* original funciona relativamente bem. Agora quando existem pequenas lesões ou várias lesões na mesma imagem, a *pipeline* original, método automático, geralmente falha, daí se utilizar o método manual, pois caso contrário o valor da limiarização calculado automaticamente falha as lesões.

Comparando os dois sistemas de cor utilizados, RGB e HSV, depreende-se que o RGB consegue melhores resultados, pois em termos percentuais para as 104 imagens obteve-se cerca de 8% a mais. Já no HSV sem as imagens de 10% do contorno obtido, ou seja, trabalhando apenas com 63 imagens, apresentou um resultado de cerca de 46%. Enquanto que o número de imagens de RGB pela qual não se conseguiu obter 10% do contorno foi de 21 imagens, ou seja trabalhou-se 83 imagens e conseguiu-se cerca de 45%. Segue a Tabela 4.2 que ilustra esta explicação mais explicitamente.

Avaliando os contornos de forma visual o sistema de cor HSV aparenta ser melhor

Nº imagens	104	63 (>10%)	83 (>10%)
RGB	37 %	-----	45 %
HSV	29 %	46 %	-----

TABELA 4.2: Resultados finais comparativos dos dois sistemas de cor: RGB e HSV.

que o sistema de cor RGB, no entanto através da razão de superposição, confirma-se exatamente o contrário.

A Tabela 4.3 demonstra com maior sensibilidade os resultados obtidos pelos três métodos dos vários tipos de lesões. Pode-se concluir que o método automático é superior relativamente aos outros dois métodos (manual e cinza), através dos resultados no sistema de cor RGB de 30.77% e 26.92% para lesões benignas e malignas respetivamente, e no sistema de cor HSV de 35.58% lesões benignas e 29.81% malignas.

O maior problema do método automático é a dificuldade em se reconhecer ou isolar a lesão. Esta dificuldade está associada sobretudo à difícil representação da lesão na imagem. O método automático geralmente falha a segmentar as lesões que não apresentem uma zona escura, quando vários micro-quistos pequenos estão contidos na imagem ou quando existe uma sombra muito grande em torno da lesão. O método automático comporta-se melhor quando se tem uma zona escura na imagem que geralmente representa a lesão.

Atendendo aos resultados da Tabela 4.3 não se consegue ter uma preferência perante os resultados experimentais nos dois tipos de lesões, tanto em imagens benignas como malignas, nem face ao sistema de cor RGB e HSV. Quando comparados os valores percentuais são muito semelhantes. Talvez num universo maior de imagens de elastografia, se consiga tirar uma conclusão mais clara sobre o melhor método para um tipo de lesão.

Tentou-se utilizar também imagens de elastografia obtidas diretamente na escala de cinza, mas face à pouca quantidade de imagens adquiridas, à natureza das mesmas e aos resultados, concluiu-se que são mais difíceis de analisar e de levar a resultados

	RGB				HSV			
	nº benignas	(%)	nº malignas	(%)	nº benignas	(%)	nº malignas	(%)
Método A	32	30.77	28	26.92	37	35.58	31	29.81
Método M	19	18.27	13	12.50	22	21.15	14	13.46
Método C	8	7.69	4	3.85	-----	----	-----	----

TABELA 4.3: Resultados comparativos dos três tipos de métodos usados e do tipo de lesão das 104 imagens.

satisfatórios.

A Tabela 4.4 representa os resultados dos diferentes sistemas de cor utilizados, quando calculados para 59 lesões benignas e 45 lesões malignas.

	RGB		HSV	
	benignas (%)	malignas (%)	benignas (%)	malignas (%)
Método A	54.24	62.22	62.71	68.89
Método M	32.20	28.89	37.29	31.11
Método C	13.56	8.89	-----	-----

TABELA 4.4: Resultado comparativo de 59 lesões benignas e 45 lesões malignas.

Pelo método automático pode-se dizer que o sistema de cor HSV foi mais justo porque funcionou melhor para imagens benignas como malignas. Já no método manual houve maior coerência pelo sistema de cor RGB face a lesões benignas e malignas.

4.4 Limitações e Problemas Encontrados

Tal como referido anteriormente, quando se trata de PI não existe um único padrão para todas as imagens, pois o procedimento vai depender muito da natureza e das características de cada imagem. A segmentação automática ou semi-automática de imagens é uma das tarefas mais difíceis do PDI. Consegue-se avaliar melhor os resultados dos diversos métodos e algoritmos através da experimentação exaustiva a uma grande quantidade de imagens.

Perante as limitações e problemas encontrados no algoritmo em estudo é por exemplo o uso da função do ©Matlab *rgb2gray()* para converter as imagens para a escala de

cinza esta vai falhar mais tarde a isolar as devidas lesões, daí não ser utilizada mas sim efetuar-se a separação de cada componente de imagem e aplicar-se a média destas por forma a se obter a imagem na escala de cinza.

Relativamente ao valor de limiarização, geralmente nos casos onde as lesões das imagens são de difícil interpretação ou a região circundante é muito semelhante às características da lesão, é necessário ajustar manualmente este valor de modo a que se consiga isolar as lesões.

Em algumas situações o contorno ativo não abrange corretamente todas as regiões, neste caso uma possível solução será ter um maior cuidado na seleção do P_{el} de modo a obrigar o contorno a analisar determinada região.

