



UNIVERSIDADE DA BEIRA INTERIOR  
Engenharia

## **Segmentação de Imagens Torácicas de Raio-X**

**Ricardo Filipe Pereira Seco Oliveira Graça**

Dissertação para obtenção do Grau de Mestre em  
**Engenharia Informática**  
(2º ciclo de estudos)

Orientador: Prof. Doutor Hugo Pedro Proença

**Covilhã, Outubro de 2012**



## Agradecimentos

Esta dissertação é o resultado de um ano de intenso trabalho. Tendo sido uma maratona e não uma corrida ao sprint, a ajuda, o apoio, as palavras de encorajamento de muitas pessoas serviram muitas vezes como uma barra energética que tornou possível a chegada à meta. A todas estas pessoas gostaria de expressar o meu mais sincero agradecimento.

As primeiras palavras são inteiramente dirigidas ao meu orientador o Prof. Doutor Hugo Proença, que ao longo de um ano me conseguiu orientar e aconselhar da melhor forma indicando-me o melhor caminho a percorrer para chegar à meta e com o qual se estabeleceu uma boa relação que espero que não termine, mas que possa continuar depois do fim desta etapa.

Um agradecimento especial ao Dr. José Manuel do Hospital Sousa Martins (Guarda), pelo conhecimento transmitido na fase inicial do estudo.

Não queria também perder a oportunidade de dirigir algumas palavras à empresa para a qual trabalho. A Collectivus pela pessoa do Sr. Nuno Ferreira e do Sr. António Pires sempre demonstrou total abertura e compreensão às saídas do trabalho de modo a poder resolver questões relacionadas com a dissertação, para além de mostrarem abertura e todo o apoio que precisasse de modo a levar esta maratona a bom porto.

Queria deixar igualmente o meu agradecimento a todos os meus amigos e colegas. Não querendo individualizar, mas dar uma palavra especial aos amigos de sempre, Mafalda Silva e ao futuro médico e grande amigo João Santos pelas palavras oportunas em dias em que força faltava.

Não podia deixar de agradecer à minha namorada Maria João, pelas palavras, mas principalmente por me aguentar em dias difíceis.

Por último mas não menos importante, uma palavra aos meus queridos pais. Foi uma fase difícil e desgastante não só para mim mas também para eles que me apoiaram em tudo.

Graças a todos eles a maratona foi concluída e a eles lhes devo muito deste feito.

A todos o meu mais sincero obrigado.



## Resumo

A segmentação é uma das etapas que constituem o processamento de uma imagem. Consiste na divisão da imagem em componentes independentes. Essa informação é usada em etapas posteriores, de forma a obter-se conhecimento.

Trata-se de um conceito utilizado em imagens médicas no qual irá incidir este estudo. Esta aplicação em imagens médicas torna-se um desafio devido a vários factores, como a falta de uniformidade das imagens ou à presença de elevado ruído, só para citar alguns dos obstáculos existentes.

Devido a esta falta de uniformidade que é característica das imagens médicas, torna-se difícil a construção de um método *standard* que se possa ajustar a uma grande diversidade de imagens.

Este estudo pretende analisar três métodos de segmentação, aplicando-os a imagens torácicas de raio-x. Os três métodos são: o método de contornos activos segundo Chan e Vese, o método de contornos activos híbrido segundo Shawn Lankton e o método igualmente de contornos activos baseado em regiões segundo o mesmo autor. Esta análise é efectuada através da aplicação de 10 máscaras que servem como contornos iniciais em cada um dos três métodos.

Observa-se o comportamento de cada um dos métodos no conjunto de dados analisado, com a aplicação de pré-processamento e sem aplicação de pré-processamento nas imagens, de modo a ser possível concluir qual ou quais os que apresentam melhor e pior comportamento.

Uma segunda finalidade do estudo é a proposta de um modelo por parte do autor. Modelo este que se pretende que obtenha melhores resultados em termos de um menor erro de segmentação da região de interesse, em relação aos três métodos base.

Este modelo proposto mostra obter melhores resultados após a conjugação de observações de cada método em relação aos resultados de cada método de uma forma isolada.

## Palavras-chave

Contornos Activos, Segmentação, Regiões, Chan Vese, Shawn Lankton



## Abstract

Segmentation is one of the steps that constitute the processing of an image. It is the division of the image into independent components. This information is then used in later stages where it will be in order to obtain knowledge. This information is the used in later stages where it will be in order to obtain knowledge.

It is a concept used in medical imaging in which this study will focus. This application in medical imaging becomes a challenge due to several factors such as the lack of uniformity of the images or to the presence of high noise, just to name some of the obstacles.

Due to this lack of uniformity that is characteristic of medical images, it becomes difficult to construct a standard method one can fit a wide range of images.

This study aims to analyze three segmentation methods by applying them to images of ches-x ray. The three methods are: the active contour method of chan and Vese, the hybrid active contour method by Shawn Lankton and the method based on active contours regions by the same author. This analysis is performed by applying ten masks that serve as starting contours in each of the three methods.

Observe the behaviour of each method in data set analyzed by applying preprrocessing and without preprocessing application in the images, so that it is possible to conclude which of best to worst behaviour.

A second purpose of the study is to propose a model by the author. In this model that is intended to obtain better results in terms of lower error segmentation of the region of interest in relation of the three base methods.

This proposed model shows better results after combining observations of each method in relation to the results of each method in isolation.

## Keywords

Active Contours, Segmentation, Regions, Chan Vese, Shawn Lanwkton



# Índice

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Enquadramento do Tema . . . . .	1
1.2	Objectivos da Dissertação . . . . .	1
1.2.1	Objectivos Gerais . . . . .	2
1.3	Motivação . . . . .	2
1.4	Estrutura da Dissertação . . . . .	2
<b>2</b>	<b>Estado da Arte</b>	<b>5</b>
2.1	Segmentação de Imagens . . . . .	5
2.2	Importância da Segmentação . . . . .	6
2.3	Aplicações da Segmentação . . . . .	7
2.4	Dificuldades na Segmentação . . . . .	7
2.5	Pré-processamento . . . . .	8
2.6	Etapas do Processamento de uma Imagem . . . . .	9
2.7	Técnicas de Segmentação . . . . .	9
2.7.1	Segmentação baseada em Limiares . . . . .	10
2.7.2	Segmentação baseada na detecção de arestas . . . . .	12
2.7.3	Avaliação de Performance do Detector de Arestas . . . . .	18
2.7.4	Segmentação Baseada em Regiões . . . . .	19
2.7.5	Segmentação baseada no método <i>Watershed</i> . . . . .	24
2.7.6	Segmentação baseada em Contornos Activos . . . . .	28
2.7.7	Segmentação com Métodos Baseados em <i>Clusters</i> . . . . .	31
2.8	Segmentação de Imagem Médica . . . . .	34
2.8.1	Dificuldades na segmentação de imagens médicas . . . . .	34
2.8.2	Critérios de classificação dos métodos . . . . .	35
2.8.3	Métodos de segmentação de imagem médica . . . . .	35
<b>3</b>	<b>Caso de Estudo</b>	<b>39</b>
3.1	Métodos Base . . . . .	39
3.1.1	Método de Contornos Activos Híbrido segundo Shawn Lankton . . . . .	39
3.1.2	Método de Contornos Activos segundo Chan e Vese . . . . .	42
3.1.3	Método de Contornos Activos baseado em Regiões segundo Shawn Lankton . . . . .	43
3.2	Conjunto de Dados . . . . .	45
3.2.1	Propriedades do Conjunto . . . . .	46
3.2.2	Limitações do Conjunto de Dados . . . . .	46
3.2.3	Estatísticas do Conjunto de Dados . . . . .	46
3.3	Contorno Inicial . . . . .	47
3.4	Modelo Proposto . . . . .	48
3.4.1	Construção do Modelo . . . . .	51
3.5	Estatísticas de Precisão . . . . .	53
3.6	Pré-Processamento . . . . .	55