Para o cálculo da RS é necessário que os contornos estejam todos fechados, caso contrário o cálculo desta falha.

Em muitas imagens processadas, principalmente nas imagens adquiridas pelo equipamento da ©GE Healthcare, Logic 9 do Hospital de Faro E.P.E, existe uma grande sombra abaixo da lesão o que torna mais difícil ao algoritmo fazer a separação da lesão, pois este perde-se confundindo a lesão com a sombra.

Capítulo 5

Conclusões

O último capítulo representa a conclusão do trabalho e o trabalho futuro que pode dar continuidade e melhorar as qualidades do algoritmo e de segmentação às imagens de elastografia.

5.1 Conclusão

Com a realização desta dissertação conseguiu-se obter resultados de segmentação das lesões em imagens de elastografia a cores. Utilizaram-se vários algoritmos de segmentação, mas atendendo aos resultados destes, e sendo a maioria baseados em contornos ativos, apenas um dos algoritmos foi selecionado. Adicionou-se um pré-processamento às imagens de elastografia por forma a isolar as lesões, e aplicou-se o contorno ativo de modo a delimitar as devidas lesões.

Através da RS conseguiu-se avaliar os contornos calculados. As regiões segmentadas comparadas às regiões delineadas pelo médico especialista. Os valores médios da RS demonstram que as áreas segmentadas coincidiram em pouco menos de 50%. Isto acontece porque as representações das lesões variam muito de acordo com as propriedades de cada imagem. Foi feito apenas um único

pré-processamento para todas as imagens de elastografia, sendo estas adquiridas por dois equipamentos distintos. Existem variadas lesões com diversos tipos de propriedades e que por vezes estas não estão bem definidas através da zona mais escura. Os contornos da elastografia precisam ainda ser melhor entendidos pela comunidade médica para definir padrões e relacioná-los aos diagnósticos. Só então pode-se definir um método computacional mais robusto para deteção do contorno e eventual classificação dos mesmos.

Utilizaram-se três métodos de segmentação que diferem ligeiramente da *pipeline* original, ou seja, é feito um ajuste à *pipeline* original. Os métodos constam do método automático, manual e cinza para as imagens no sistema de cor RGB. Para as imagens no sistema de cor HSV, utilizam-se apenas o método automático e o método manual. Face ao universo de 104 imagens de elastografia a cores e aos resultados obtidos, não se consegue afirmar qual o melhor sistema de cor para lesões benignas ou malignas. No entanto sabe-se que em ambos os sistemas de cor o método automático apresentou os melhores resultados. Se se comparar apenas o sistema de cor que apresentou melhores resultados para todo o universo de imagens de elastografia o sistema de cor RGB apresenta resultados mais satisfatórios.

Há que acrescentar que não se sabe qual o formato verdadeiro da lesão, pois a elastografia pode indicar bordas diferentes da ecografia modo-B. Não havendo uma ideia clara sobre os contornos das lesões por elastografia, dificulta a elaboração de diagnóstico. Até onde se pôde investigar, não há qualquer experiência prévia de segmentação a imagens de elastografia a cores, este pode ter sido um ponto de partida para que se faça evoluir as técnicas de segmentação e de pré-processamento a este tipo de imagens.

5.2 Trabalho Futuro

Possivelmente será necessário criar dois algoritmos distintos, ou melhor vários tipos de pré-processamento para os diversos tipos de imagens de elastografia. Separando as várias imagens, por tipo de lesão, e por tipo de equipamento utilizado na aquisição de imagem. Assim aplicar-se-ia para cada tipo de imagem o pré-processamento mais adequado.

Relativamente à questão dos médicos analisarem as imagens de elastografia sempre com base nas imagens de ecografia modo-B, talvez uma possível solução para melhorar os valores dos contornos calculados, seria sobrepor a lesão do modo-B de ecografia na imagem de elastografia e com base nas lesões de ambas isolar-se partindo daí. Tendo cuidado especial na sobreposição das imagens, pois sabe-se que utilizando o modo manual da elastografia faz um pequeno deslocamento na imagem quando a imagem é adquirida. Tem tendência a subir ligeiramente a lesão quando comparado com a lesão na imagem de ecografia modo-B.

Outra hipótese seria experimentar aplicar o algoritmo a imagens obtidas através de métodos automáticos de elastografia, tal como o SWE ou o ARFI.

Anexo A

Elasto Region.m

```
1 %% close and clear all
2 close all; clear all; clc;
3
4 %% Load image
5 path(path, '/diretorioimagens');
6
7 a = dir('53089178-e1.png'); norig='53089178-e1.png';
8
9 F = imread(a.name);
10 [~,name] = fileparts(norig);
11 % figure 1
12 figure; imshow(F); title(['Imagem original: ', a.name]);
13 copyfile(norig, 'resultados/')
14
15
16 %% pre-processing
17
18 % convert to "gray-scale"
19 F = im2double(F);
20 % converting RGB image to intensity image
21 r = F(:,:,1);
22 g = F(:,:,2);
23 b = F(:,:,3);
24 I = (r+g+b)/3;
25
26 % figure 2
27 figure; imshow(I); title('Imagem original na escala de cinza');
28 % imwrite(I,'bw.jpg');
29 filecinza=sprintf('resultados/%s-cinza.png',name);
30 imwrite(I,filecinza,'png');
31 [~,ouname] = fileparts(filecinza);
32
33 %% I=rgb2hsv(F);
34 %% I=I(:,:,3);
35 %% imwrite(I,'bw.jpg');
36 %%
37 %% % figure 2
38 %% figure; imshow(I); title('Imagem original convertida para HSV e esta é somente o V');
39 %% fileV=sprintf('resultados/%s-V.png',name);
40 %% imwrite(I,fileV,'png');
41 %% [~,ouname] = fileparts(fileV);
42
43 se = stre1('disk',20); % stre1 - Cria EE
```

```

44
45 % applying erode and reconstruct operators
46 Ie = imerode(I, se);
47 Iobr = imreconstruct(Ie, I);
48 % figure 3
49 figure; imshow(Iobr); title('Aplicado operador de erosão à imagem de cinza seguido pelo operador de reconstrução:');
50 % imwrite(Iobr,'bw.jpg');
51 % % % Iobr = I;
52 fileero=sprintf('resultados/%s-ero.png',ouname);
53 imwrite(Iobr,fileero,'png');
54 [~,ouname] = fileparts(fileero);
55
56 % Thresholded
57 bw = im2bw(Iobr, graythresh(Iobr)); %A3
58 % bw = im2bw(Iobr, 0.53); %Mvalor
59 % bw = im2bw(Iobrcbr, 0.2); %Mvalor
60 % bw = im2bw(Iobrcbr, graythresh(Iobrcbr)); %A
61 % bw = im2bw(Iobrcbr);
62 % figure 5
63 figure; imshow(bw); title('Thresholded opening-closing by reconstruction (bw)');
64 % imwrite(bw,'bw.jpg');
65 filebw=sprintf('resultados/%s-bw.png',ouname);
66 imwrite(bw,filebw,'png');
67 [~,ouname] = fileparts(filebw);
68
69 % suaviza e limpa detritos
70 se2 = strel(ones(5,5));
71 % se2 = strel('disk',1);
72 fgm2 = imclose(bw, se2);
73 figure; imshow(fgm2); title('fgm2');
74 imwrite(fgm2,'bw.jpg');
75 filefgm2=sprintf('resultados/%s-fgm2.png',ouname);
76 imwrite(fgm2,filefgm2,'png');
77 [~,ouname] = fileparts(filefgm2);
78
79
80 %% region based modificado
81 % demo of "Region Based Active Contours"
82 % coded by: Shawn Lankton (www.shawnlankton.com)
83 % http://www.shawnlankton.com/2007/05/active-contours/
84 % http://www.shawnlankton.com/2008/04/active-contour-matlab-code-demo/
85
86 I = imread('bw.jpg'); % load the image again, se nao fica tudo preto
87
88 m = roipoly(I); % create initial mask
89 % I = imresize(I,.5); % make image smaller
90 % m = imresize(m,.5); % for fast computation
91
92 [seg,C] = region_seg(I, m, 1000); % run segmentation
93 xy = {C.X; C.Y};
94 orig = F;
95 [r,c,d] = size(orig); % Get the image size
96 % figure 6;
97 figure; imshow(orig); title('Segmentação final do(s) nóduo(s)');
98 set(gca,'Units','normalized','Position',[0 0 1 1]); % Modify axes size
99 set(gcf,'Units','pixels','Position',[200 200 c r]); % Modify figure size
100 hold on; contorno = plot(xy{:});
101 set(contorno,'Color','black','LineWidth',1);
102 % set(contorno,'Color','yellow','LineWidth',1);
103 f = getframe(gcf); % Capture the current window
104 fileseg=sprintf('resultados/%s-seg.png',name);
105 imwrite(f.cdata,fileseg,'png'); % Save the frame data
106

```

A.1 RegionBased()

```

1  % Region Based Active Contour Segmentation
2  %
3  % http://www.shawnlankton.com/2007/05/active-contours/
4  % http://www.shawnlankton.com/2008/04/active-contour-matlab-code-demo/
5  %
6  % seg = region_seg(I,init_mask,max_its,alpha,display)
7  %
8  % Inputs: I          2D image
9  %         init_mask  Initialization (1 = foreground, 0 = bg)
10 %         max_its    Number of iterations to run segmentation for
11 %         alpha      (optional) Weight of smoothing term
12 %                   higer = smoother.  default = 0.2
13 %         display    (optional) displays intermediate outputs
14 %                   default = true
15 %
16 % Outputs: seg       Final segmentation mask (1=fg, 0=bg)
17 %         C          Contour
18 %
19 % Description: This code implements the paper: "Active Contours Without
20 % Edges" By Chan Vese. This is a nice way to segment images whose
21 % foregrounds and backgrounds are statistically different and homogeneous.
22 %
23 % Example:
24 % img = imread('tire.tif');
25 % m = zeros(size(img));
26 % m(33:33+117,44:44+128) = 1;
27 % seg = region_seg(img,m,500);
28 %
29 % Coded by: Shawn Lankton (www.shawnlankton.com)
30 %-----
31 function [seg,C] = region_seg(I,init_mask,max_its,alpha,display)
32
33     %-- default value for parameter alpha is .2
34     if(~exist('alpha','var'))
35         alpha = .2;
36     end
37     %-- default behavior is to display intermediate outputs
38     if(~exist('display','var'))
39         display = true;
40     end
41     %-- ensures image is 2D double matrix
42     I = im2graydouble(I);
43
44     %-- Create a signed distance map (SDF-Signed distance function) from mask
45     phi = mask2phi(init_mask);
46