<b>4</b>	<b>Resultados e Discussão</b>	<b>59</b>
4.1	Resultados da Precisão dos Métodos Base . . . . .	59
4.2	Resultados das Árvores de Decisão . . . . .	64
4.2.1	Resultados dos Métodos Base . . . . .	64
4.2.2	Resultados do Método Proposto . . . . .	64
<b>5</b>	<b>Conclusão</b>	<b>69</b>
5.1	Conclusões . . . . .	69
5.2	Trabalho Futuro . . . . .	70

## Lista de Figuras

1.1	Estrutura da dissertação. . . . .	3
2.1	Conceito de segmentação . . . . .	6
2.2	Segmentação de regiões da floresta tropical da Amazónia . . . . .	6
2.3	Possível aplicação da segmentação no trânsito . . . . .	7
2.4	Exemplo da aplicação de pré-processamento . . . . .	8
2.5	Etapas que constituem o processamento de uma imagem . . . . .	9
2.6	Identificação do valor do limiar . . . . .	10
2.7	Conceito de segmentação segundo o limiar . . . . .	11
2.8	Resultado da segmentação usando a limiarização simples . . . . .	11
2.9	Segmentação segundo o conceito da limiarização local. . . . .	12
2.10	Segmentação segundo o conceito de detecção de arestas . . . . .	12
2.11	Definição de aresta em termos gráficos . . . . .	13
2.12	Tipos de arestas existentes . . . . .	14
2.13	Detecção de arestas através da primeira derivada. . . . .	14
2.14	Detecção de arestas através da segunda derivada. . . . .	15
2.15	Aplicação do operador Sobel . . . . .	15
2.16	Aplicação do operador Roberts . . . . .	16
2.17	Aplicação do operador de Prewitt . . . . .	17
2.18	Aplicação do detector de arestas LoG . . . . .	17
2.19	Aplicação do operador de aresta Canny . . . . .	18
2.20	Conceito do método de segmentação baseado em regiões . . . . .	19
2.21	Método de crescimento de regiões partindo da semente . . . . .	20
2.22	Conceito do valor escalar associado ao crescimento de regiões . . . . .	21
2.23	Conceito do desvio padrão associado ao crescimento de regiões . . . . .	21
2.24	Segmentação segundo o conceito de divisão e fusão de regiões . . . . .	23
2.25	Conceito <i>quadtree</i> na divisão e fusão de regiões . . . . .	23
2.26	Segmentação de regiões segundo a abordagem <i>watershed</i> . . . . .	25
2.27	Segmentação <i>watershed</i> segundo o conceito de inundação . . . . .	27
2.28	Segmentação <i>watershed</i> segundo o conceito de marcadores . . . . .	28
2.29	Efeitos do marcador no gradiente . . . . .	28
2.30	Segmentação segundo o conceito de contornos activos . . . . .	29
2.31	Sistemas inteligentes de imagem médica . . . . .	34
3.1	Imagem resultado de ressonância magnética, segmentada por diferentes métodos . . . . .	39
3.2	Regiões locais analisadas . . . . .	41
3.3	Evolução da segmentação de uma imagem do conjunto de dados utilizando a abordagem híbrida segundo Shawn Lankton . . . . .	42
3.4	Diferença entre o método Chan Vese e um método mais clássico. . . . .	42
3.5	Evolução da segmentação de uma imagem do conjunto de dados utilizando a abordagem de Chan e Vese . . . . .	43
3.6	Análise das regiões locais em cada ponto da curva . . . . .	44
3.7	Evolução da segmentação de uma imagem do conjunto de dados utilizando a abordagem de contornos activos baseados em regiões segundo Shawn Lankton . . . . .	45

3.8	Exemplos de imagens do conjunto de dados . . . . .	45
3.9	Limitações do conjunto de dados . . . . .	46
3.10	Dados estatísticos do conjunto de dados . . . . .	47
3.11	Máscaras construídas que servem como contorno inicial dos métodos base . . . . .	48
3.12	Separação dos pulmões das imagens . . . . .	49
3.13	Eficiência da segmentação dos pulmões . . . . .	49
3.14	Divisão dos pulmões. . . . .	50
3.15	Critério subjectivo de classificação de um pulmão como sendo bem segmentado. . . . .	51
3.16	Critério subjectivo de indicação de um pulmão como sendo mal segmentado. . . . .	51
3.17	Exemplo de uma árvore de decisão utilizada na avaliação de cada método . . . . .	52
3.18	Extracção dos valores de precisão utilizando cada uma das 10 máscaras por parte de cada método base . . . . .	54
3.19	Aplicação de pré-processamento . . . . .	56
3.20	Aplicação de pré-processamento . . . . .	56
3.21	Aplicação de pré-processamento . . . . .	56
4.1	Resultados da abordagem híbrida segundo Shawn Lankton com e sem pré-processamento . . . . .	59
4.2	Resultados da abordagem segundo Chan e Vese com e sem pré-processamento . . . . .	60
4.3	Resultados da abordagem baseada em regiões segundo Shawn Lankton com e sem pré-processamento . . . . .	61
4.4	Resultados da abordagem híbrida e baseada em regiões segundo Shawn Lankton sem pré-processamento. . . . .	61
4.5	Resultados da abordagem híbrida e baseada em regiões com pré-processamento . . . . .	62
4.6	Resultados dos três métodos base sem pré-processamento . . . . .	63
4.7	Resultados dos três métodos base com pré-processamento . . . . .	63
4.8	Resultados de correlação dos métodos em relação ao pulmão direito. . . . .	65
4.9	Resultados de correlação dos métodos em relação ao pulmão esquerdo. . . . .	65
4.10	Resultados do modelo proposto em relação ao pulmão esquerdo. . . . .	66
4.11	Resultados do modelo proposto em relação ao pulmão direito. . . . .	67
4.12	Resultados do modelo proposto em relação aos dois pulmões. . . . .	68