```

```

47 - phi=im2double(phi); % adicionei eu para contours funcionar
48
49 -- main loop
50 - for its = 1:max_its % Note: no automatic convergence test
51
52 -     idx = find(phi <= 1.2 & phi >= -1.2); % get the curve's narrow band
53
54     -- find interior and exterior mean
55 -     upts = find(phi<=0); % interior points
56 -     vpts = find(phi>0); % exterior points
57 -     u = sum(I(upts))/(length(upts)+eps); % interior mean
58 -     v = sum(I(vpts))/(length(vpts)+eps); % exterior mean
59
60 -     F = (I(idx)-u).^2-(I(idx)-v).^2; % force from image information
61 -     curvature = get_curvature(phi,idx); % force from curvature penalty
62
63     dphidt = F./max(abs(F)) + alpha*curvature; % gradient descent to minimize energy
64
65     -- maintain the CFL condition
66 -     dt = .45/(max(dphidt)+eps);
67
68     -- evolve the curve
69 -     phi(idx) = phi(idx) + dt.*dphidt;
70
71     -- Keep SDF smooth
72 -     phi = sussman(phi, .5);
73
74     -- intermediate output
75 -     if((display>0)&&(mod(its,20) == 0))
76 -         C=showCurveAndPhi(I,phi,its);
77 -     end
78 - end
79
80     -- final output
81 -     if(display)
82 -         C=showCurveAndPhi(I,phi,its);
83 -     end
84
85     -- make mask from SDF
86 -     seg = phi<=0; % get mask from levelset
87
88
89
90
91 -----
92 -----

```

```

93  %-- AUXILIARY FUNCTIONS -----
94  %-----
95  %-----
96
97  %-- Displays the image with curve superimposed
98  function C=showCurveAndPhi(I, phi, i)
99  |   imshow(I,'initialmagnification',200,'displayrange',[0 255]); hold on;
100 |   contour(phi, [0 0], 'g','LineWidth',4);
101 |   contour(phi, [0 0], 'k','LineWidth',2);
102 |   C=contourcs(double(phi), [0 0]);
103 |   hold off; title([num2str(i) ' Iterations']); drawnow;
104
105  %-- converts a mask to a SDF
106  function phi = mask2phi(init_a)
107  |   phi=bwdist(init_a)-bwdist(1-init_a)+im2double(init_a)-.5;
108
109  %-- compute curvature along SDF
110  function curvature = get_curvature(phi,idx)
111  |   [dimy, dimx] = size(phi);
112  |   [y x] = ind2sub([dimy,dimx],idx); % get subscripts
113
114  |   %-- get subscripts of neighbors
115  |   ym1 = y-1; xm1 = x-1; yp1 = y+1; xp1 = x+1;
116
117  |   %-- bounds checking
118  |   ym1(ym1<1) = 1; xm1(xm1<1) = 1;
119  |   yp1(yp1>dimy)=dimy; xp1(xp1>dimx) = dimx;
120
121  |   %-- get indexes for 8 neighbors
122  |   idup = sub2ind(size(phi),yp1,x);
123  |   iddn = sub2ind(size(phi),ym1,x);
124  |   idlt = sub2ind(size(phi),y,xm1);
125  |   idrt = sub2ind(size(phi),y,xp1);
126  |   idul = sub2ind(size(phi),yp1,xm1);
127  |   idur = sub2ind(size(phi),yp1,xp1);
128  |   iddl = sub2ind(size(phi),ym1,xm1);
129  |   iddr = sub2ind(size(phi),ym1,xp1);
130
131  |   %-- get central derivatives of SDF at x,y
132  |   phi_x = -phi(idlt)+phi(idrt);
133  |   phi_y = -phi(iddn)+phi(idup);
134  |   phi_xx = phi(idlt)-2*phi(idx)+phi(idrt);
135  |   phi_yy = phi(iddn)-2*phi(idx)+phi(idup);
136  |   phi_xy = -0.25*phi(iddl)-0.25*phi(idur)...
137  |           +0.25*phi(iddr)+0.25*phi(idul);
138  |   phi_x2 = phi_x.^2;

```

```

139 -     phi_y2 = phi_y.^2;
140
141     %-- compute curvature (Kappa)
142     curvature = ((phi_x2.*phi_yy + phi_y2.*phi_xx - 2*phi_x.*phi_y.*phi_xy) ./...
143                 (phi_x2 + phi_y2 + eps).^(3/2)).*(phi_x2 + phi_y2).^(1/2);
144
145     %-- Converts image to one channel (grayscale) double
146     function img = im2graydouble(img)
147     [dimy, dimx, c] = size(img);
148     if(isfloat(img)) % image is a double
149         if(c==3)
150             img = rgb2gray(uint8(img));
151         end
152     else % image is a int
153         if(c==3)
154             img = rgb2gray(img);
155         end
156         img = double(img);
157     end
158
159     %-- level set re-initialization by the sussman method
160     function D = sussman(D, dt)
161     % SUSSMAN(D, dt) Corrects distance function so that it maintains |Dt| = 1
162     % (slope of 1) using method presented in Sussman "Level Set Approach in
163     % Two-Phase Flow":
164     %
165     % G(D) = sqrt( max[(a+)^2, (b-)^2] + max[(c+)^2, (d-)^2] ) - 1   if D > 0
166     %         = sqrt( max[(a-)^2, (b+)^2] + max[(c-)^2, (d+)^2] ) - 1   if D < 0
167     %         = 0                                                         otherwise
168     %
169     % Applies one iteration of:
170     %   Dt+1 = Dt - dt * S(D)*G(D)
171     %
172     % http://www.mathworks.com/matlabcentral/fileexchange/26101-active-contours-a-new-distribution
173
174     % forward/backward differences
175     a = D - shiftR(D); % backward
176     b = shiftL(D) - D; % forward
177     c = D - shiftD(D); % backward
178     d = shiftU(D) - D; % forward
179
180     % setup defaults for the positive and negative filtered versions
181     a_p = a; a_n = a; % a+ and a-
182     b_p = b; b_n = b;
183     c_p = c; c_n = c;

```

```

184 -     d_p = d;  d_n = d;
185
186     % positive ones are defined as having only those values that are
187     % positive, otherwise zero, for example:
188     % a_p(i,j) = a_p(i,j)   if a_p(i,j) > 0
189     %           = 0         otherwise
190 -     a_p(a < 0) = 0;
191 -     a_n(a > 0) = 0;
192 -     b_p(b < 0) = 0;
193 -     b_n(b > 0) = 0;
194 -     c_p(c < 0) = 0;
195 -     c_n(c > 0) = 0;
196 -     d_p(d < 0) = 0;
197 -     d_n(d > 0) = 0;
198
199 -     dD = zeros(size(D));
200 -     D_neg_ind = find(D < 0);
201 -     D_pos_ind = find(D > 0);
202 -     dD(D_pos_ind) = sqrt(max(a_p(D_pos_ind).^2, b_n(D_pos_ind).^2) ...
203 -                       + max(c_p(D_pos_ind).^2, d_n(D_pos_ind).^2)) - 1;
204 -     dD(D_neg_ind) = sqrt(max(a_n(D_neg_ind).^2, b_p(D_neg_ind).^2) ...
205 -                       + max(c_n(D_neg_ind).^2, d_p(D_neg_ind).^2)) - 1;
206
207 -     D = D - dt .* sussman_sign(D) .* dD;
208
209     %-- whole matrix derivatives
210     function shift = shiftD(M)
211     L shift = shiftR(M)';
212
213     function shift = shiftL(M)
214     L shift = [ M(:,2:size(M,2)) M(:,size(M,2)) ];
215
216     function shift = shiftR(M)
217     L shift = [ M(:,1) M(:,1:size(M,2)-1) ];
218
219     function shift = shiftU(M)
220     L shift = shiftL(M)';
221
222     function S = sussman_sign(D)
223     L S = D ./ sqrt(D.^2 + 1);
224

```

A.2 Contourcs()

```
1  function Cout = contourcs(varargin)
2  %CONTOURCS Wrapper to CONTOURS to Obtain Structure Output
3  % S = CONTOURCS(...) takes the exact same input arguments as the default
4  % CONTOURC but its output is a struct array with fields:
5  %
6  %     Level - contour line value
7  %     Length - number of contour line points
8  %     X     - X coordinate array of the contour line
9  %     Y     - Y coordinate array of the contour line
10 %
11 % See also contourc.
12
13 % Version 1.0 (Aug 11, 2010)
14 % Written by: Takeshi Ikuma
15 % Revision History:
16 % - (Aug. 11, 2010) : initial release
17
18 % Run CONTOURC and get output matrix
19 try
20     C = contourc(varargin{:});
21 catch ME
22     throwAsCaller(ME);
23 end
24
25 % Count number of contour segments found (K)
26 K = 0;
27 n0 = 1;
28 while n0 <= size(C,2)
29     K = K + 1;
30     n0 = n0 + C(2,n0) + 1;
31 end
32
33 % initialize output struct
34 e1 = cell(K,1);
35 Cout = struct('Level',e1,'Length',e1,'X',e1,'Y',e1);
36
37 % fill the output struct
38 n0 = 1;
39 for k = 1:K
40     Cout(k).Level = C(1,n0);
41     idx = (n0+1):(n0+C(2,n0));
42     Cout(k).Length = C(2,n0);
43     Cout(k).X = C(1,idx);
44     Cout(k).Y = C(2,idx);
45     n0 = idx(end) + 1; % next starting index
46 end
```

```
47
48 % Copyright (c)2010, Takeshi Ikuma
49 % All rights reserved.
50 %
51 % Redistribution and use in source and binary forms, with or without
52 % modification, are permitted provided that the following conditions are
53 % met:
54 %
55 % * Redistributions of source code must retain the above copyright
56 % notice, this list of conditions and the following disclaimer.
57 % * Redistributions in binary form must reproduce the above copyright
58 % notice, this list of conditions and the following disclaimer in the
59 % documentation and/or other materials provided with the distribution.
60 % * Neither the names of its contributors may be used to endorse or
61 % promote products derived from this software without specific prior
62 % written permission.
63 %
64 % THIS SOFTWARE IS PROVIDED BY THE COPYRIGHT HOLDERS AND CONTRIBUTORS "AS
65 % IS" AND ANY EXPRESS OR IMPLIED WARRANTIES, INCLUDING, BUT NOT LIMITED TO,
66 % THE IMPLIED WARRANTIES OF MERCHANTABILITY AND FITNESS FOR A PARTICULAR
67 % PURPOSE ARE DISCLAIMED. IN NO EVENT SHALL THE COPYRIGHT HOLDER OR
68 % CONTRIBUTORS BE LIABLE FOR ANY DIRECT, INDIRECT, INCIDENTAL, SPECIAL,
69 % EXEMPLARY, OR CONSEQUENTIAL DAMAGES (INCLUDING, BUT NOT LIMITED TO,
70 % PROCUREMENT OF SUBSTITUTE GOODS OR SERVICES; LOSS OF USE, DATA, OR
71 % PROFITS; OR BUSINESS INTERRUPTION) HOWEVER CAUSED AND ON ANY THEORY OF
72 % LIABILITY, WHETHER IN CONTRACT, STRICT LIABILITY, OR TORT (INCLUDING
73 % NEGLIGENCE OR OTHERWISE) ARISING IN ANY WAY OUT OF THE USE OF THIS
74 % SOFTWARE, EVEN IF ADVISED OF THE POSSIBILITY OF SUCH DAMAGE.
75
```