## Lista de Tabelas

3.1	Propriedades das imagens. . . . .	46
3.2	Coordenadas dos pontos utilizados na construção de cada uma das máscaras. . .	48
3.3	Obtenção dos valores que constituem o modelo proposto. . . . .	53
4.1	Fiabilidade de segmentação de cada método base em relação ao pulmão esquerdo.	64
4.2	Fiabilidade de segmentação de cada método base em relação ao pulmão direito.	64



## Lista de Acrónimos e Abreviaturas

ANN	<i>Artificial Neural Network</i>
CV	<i>Chan-Vese</i>
FCM	<i>Fuzzy C-means</i>
FKM	<i>Fuzzy K-means</i>
LoG	<i>Laplacian of Gaussian</i>
RGB	<i>Red-Green-Blue</i>
ROI	<i>Region of Interest</i>
SH	<i>Shawn Hybrid</i>
SM	<i>Split and Merge</i>
SRB	<i>Shawn Region Based</i>
TN	<i>True Negative</i>



# Capítulo 1

## Introdução

Neste capítulo pretende-se fazer uma apresentação do tema objecto deste trabalho, isto é, efectuar uma pequena abordagem à temática que será abordada mais aprofundamente à frente neste estudo. Para além de uma pequena apresentação do tema, este capítulo servirá também para enunciar quais os objectivos que se pretende atingir no final. Esses mesmos objectivos encontram-se descritos na secção relativa aos objectivos gerais. Será também referida a motivação, o porquê do estudo deste tema na dissertação. É igualmente abordada a forma como este relatório se encontra estruturado.

### 1.1 Enquadramento do Tema

A utilização de sistemas de inteligência artificial na análise da imagem médica é encarada como um precioso instrumento auxiliar por parte dos médicos sendo utilizada nas mais variadas áreas da medicina. Tendo como exemplo o campo das imagens torácicas de raio-x, trata-se de um campo onde a análise das imagens por parte dos especialistas se torna demasiado subjectiva.

Questões acerca de determinadas anormalidades presentes nas imagens é usual que ocorram na cabeça dos médicos sendo desta forma necessário um sistema que indique a probabilidade dessa anormalidade ser ou não perigosa, sendo esta uma simples indicação capaz de fornecer uma outra perspectiva acerca dessa questão e um procedimento eficaz que possa ser aplicado. É neste ponto que entra então a segmentação, como sendo um processo da divisão e extracção de dados da imagem de modo a facilitar posteriormente a sua análise. A segmentação só por si não ajuda os peritos a tomar uma melhor ou pior escolha, a segmentação torna possível a extracção de informação importante da imagem, de modo a que essa imagem possa ser convenientemente analisada e classificada. Sendo analisada e classificada torna-se posteriormente possível a construção de um sistema inteligente, que partindo de um conjunto de imagens possa apreender conhecimento, através da definição de padrões, tornando-se assim possível que esse sistema possa autónomamente determinar com certo grau de confiança se uma dada anormalidade de uma imagem pode ou não ser problemática, dando indicação ao especialista de um possível caminho a seguir.

### 1.2 Objectivos da Dissertação

O objectivo deste trabalho consiste no desenvolvimento de um algoritmo de segmentação supervisionada por imagens torácicas de raio-x. Tal algoritmo deverá receber como entrada os resultados obtidos por três algoritmos de segmentação amplamente conhecidos e utilizados no domínio da visão computacional. De seguida, utilizando técnicas de aprendizagem automática, o algoritmo deverá ser capaz de extrair informação relevante de cada instância e, com base nesta, decidir qual o algoritmo de segmentação potencialmente mais apropriado.

Pretende-se comparar a eficiência deste algoritmo com a dos três métodos base de segmentação.

### 1.2.1 Objectivos Gerais

Esta dissertação tem como objectivo geral analisar e comparar métodos de segmentação de imagem que possam ser aplicados à região torácica. Comparação essa que será baseada nos resultados de segmentação desses métodos e que serão analisados de duas formas distintas.

A primeira corresponde à análise de taxas de precisão de cada método, comparando o comportamento de cada um, de modo a ser possível extrair uma conclusão acerca de qual apresenta um melhor comportamento.

Numa segunda abordagem, através de árvores de decisão, de modo a concluir-se qual o método que mais vezes se aproxima da segmentação desejada, com base nas características das imagens. Partindo desta informação pretende-se, a construção de um modelo alicerçado nos métodos base que consiga obter melhores resultados.

Em suma pretende-se obter um modelo, que seja capaz de extrair o melhor do conjunto dos três métodos.

### 1.3 Motivação

A motivação para a realização deste estudo resulta da junção de diversos factores. O primeiro desses factores diz respeito ao interesse pessoal na área da manipulação de imagem, interesse esse que nasceu no âmbito de projectos realizados anteriormente na licenciatura.

Um outro factor, era o facto do autor pretender um projecto que pudesse originar resultados que pudessem ainda que minimamente resultar numa evolução na área da segmentação. Por último, mas não menos importante, trata-se da contribuição que o método proposto pelo autor poderá acrescentar à medicina em termos do campo da segmentação de pulmões e consequentemente em sistemas inteligentes mais precisos e confiáveis.

### 1.4 Estrutura da Dissertação

Esta dissertação encontra-se dividida em 5 capítulos sendo a sua estrutura ilustrada através da figura 1.1.

**Capítulo 1. Introdução** - Neste capítulo faz-se uma primeira abordagem ao tema em questão. Introdução esta que é composta pelo enquadramento do tema, sendo referido o campo que será alvo de estudo nesta dissertação. São igualmente enumerados os factores que constituíram a motivação que permitiu este estudo. Para além disto, são igualmente enumerados os objectivos que se pretende atingir no final.

**Capítulo 2. Estado da Arte** - Neste capítulo é efectuada uma revisão da literatura acerca do tema. Inicialmente é introduzido o tema da segmentação de imagem, onde é referido o conceito e possíveis aplicações. Posteriormente é efectuada uma enumeração dos métodos identificados ao longo da análise da literatura acerca do tema em questão bem como a identificação das vantagens e desvantagens de cada um deles.

**Capítulo 3. Caso de Estudo** - No capítulo três descrevem-se os três métodos em estudo no que ao seu funcionamento diz respeito bem como as suas características, vantagens e desvantagens. Para além disso, é são descritos os passos que permitem a extracção de resultados

## Segmentação de Imagens Torácicas de Raio-X

e das respectivas conclusões acerca dos mesmos, bem como a construção do modelo proposto. Será também descrito o conjunto de dados utilizado, ao qual são aplicados os respectivos métodos em estudo.

**Capítulo 4. Resultados e Discussão** - Este capítulo é dedicado à análise dos resultados obtidos no capítulo anterior. Com base nestes dados e na sua análise são extraídas conclusões acerca dos métodos que apresentam melhor desempenho, sendo igualmente analisados os resultados do modelo proposto pelo autor.

**Capítulo 5. Conclusões e Trabalho Futuro** - Por fim, neste último capítulo serão enunciadas as conclusões a extrair deste estudo, bem como as limitações inerentes ao mesmo e a trabalho futuro passível de ser realizado.