A.3 ContornoRS

```
1 %% close and clear all
2 close all; clear all; clc;
3
4 %% load image
5 path(path, '/contornosdadra');
6 path(path, '/minhasegmentacao');
7
8 a = dir('contornosdadra/53089178-el-seg-dra.png'); norig='contornosdadra/53089178-el-seg-dra.png';
9 b=imread('53089178-el-seg-A3.png');
10
11 F = imread(a.name);
12 % [~,name] = fileparts(norig);
13 % figure 1
14 figure; imshow(F); title(['contorno da dra: ', a.name]);
15
16 F = im2double(F);
17 g = F(:,:,2);
18 % figure; imshow(g); title('componente verde do contorno da dra');
19
20 r = F(:,:,1);
21 % figure; imshow(r); title('red');
22 % b1 = F(:,:,3);
23 % figure; imshow(b); title('blue');
24 % I = (r+g+b)/3;
25 % figure; imshow(I); title('cinza');
26 % % % I=rgb2hsv(F);
27 % % % v=I(:,:,3);
28 % % % figure; imshow(v); title('apenas o V do hsv');
29
30 bw = im2bw(g,0.99);
31 % % % bw = im2bw(v,0.4);
32 bw = imcomplement(bw);
33 % figure; imshow(bw); title('apenas o contorno da dra');
34
35 figure; imshow(b); title('a minha segmentacao');
36
37 % bw2 = im2bw(b,0.01);
38 % para imagens C***.png do outro H descomentar as 2 linhas seguintes e
39 % comentar a linha acima desta e mais abaixo comentar a dd=imcompl... e
40 % descomentar a dd=bw2, assim e que conseguimos para estas imagens.
41 y = b(:,:,2);
42 bw2 = im2bw(y,0.99);
43 % figure; imshow(bw2); title('apenas o contorno da minha segmentacao');
44
45 % # show overlaid images
46 figure; imshow(bw2), hold on;
```

```
47 - hImg = imshow(bw); set(hImg, 'AlphaData', 0.5); title('ambas sobrepostas');
48
49
50 - %% Cálculo do RS
51 - tt=imcomplement(bw);
52 - % figure; imshow(tt);
53 - pp=imfill(tt, 'holes');
54 - figure; imshow(pp); title('dra preenchido');
55
56 - % dd=imcomplement(bw2);
57 - dd=bw2;
58 - % figure; imshow(dd);
59 - qq=imfill(dd, 'holes');
60 - figure; imshow(qq); title('minha preenchida');
61
62 - intersecao2 = pp & qq;
63 - figure; imshow(intersecao2); title('intersecao2');
64 - uniao2 = pp | qq;
65 - figure; imshow(uniao2); title('uniao2');
66
67 - num2 = bwarea(intersecao2);
68 - den2 = bwarea(uniao2);
69
70 - RS2 = num2/den2
```

Bibliografia

- [1] Hui Zhi, Bing Ou, Bao-Ming Luo, Xia Feng, Yan-Ling Wen, and Hai-Yun Yang. Comparison of ultrasound elastography, mammography, and sonography in the diagnosis of solid breast lesions. *J Ultrasound Med*, 26(6):807–15, 2007. ISSN 0278-4297. URL <http://www.biomedsearch.com/nih/Comparison-ultrasound-elastography-mammography-sonography/17526612.html>.
- [2] J. Ophir. Elastography: A quantitative method for imaging the elasticity of biological tissues. *Ultrasonic Imaging*, 13(2):111–134, apr 1991. ISSN 01617346. doi: 10.1016/0161-7346(91)90079-w. URL [http://dx.doi.org/10.1016/0161-7346\(91\)90079-w](http://dx.doi.org/10.1016/0161-7346(91)90079-w).
- [3] Anca Ciurea, Dana Dumitriu, Cristiana Ciortea, Carolina Botar-Jig, and Sorin Dudea. Artifacts and pitfalls in breast elastoultrasonography: a pictorial essay. *Medical Ultrasonography*, 10(2), 2008.
- [4] Gonzalez R.C. and Woods R.E. *Digital Image Processing*. Pearson/Prentice Hall, 3rd edition, 2008. ISBN 9780131687288. URL <http://books.google.es/books?id=8uG0njRGEzoC>.
- [5] Gonzalez R.C., Woods R.E., and Eddins S.L. *Digital Image Processing Using MATLAB*. Gatesmark Publishing, 2nd edition, 2009. ISBN 0982085400. URL <http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0982085400>.
- [6] Matlab. Matlab digest academic edition @ONLINE, Dec 2013. URL http://www.mathworks.com/tagteam/64199_91822v00_eddins_final.pdf.

- [7] Alvarenga A.V., Infantosi A.F.C., Azevedo C.M., and Pereira W.C.A. Aplicação de operadores morfológicos na segmentação e determinação do contorno de tumores de mama em imagens por ultra-som. *Revista Brasileira de Engenharia Biomédica*, 19(2):91–101, 2002.
- [8] O.M. Filho and H.V. Neto. *Processamento digital de imagens*. Série Acadêmica. BRASPORT, 1999. ISBN 9788574520094. URL <http://books.google.pt/books?id=MAE0twAACAAJ>.
- [9] C. Li, R. Huang, Z. Ding, C. Gatenby, D. N. Metaxas, and J. C. Gore. A level set method for image segmentation in the presence of intensity inhomogeneities with application to mri. *IEEE Trans. Image Process.*, 20(7):2007–2016, July 2011.
- [10] C Balleyguier, S Canale, W Ben Hassen, P Vielh, E H Bayou, M C Mathieu, C Uzan, C Bourgier, and C Dromain. Breast elasticity: Principles, technique, results: An update and overview of commercially available software. *Eur J Radiol*, 2012. ISSN 1872-7727. URL <http://www.biomedsearch.com/nih/Breast-elasticity-Principles-technique-results/22445593.html>.
- [11] A. Itoh, E. Ueno, E. Tohno, H. Kamma, and H. Takahashi. Breast disease: Clinical application of us elastography for diagnosis. *Radiology*, 239:341–350, dec 2006. URL <http://radiology.rsnaajnl.org/cgi/content/abstract/239/2/341>.
- [12] K.M. Hiltawsky, Martin Krüger, Claudia Starke, Lothar Heuser, Helmut Ermert, and Arne Jensen. Freehand ultrasound elastography of breast lesions: clinical results. *Ultrasound in Medicine and Biology*, 27:1461–1469, 2001.
- [13] J Ophir, S K Alam, B Garra, F Kallel, E Konofagou, T Krouskop, and T Varghese. Elastography: ultrasonic estimation and imaging of the elastic properties of tissues. pages 203–233, 1999.
- [14] ImageMagick. Imagemagick: Command line tools: Mogrify @ONLINE, Dec 2013. URL <http://www.imagemagick.org/www/mogrify.html>.

- [15] Ritwik Kumar. Ritwik kumar @ONLINE, Feb 2013. URL <http://people.seas.harvard.edu/~rkkumar>.
- [16] Michael Kass, Andrew Witkin, and Demetri Terzopoulos. Snakes: Active contour models. *International Journal of Computer Vision*, 1(4):321–331, 1988.
- [17] Yue Wu. Yue wu @ONLINE, Dec 2013. URL <https://sites.google.com/site/rexstribeofimageprocessing>.
- [18] Tony F. Chan and Luminita A. Vese. Active contours without edges. *IEEE Transactions on Image Processing*, 10(2):266–277, 2001. URL <http://dblp.uni-trier.de/db/journals/tip/tip10.html#ChanV01>.
- [19] Tony F. Chan, B. Yezriev Sandberg, and Luminita A. Vese. Active contours without edges for vector-valued images. *Journal of Visual Communication and Image Representation*, 11:130–141, 2000.
- [20] Luminita A. Vese and Tony F. Chan. A multiphase level set framework for image segmentation using the mumford and shah model. *International Journal of Computer Vision*, 50(3):271–293, 2002. ISSN 0920-5691. doi: 10.1023/A:1020874308076. URL <http://dx.doi.org/10.1023/A%3A1020874308076>.
- [21] T. Dietenbeck, M. Alessandrini, D. Friboulet, and O. Bernard. Creaseg: A free software for the evaluation of image segmentation algorithms based on level-set. pages 665–668, 2010. ISSN 1522-4880. doi: 10.1109/ICIP.2010.5652991.
- [22] Olivier Bernard. Olivier bernard’s website @ONLINE, Dec 2013. URL <http://www.creatis.insa-lyon.fr/~bernard>.
- [23] Vicent Caselles, Ron Kimmel, and Guillermo Sapiro. Geodesic active contours. *Int. J. Comput. Vision*, 22(1):61–79, feb 1997. ISSN 0920-5691. doi: 10.1023/A:1007979827043. URL <http://dx.doi.org/10.1023/A:1007979827043>.