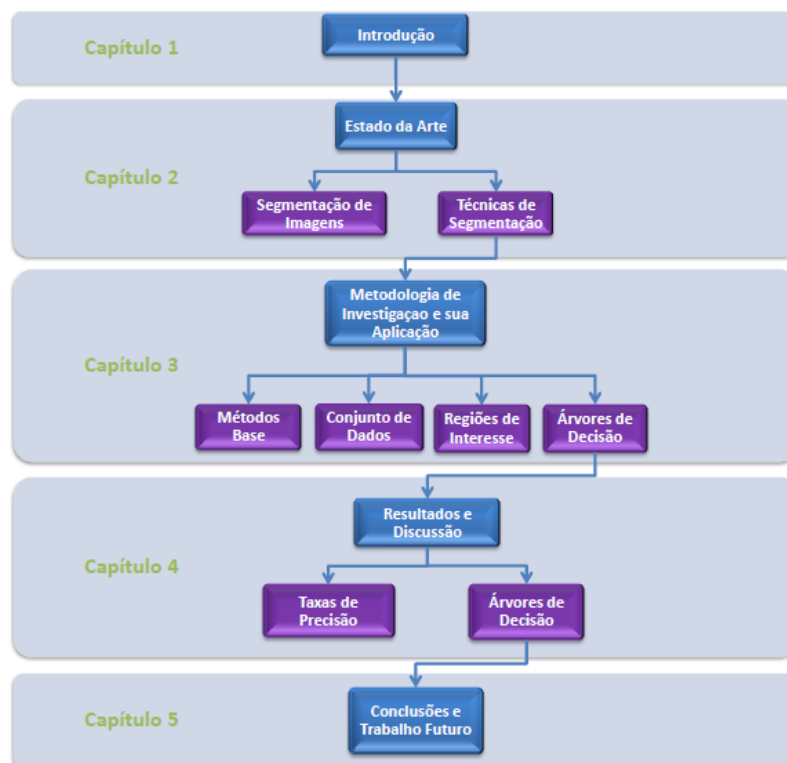


Figura 1.1: Estrutura da dissertação.



# Capítulo 2

## Estado da Arte

### 2.1 Segmentação de Imagens

Para se iniciar o estudo sobre a segmentação de imagens torácicas de raio-x é importante ter uma noção do que se trata e para que serve, o que será feito através de uma análise bibliográfica do tema.

Uma imagem pode não ser vista apenas como um único e só objecto. Pode conter um conjunto de objectos independentes uns dos outros, sendo que da sua união irá resultar a própria imagem.

Segmentar pode então ser visto como uma fragmentação da imagem em regiões, que não são mais do que os objectos anteriormente referidos que compõem a imagem [58]. Em suma com a segmentação pretende-se um conjunto de regiões onde em cada uma delas o conteúdo é similar [55].

Em notação matemática pode-se descrever o que é a segmentação da seguinte forma: se  $I$  é o conjunto de todos os píxeis da imagem, então através da segmentação obtemos diferentes e únicas regiões  $\{S_1, S_2, S_3, \dots, S_n\}$  que quando combinadas formam  $I$  [47].

- a)  $\bigcup_{i=1}^n S_i = I$  onde  $S_i \cap S_j = \emptyset$ ;
- b)  $S_i$  é uma região interligada,  $i = 1, 2, \dots, n$ ;
- c)  $P(S_i) = VERDADEIRO$  para  $i = 1, 2, \dots, n$ ;
- d)  $P(S_i \cup S_j) = FALSO$  para  $i \neq j$ ;

Assim a segmentação de imagens não é mais do que a partição de uma imagem num conjunto de regiões disjuntas que são visualmente diferentes entre si [58]. Cada uma dessas regiões deve ser homogênea tendo em conta uma dada característica discriminativa que faça dessa região alvo único na imagem.

De referir que a eficácia deste processo é muito importante para o sucesso das etapas seguintes mais especificamente a análise e classificação da imagem. Caso o resultado da segmentação seja fraco, o restante processo resultará igualmente em resultados aquém dos pretendidos. No caso do objecto de estudo, a segmentação torna-se deveras importante, porque a identificação das fronteiras dos pulmões nas radiografias do tórax é um passo necessário para a detecção de possíveis anormalidades como é o caso dos nódulos pulmonares [16] para citar um exemplo. Em suma se a segmentação for fraca todo o processo ficará irremediavelmente comprometido em termos de precisão e confiança dos resultados.



Figura 2.1: Conceito de segmentação: a) Imagem original b) Imagem segmentada, com cada região bem definida e identificada.

(<http://spie.org/x8899.xml?pf=true&ArticleID=x8899>)

## 2.2 Importância da Segmentação

É de referir que a segmentação pode ter várias utilidades, entre as quais se encontram: a extracção de informação, o realce dos detalhes, efectuação de medições, bem como a efectuação de comparações entre outras. A segmentação torna-se importante na medida em que muitas vezes se pretende estudar apenas um determinado objecto, não sendo necessário para tal a imagem na sua globalidade. Assim o que a segmentação permite é uma extração da informação do objecto que se pretende estudar. Isto permite reduzir a complexidade envolvida e consequentemente o processamento necessário, em termos temporais e espaciais, visto que a análise irá incidir naquele objecto específico e não na totalidade da imagem.

Pode-se portanto concluir que a segmentação de imagens é uma tarefa com uma importância fundamental na análise da imagem digital. Como exemplo podemos ver a figura 2.2 que diz respeito à segmentação de zonas da floresta tropical da Amazónia.




Figura 2.2: Segmentação de regiões da floresta tropical da Amazónia.  
(<http://www.members.tripod.com/GerardoKuntschik/Papers/Merida.pdf>)

Neste caso específico pode-se através da segmentação analisar o estado da evolução em termos da desflorestação da floresta amazónica, fornecendo dados aos especialistas acerca da velocidade dessa desflorestação de ano para ano.

## 2.3 Aplicações da Segmentação

Nos dias de hoje a segmentação de imagens tem aplicação em diversos sectores da nossa sociedade. é aplicada em termos de imagens médicas, na localização de tumores e outras patologias, medição de volumes de tecido, cirurgia guiada por computador, diagnóstico, planeamento do tratamento e estudo da estrutura anatómica. Mas não só em termos de imagens médicas se pode vislumbrar aplicações possíveis para a segmentação. A segmentação pode ser igualmente aplicada na monitorização do tráfego existente nas estradas, quer em termos da densidade de tráfego bem como de possíveis excessos de velocidade.

Mediante utilização de câmeras colocadas ao longo das estradas, pode ser possível seguir o trajecto de carros de uma forma automática, possibilitando aos serviços de emergência obter uma indicação mais rápida de possíveis engarrafamentos ou indicação de probabilidade da existência de acidente tendo em conta as diversas velocidades podendo-se colocar sinalização de aviso nos painéis electrónicos ao longo da via. A velocidade de um dado veículo pode ser determinada registando a distância percorrida pelo veículo segmentado durante um determinado período de tempo conhecido [15] como é possível ver na figura 2.3.



Figura 2.3: Possível aplicação da segmentação no trânsito: Sendo possível determinar a velocidade a que segue determinado veículo [15].

Poderá ser igualmente aplicada na localização de objectos em imagens de satélite (estradas, florestas, entre outros), reconhecimento facial, reconhecimento da íris, reconhecimento de impressão digital, bem como em imagens agrícolas no que à detecção de possíveis problemas das culturas diz respeito. Conclui-se portanto que a segmentação é muito mais utilizada do que aquilo que se poderá supor.

## 2.4 Dificuldades na Segmentação

Nos anos mais recentes assistiu-se a um aumento exponencial do número de dispositivos digitais, como por exemplo os *smartphones* com alta qualidade de captação de imagem, aumento este que aumentou a importância do processamento multimédia.

Em termos gerais, quanto maior for a qualidade das imagens mais precisa e rigorosa será a sua segmentação e conseqüentemente a sua posterior análise. Algoritmos de segmentação de imagem quando aplicados por diferentes utilizadores em múltiplas aplicações diferentes não garantem uma alta qualidade de resultados [54], ou seja, quando aplicados a imagens diferentes, provenientes de fontes diferentes com igualmente diferentes capacidades processamento, os

algoritmos de segmentação perdem precisão e qualidade, sendo este um dos problemas, o da adaptação dos algoritmos a diversos tipos de imagem, de modo a que um método seja o mais uniforme possível. Em suma torna-se difícil a uniformização dos métodos de segmentação. Outro dos problemas existentes neste campo da segmentação trata-se do facto deste crescimento exponencial de fotos e da importância que as pessoas hoje lhes dão, necessitar de um maior tempo consumido, isto é, com um maior número de imagens torna-se pouco recomendável aplicar o algoritmo imagem a imagem, o que irá aumentar de uma forma não menos exponencial o tempo consumido bem como igualmente os recursos necessários. Outra das dificuldades associadas à segmentação advém da forma como as imagens são captadas. Se estivermos a falar em imagens captadas através da câmara dos telemóveis a segmentação poderá tornar-se um pouco mais complicada devido aos recursos computacionais limitados, o que pode originar imagens com pouca precisão e conseqüentemente com muito ruído associado provocando *over-segmentation* ou *under-segmentation*, existindo ainda alguma margem para a segmentação poder evoluir principalmente nestes casos de imagens de fraca qualidade.

Em suma conclui-se que o resultado da análise e classificação efectuada das imagens será tanto melhor quanto melhor for a qualidade da imagem captada.

### 2.5 Pré-processamento

Uma das formas de minimizar os problemas da segmentação relativos à qualidade da imagem é através da aplicação de técnicas de pré-processamento.

Antes da aplicação de qualquer técnica de segmentação de imagem é normalmente necessário efectuar um pré-processamento da mesma. O pré-processamento consiste num conjunto de operações, que não são mais do que, um tratamento preliminar dos dados, com a finalidade de calibrar a radiometria da imagem, corrigir as suas distorções no sentido de eliminar erros em termos de distorções geométricas e de ruído, realce do contraste e demarcação das regiões de interesse, no sentido de facilitar o processo de segmentação.

O pré-processamento é efectuado através da aplicação de diversos filtros às imagens.




Figura 2.4: Exemplo da aplicação de pré-processamento: a) Imagem original sem aplicação de qualquer técnica de pré-processamento e carregada de ruído b) A mesma imagem após a aplicação de um filtro de pré-processamento que permite a remoção do ruído [13].

Em suma partindo do exemplo da figura 2.4 é possível verificar as diferenças que existem entre a imagem original e a imagem após a aplicação do pré-processamento, sendo uma preciosa ajuda para uma melhor segmentação.

## 2.6 Etapas do Processamento de uma Imagem

**Aquisição da Imagem** - É nesta fase que se adquire a imagem, o que pode ser efectuado através de uma câmara fotográfica ou câmara de filmar ou em termos médicos através de uma máquina de ressonância magnética por exemplo. Dependendo do método de obtenção, a qualidade de cada imagem irá variar, tal como a sua posterior segmentação.

**Pré-processamento** - Após a aquisição, é normal que exista informação desnecessária, ou componentes de ruído, sendo necessário eliminar essa informação. A eliminação é normalmente efectuada através de filtros. A importância desta etapa reside no facto de estar na base do processo e se não for tratada convenientemente os resultados obtidos em fases subsequentes podem não ser os melhores. Esta etapa permite então aumentar as hipóteses de sucesso das etapas posteriores.

**Segmentação** - A segmentação permite receber uma imagem previamente pré-processada ou não, e separar os objectos presentes nessa imagem em regiões diferentes de forma a que mais tarde seja possível a análise dessas regiões separadamente e de uma forma independente.

**Análise** - Após a segmentação é possível definir uma região de interesse que será analisada numa fase posterior, normalmente através de processos de codificação e descrição. Em termos práticos efectua-se uma extracção de características que resultam em informação de interesse.

**Classificação** - Nesta etapa são utilizadas as características extraídas na etapa anterior, de modo a que seja possível extrair padrões e inferir conhecimento. Torna-se assim possível a construção de um sistema autónomo que através desses padrões infere conhecimento à medida que efectuará a segmentação de um cada vez maior número de imagens.



Figura 2.5: Etapas que constituem o processamento de uma imagem.

## 2.7 Técnicas de Segmentação

Diversos algoritmos e técnicas têm sido desenvolvidos para a segmentação de imagens.

Todas as técnicas combinadas com conhecimento no domínio podem ser aplicadas num problema específico. Os algoritmos de segmentação permitem identificar diferenças existentes entre os objectos da imagem. Esta distinção permitirá ao programa interpretar píxeis contíguos e agrupá-los em regiões.

Os algoritmos de segmentação de imagens monocromáticas são geralmente baseados numa de duas propriedades básicas respeitantes aos valores de níveis de cinza: a descontinuidade e a similaridade [58].

Na descontinuidade, a partição da imagem é efectuada com base em alterações bruscas de intensidade (ex. detecção de contornos). Já na similaridade a partição é efectuada com base na semelhança entre píxeis, seguindo um determinado critério (ex. binarização, crescimento de regiões, divisão e junção de regiões entre outras técnicas) [58].

### 2.7.1 Segmentação baseada em Limiares

As técnicas baseadas no limiar são normalmente usadas para imagens em tons de cinzento.

é uma das técnicas mais populares e é muito simples de implementar, no entanto são necessárias técnicas e ferramentas adicionais caso se pretenda implementar o método em imagens de cor [47].

A segmentação de imagem baseada na limiarização tem como objectivo a partição da imagem original em píxeis de dois ou mais valores, através da comparação dos valores dos píxeis com o valor predefinido do limiar que é  $T$  [58]. O valor do limiar é normalmente determinado através de um histograma de intensidades da imagem. Dado o número de píxeis de uma imagem ser geralmente muito elevado, pode-se considerar o histograma como uma boa aproximação à densidade de probabilidade da propriedade que ele representa.