- [24] Shawn Lankton, Student Member, and Allen Tannenbaum. Localizing region-based active contours. *IEEE Trans. on Image Processing*, pages 2029–2039, 2008.
- [25] O. Bernard, D. Friboulet, P. Thevenaz, and M. Unser. Variational b-spline level-set: A linear filtering approach for fast deformable model evolution. *Image Processing, IEEE Transactions on*, 18(6):1179–1191, 2009. ISSN 1057-7149. doi: 10.1109/TIP.2009.2017343.
- [26] C. Li, C. Kao, J. C. Gore, and Z. Ding. Minimization of region-scalable fitting energy for image segmentation. *IEEE Trans. Image Process.*, 17(10):1940–1949, October 2008.
- [27] Yonggang Shi and W.C. Karl. A real-time algorithm for the approximation of level-set-based curve evolution. *Image Processing, IEEE Transactions on*, 17(5):645–656, 2008. ISSN 1057-7149. doi: 10.1109/TIP.2008.920737.
- [28] Chunming Li. Chunming li’s home page @ONLINE, Dec 2013. URL <http://www.engr.uconn.edu/~cml>.
- [29] C. Li, C. Xu, C. Gui, and M. D. Fox. Distance regularized level set evolution and its application to image segmentation. *IEEE Trans. Image Process.*, 19(12):3243–3254, December 2010.
- [30] Rafal Petryniak. rpetryniak @ONLINE, Dec 2013. URL <https://github.com/rpetryniak>.
- [31] Ronounours. The cimg library free audio and video software downloads at sourceforge.net @ONLINE, Dec 2013. URL <http://sourceforge.net/projects/cimg>.
- [32] Rpetryniak. Rpetryniak my cimg algorithms implementations @ONLINE, Dec 2013. URL <https://github.com/rpetryniak/My-CImg-Algorithms-Implementations>.

- [33] Shawn Lankton. Computer vision, science, business, and life @ONLINE, Dec 2013. URL <http://www.shawnlankton.com>.
- [34] D. Mumford and J. Shah. Optimal approximations by piecewise smooth functions and associated variational problems. *Comm. Pure Appl. Math.*, 42(5):577–685, jul 1989. doi: 10.1002/cpa.3160420503. URL <http://dx.doi.org/10.1002/cpa.3160420503>.
- [35] Karla Horsch, Maryellen L. Giger, Luz A. Venta, and Carl J. Vyborny. Automatic segmentation of breast lesions on ultrasound. *Medical Physics*, 28(8):1652–1659, 2001. doi: <http://dx.doi.org/10.1118/1.1386426>. URL <http://scitation.aip.org/content/aapm/journal/medphys/28/8/10.1118/1.1386426>.
- [36] Rangayyan R.M. *Biomedical Image Analysis*. Biomedical Engineering. Taylor & Francis, 2004. ISBN 9780203492543. URL http://books.google.es/books?id=o_8jEGNpEuwC.
- [37] M. A. Duarte, A.V. Alvarenga, C.M. Azevedo, A. F C Infantosi, and W. C A Pereira. Automatic microcalcifications segmentation procedure based on otsu's method and morphological filters. pages 102–106, 2011. doi: 10.1109/PAHCE.2011.5871858.
- [38] Antonio Fernando Catelli Infantosi, L.M.S. Luz, W.C.A. Pereira, and A.V. Alvarenga. Breast ultrasound segmentation using morphologic operators and a gaussian function constraint. 20:520–523, 2008. doi: 10.1007/978-3-540-69367-3_139. URL http://dx.doi.org/10.1007/978-3-540-69367-3_139.
- [39] Wagner Coelho A. Pereira, André V. Alvarenga, Antonio Fernando C. Infantosi, Leonardo Macrini, and Carlos E. Pedreira. A non-linear morphometric feature selection approach for breast tumor contour from ultrasonic images. *Comput. Biol. Med.*, 40(11-12):912–918, nov 2010. ISSN 0010-4825. doi: 10.1016/j.compbiomed.2010.10.003. URL <http://dx.doi.org/10.1016/j.compbiomed.2010.10.003>.

- [40] Xu Liu, Zhimin Huo, and Jiwu Zhang. Automated segmentation of breast lesions in ultrasound images. pages 7433–7435, 2005. doi: 10.1109/IEMBS.2005.1616230.
- [41] Sangyun Park, Hyoun-Joong Kong, Woo Kyoung Moon, and Hee Chan Kim. Segmentation of solid nodules in ultrasonographic breast image based on wavelet transform. pages 5649–5652, 2007. ISSN 1557-170X. doi: 10.1109/IEMBS.2007.4353628.
- [42] Luan Jiang, Enmin Song, Xiangyang Xu, Guangzhi Ma, and Bin Zheng. Automated detection of breast mass spiculation levels and evaluation of scheme performance. *Academic Radiology*, 15:1534–1544, 2008. doi: 10.1016/j.acra.2008.07.015.
- [43] Raquel Pardal. Despiste de lesões mamárias benignas vs. malignas: Estudo comparativo entre a mamografia, ultrassonografia modo-b, elastossonografia e resultado histológico. 2012.
- [44] Rute Jesus. O estado da arte da mamografia, aplicação ao âmbito técnico. 2009.