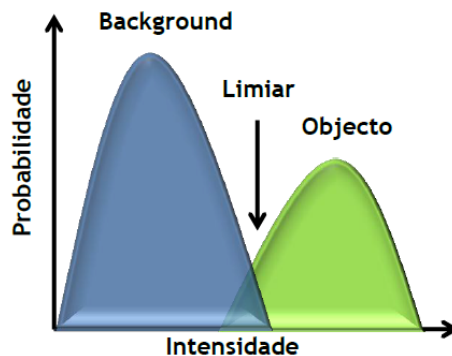


Figura 2.6: Identificação do valor do limiar.

Em suma, como se pode constatar através da figura 2.6, para uma imagem em escala de cinzentos, assume-se que essa mesma imagem se encontra dividida em duas partes designadas de *background* e *foreground*. O *foreground* define-se como contendo os objectos de interesse, enquanto o *background* é o restante. O valor do limiar é determinado através da análise da intensidade de todos os píxeis da imagem sendo que o limiar é o valor que separa o *background* e os objectos no que à intensidade diz respeito. Qualquer pixel  $(x,y)$  para o qual  $f(x,y) \geq T$  é designado de ponto objecto, caso contrário, o mesmo pixel é designado de ponto *background* [47]. Assim,

$$I(x,y) = \begin{cases} 0, & p(x,y) < T \\ 1, & p(x,y) \geq T \end{cases} \quad (2.1)$$




Figura 2.7: Conceito de segmentação segundo o limiar.  
([http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1415-43662003000200030](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662003000200030))

No entanto a aplicação da limiarização simples também designada de limiarização global, nem sempre é possível devido a inconvenientes como por exemplo a existência de objectos com diferentes níveis de cinzento, a existência de variações na escala de cinzentos no *background* ou a presença de ruído na imagem, o que torna difícil determinar o valor do limiar [12], sendo o resultado final pouco preciso, não condizendo com a realidade




Figura 2.8: Resultado da segmentação usando a limiarização simples: a) Imagem em escala de cinzentos  
b) Imagem após a segmentação utilizando a limiarização global.  
<http://eof.alunos.dcc.fc.up.pt/wiki/index.php/Thresholding>

No entanto existe forma de aumentar a eficiência deste método, através da técnica de limiarização local.

### 2.7.1.1 Limiarização Local

É uma variante da limiarização simples. Permite aplicar o método do limiar em partes separadas da imagem em vez de aplicar à imagem completa aumentando normalmente a eficiência. Na figura 2.9 pode-se ver um exemplo da aplicação do limiar local, onde a imagem é dividida em quatro. Posteriormente são determinados os quatro valores do limiar de cada uma dessas sub-imagens. Como se pode constatar o resultado é muito mais eficiente do que utilizando um valor único de limiar para a imagem no seu todo.

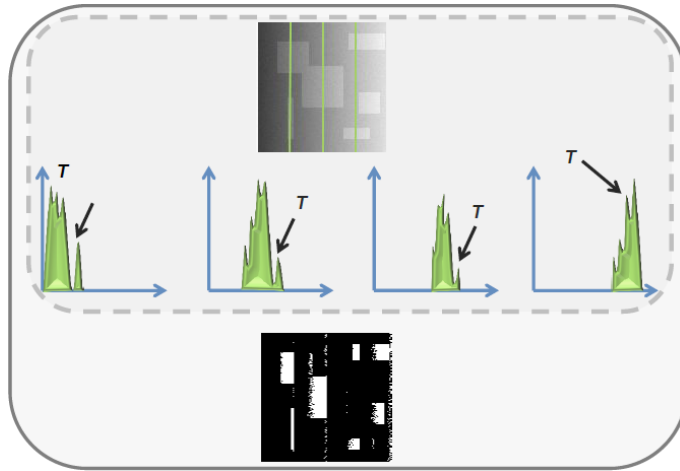


Figura 2.9: Segmentação segundo o conceito da limiarização local.

### 2.7.2 Segmentação baseada na detecção de arestas

A detecção de arestas é fundamental para a segmentação e consequentemente para a visão computacional, uma vez que as fronteiras são essenciais para segmentar as regiões [12]. A detecção de arestas é a abordagem mais comum para a detecção de descontinuidades significativas nos níveis de cinza. O processo de detecção de arestas permite uma simplificação da análise da imagem através da redução do conjunto de dados a serem processados, enquanto que simultaneamente permite a preservação de importante informação sobre as fronteiras do objecto [1]. A primeira e segunda derivadas bem como o gradiente e laplaciano são usados para a detecção de arestas numa imagem [47]. No entanto antes da descrição deste método é necessário saber em que consiste uma aresta.

Uma aresta consiste num conjunto de píxeis conectados entre si, que definem uma fronteira entre diferentes regiões, onde existe uma descontinuidade como a alteração do nível de cinza, cores distintas ou diferentes texturas. Uma imagem pode então ser segmentada através da detecção destas descontinuidades. Com base nesta teoria existem duas abordagens principais que são: métodos baseados no laplaciano e métodos baseados no gradiente [44].




Figura 2.10: Segmentação segundo o conceito de detecção de arestas: a) Imagem original b) Imagem resultante do conceito de segmentação baseado na detecção de arestas.  
(<http://mmlab.ie.cuhk.edu.hk/project.htm>)

## Segmentação de Imagens Torácicas de Raio-X

A figura 2.11 contém a definição de aresta em termos gráficos. Pode-se observar que os píxeis negros têm uma intensidade baixa, assim a curva do gráfico é baixa. Observa-se que o gráfico atinge altura máxima no final, indicando que a intensidade é máxima. Deve-se notar que no centro da curva existe uma inclinação íngreme, significando que estamos na presença de uma descontinuidade em termos de intensidade, existindo assim uma aresta.




Figura 2.11: Definição de aresta em termos gráficos.  
(<http://www.aishack.in/2011/04/the-sobel-and-laplacian-edge-detectors>)

### 2.7.2.1 Passos na Detecção de Arestas

O processo de detecção de arestas é normalmente constituído por três passos considerados essenciais que são: a filtragem da imagem, o seu aperfeiçoamento e a detecção propriamente dita [48][11].

#### Filtragem

As imagens encontram-se frequentemente deterioradas por diversos tipos de ruído [48][11]. A filtragem é então normalmente usada de modo a melhorar a performance de um detector de arestas no que diz respeito ao ruído. No entanto deve existir um certo nivelamento entre a força da aresta e o ruído, isto porque, quanto maior a filtragem aplicada para reduzir o ruído, maior a perda de força da aresta [11].

#### Aperfeiçoamento

De modo a facilitar a detecção de arestas, é essencial determinar alterações de intensidade na vizinhança dos pontos. Esta etapa permite enfatizar os píxeis onde existe uma alteração local significativa em termos de valores de intensidade e é normalmente efectuado através da magnitude do gradiente [11].

#### Detecção

Apenas são pretendidos pontos que constituam uma aresta forte. No entanto diversos pontos na imagem têm um valor diferente de zero em relação ao gradiente e nem todos os pontos são considerados arestas. Portanto, diversos métodos devem ser usados de modo a determinarem que pontos são pontos de aresta. Normalmente é a limiarização a fornecer os critérios usados para a detecção [11].

É importante salientar que o passo da detecção apenas indica que existe uma aresta próxima de um dado pixel da imagem, mas não fornece necessariamente uma estimativa precisa sobre a localização ou orientação da aresta [11]. Por esta razão alguns métodos pressupõem um quarto passo que é a localização, que permite uma estimativa acerca do local da aresta bem como da sua orientação [11].

Em termos de tipos de arestas, existem 4 tipos [48] [11], como se encontra ilustrado na figura 2.12

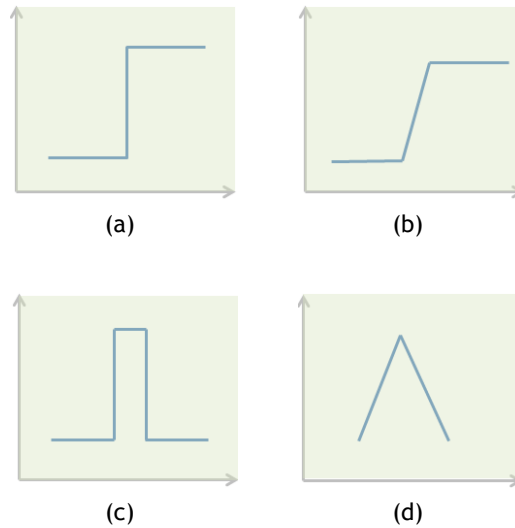


Figura 2.12: Tipos de arestas existentes: a) Aresta em degrau b) Aresta em rampa c) Aresta em linha d) Aresta em telhado.

Existem diversas formas de detectar arestas. No entanto a maioria dos métodos podem ser agrupados em duas categorias distintas: Gradiente e Laplaciano sendo ambas baseadas no conceito de convolução.

### 2.7.2.2 Método do Gradiente

Os detectores baseados no gradiente detectam as arestas através da identificação do máximo e do mínimo da primeira derivada da imagem [46] [11] como se verifica na figura 2.13. Os métodos baseados no gradiente normalmente funcionam bem, tendo como desvantagem o facto de serem muito sensíveis à noção de máximo local. Neste caso deve existir um limiar acima do qual um valor é classificado como aresta, ou em caso contrário classificado como ruído [56].




Figura 2.13: Detecção de arestas através da primeira derivada. (<http://www.aishack.in/2011/04/the-sobel-and-laplacian-edge-detectors>)

### 2.7.2.3 Método Laplaciano

Os detectores baseados no método laplaciano procuram pelo valor zero da segunda derivada da imagem para determinar arestas. Como se pode ver pela figura 2.14, no lado esquerdo onde a curva é ascendente a inclinação é positiva [46]. À direita, a inclinação é negativa, então conclui-se que deve existir um ponto onde há um cruzamento que passa no ponto zero, sendo esse ponto considerado como aresta. De referir que na segunda derivada quando a curva se encontra no valor zero a primeira derivada é um extremo como se verifica na figura 2.14 [56].




Figura 2.14: Detecção de arestas através da segunda derivada.  
(<http://www.aishack.in/2011/04/the-sobel-and-laplacian-edge-detectors>)

### 2.7.2.4 Técnicas de Detecção de Arestas

Existem diversos operadores de detecção de arestas disponíveis, cada um deles elaborado por forma a detectar determinado tipo de arestas, isto é, cada um dos operadores é direccionado para uma aresta em particular, tendo em conta as suas características. Existem diversas variáveis no que à selecção do método diz respeito, entre as quais a orientação da aresta, o ruído ambiente e a estrutura da aresta.

No que à orientação da aresta diz respeito os operadores podem ser optimizados para detectar arestas no sentido horizontal, vertical ou diagonal. Quanto ao ruído ambiente trata-se de uma característica que dificulta a detecção de arestas. Os operadores usados em imagens com ruído são geralmente operadores de maior alcance, de modo a poderem extrair os pixels ruidosos. Este processo irá resultar numa menor precisão no que à localização das arestas detectadas diz respeito. Outra característica que influencia a escolha do operador é a estrutura da aresta em causa. Nem todas as arestas envolvem uma mudança da intensidade. Efeitos como a refração ou um focus fraco podem resultar em objectos com arestas definidas através de uma mudança gradual de intensidade. Assim o operador necessita de ser escolhido de modo a dar resposta a essa mudança gradual que acontece nestes casos [48]. Existem os seguintes operadores:

#### Operador de Sobel

O detector sobel trata-se de um método baseado no gradiente e por conseguinte na primeira derivada. Em termos simples, este operador permite o cálculo do gradiente de intensidade em cada ponto da imagem sendo que o seu resultado mostra as variações de intensidade em cada ponto.



Figura 2.15: Aplicação do operador sobel: a) Imagem original b) Imagem após a aplicação do operador.  
(<http://jpegthis.blogspot.pt/2009/03/sobel-method-edge-detection.html>)

Permite o cálculo da primeira derivada da imagem para o eixo dos X's e dos Y's separadamente. As respectivas derivadas são apenas aproximações visto que as imagens não são contínuas [56]. Este operador utiliza duas matrizes 3x3 na convolução da imagem original, uma matriz para o gradiente horizontal e outra para o vertical. Sendo A a imagem original e Gy e Gx o resultado das aproximações da derivada horizontal e vertical respectivamente [11].

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} * A \quad G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} * A$$

### Operador Roberts

O operador Roberts permite um cálculo simples e rápido do gradiente espacial 2D da imagem, permitindo uma aproximação à magnitude do gradiente. Destaca regiões com alto valor de gradiente que muitas vezes correspondem às arestas. Este operador aplica um par de máscaras de convolução 2x2 [11] como se verifica a seguir, possuindo características muito semelhantes ao operador de sobel [11].

$$G_x = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} * A \quad G_y = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} * A$$



Figura 2.16: Aplicação do operador Roberts: a) Imagem original b) Imagem após a aplicação do operador. (<http://jpegthis.blogspot.pt/2009/03/sobel-method-edge-detection.html>)

### Operador de Prewitt's

O operador prewitt é semelhante ao operador sobel sendo usado para detecção de arestas verticais e horizontais nas imagens [11]. Encontra-se limitado apenas a oito direcções possíveis sendo baseado numa matriz de 3x3 para o cálculo de cada uma das oito direcções [48]. Trata-se de um operador com baixo custo computacional, podendo no entanto os seus resultados serem demasiado imprecisos. Ao contrário do operador de Sobel este operador não coloca qualquer ênfase em píxeis que se encontram perto do centro das máscaras, máscaras essas que são descritas de seguida.

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} * A \quad G_y = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} * A$$



Figura 2.17: Aplicação do operador de Prewitt: a) Imagem original b) Imagem após a aplicação do operador.

(<http://jpegthis.blogspot.pt/2009/03/sobel-method-edge-detection.html>)

### Detector de Arestas LoG

Os pontos de aresta detectados através do valor zero da segunda derivada são muito sensíveis ao ruído. Portanto é importante filtrar esse ruído antes da etapa de aperfeiçoamento da aresta. Para fazer isso o método *Laplacian of Gaussian* (LoG) combina a filtragem gaussiana com o detector de aresta laplaciano [11]. As principais características deste detector são as seguintes: o filtro de suavização é um filtro gaussiano, o aperfeiçoamento da aresta é efectuado através da segunda derivada (laplaciano), o critério de detecção diz respeito à presença do zero da segunda derivada com o correspondente máximo da primeira derivada, por fim a localização da aresta pode ser estimada usando uma interpolação linear [11].



Figura 2.18: Aplicação do operador LoG: a) Imagem original b) Imagem após a aplicação do operador.

(<http://jpegthis.blogspot.pt/2009/03/sobel-method-edge-detection.html>)

### Algoritmo de Detecção de Arestas Canny

O operador de arestas canny é um operador muito popular e eficaz que pode ser usado na etapa de pré-processamento em diversos algoritmos no que ao processamento visual diz respeito. Trata-se de um operador composto por diversas etapas, onde se efectua a suavização e filtragem, a supressão de não-máximos, seguindo-se uma análise dos compo-

nentes que se encontram conectados de modo a identificarem-se as verdadeiras arestas enquanto se eliminam as falsas [37][11].

Este operador possibilita determinar a aresta que se considera ser óptima seguindo um conjunto de critérios que maximizam a probabilidade de se detectarem arestas correctas, enquanto se minimiza simultaneamente a possibilidade de se detectarem falsas arestas [37].

Este operador funciona através de quatro passos essenciais que são: a suavização da imagem, onde é removido o ruído através do filtro gaussiano, a identificação dos gradientes e direcção de cada pixel, utilização do ponto zero da segunda derivada através do qual se identificam os píxeis mais fortes e com mais possibilidades de pertencerem a arestas existindo assim a possibilidade de se eliminarem os restantes, por fim é utilizada uma limiarização dupla, onde com a utilização de dois limiares através dos quais se determinam os píxeis finais pertencentes a cada aresta [37][11]. Na limiarização dupla são utilizados dois limiares  $t_1$  e  $t_2$  onde  $t_1 > t_2$  de modo a separar os píxeis mais fortes, em píxeis que pertencem e que não pertencem às arestas. Nesta etapa os píxeis com magnitude do gradiente maior que  $t_1$  são classificados como arestas definitivas, os píxeis que se encontrem entre  $t_2$  e  $t_1$  são classificados como potenciais arestas, já os píxeis com magnitude de gradiente abaixo de  $t_2$  são considerados como não sendo arestas [37].



Figura 2.19: Aplicação do operador Canny: a) Imagem original b) Imagem após a aplicação do operador. (<http://jpegthis.blogspot.pt/2009/03/sobel-method-edge-detection.html>)

### 2.7.3 Avaliação de Performance do Detector de Arestas

Em termos de detectores de arestas é normalmente necessário uma avaliação da sua performance. A performance de um detector é avaliada através de diversos critérios considerados importantes para uma boa performance que são: a probabilidade de detecção de falsas arestas sendo que quanto menor essa probabilidade melhor, a probabilidade de desaparecimento de arestas sendo valorizado este factor quanto menor for essa probabilidade, erro na estimativa do ângulo da aresta, distância média da aresta estimada para a verdadeira aresta e por fim, a tolerância para a distorção de arestas e outras características tal como cantos e junções [11].

#### 2.7.3.1 Problemas na Detecção de Arestas

Alguns dos problemas presentes nos métodos de detecção de arestas são: a perda ou desaparecimento de arestas, elevada quantidade de ruído ou gradientes muito ténues. Outros problemas,

## Segmentação de Imagens Torácicas de Raio-X

pode ser o mau ajuste do gradiente, o que produz resultados indesejáveis. As arestas da região segmentada podem não se encontrar ligadas entre si [58], existindo deste modo uma descontinuidade das arestas.

### 2.7.4 Segmentação Baseada em Regiões

Ao contrário dos métodos de detecção de arestas descritos anteriormente, este método não é baseado nas fronteiras dos objectos mas sim nas propriedades das regiões de cada um.

Uma região trata-se de um conjunto de píxeis com propriedades semelhantes. Os métodos baseados em regiões baseiam-se principalmente no pressuposto de que os píxeis vizinhos dentro de cada região têm valor semelhante, assim o procedimento comum é o de comparar um pixel com os seus vizinhos. Se o critério de semelhança é satisfeito o pixel pode ser definido como pertencente à dada região [5], caso contrário é provável que pertença a uma outra região como se pode verificar na figura 2.20. No entanto a classificação de um dado pixel numa dada região pode ser influenciada pela quantidade de ruído existente nessa imagem.

Em suma uma imagem será fragmentada num conjunto de várias regiões disjuntas entre si. Essa mesma fragmentação é então definida através das seguintes proposições. Sendo  $R$  a imagem inteira. Segmentar  $R$  em  $n$  regiões,  $R_1, R_2, \dots, R_n$ , tal que [43]

- a)  $\bigcup_{i=1}^n R_i = R$ ;
- b)  $R_i$  é uma região interligada,  $i = 1, 2, \dots, n$ ;
- c)  $R_i \cap R_j = \emptyset$  para todo o  $i$  e  $j$ ,  $i \neq j$ ;
- d)  $P(R_i) = VERDADEIRO$  para  $i = 1, 2, \dots, n$ ;
- e)  $P(R_i \cup R_j) = FALSO$  para  $i \neq j$ ;




Figura 2.20: Conceito do método de segmentação baseado em regiões: a) Imagem original b) Imagem segmentada utilizando o conceito de regiões.

(<http://www.sciencedirect.com/science/article/pii/S1047320307000272>)

As técnicas de segmentação baseadas em regiões são principalmente usadas para identificar várias regiões com características semelhantes na imagem [12]. Assim, para identificar regiões é necessário saber quais as características a analisar na imagem e que podem ser comuns a um determinado número de píxeis, de modo a definirem uma região.

Os princípios são a semelhança de valor, que inclui as diferenças do valor de cinzentos e a variância do valor de cinzentos, e a proximidade espacial que consiste na distância euclidiana de uma região [43]. Como se pode ver na figura 2.20, na imagem de *input* são detectadas as diferentes regiões que agrupam entre elas os vários píxeis da imagem.

As abordagens baseadas em regiões são geralmente menos sensíveis ao ruído do que os métodos baseados em arestas. No entanto, podem ser mais complexas de implementar [12].

### 2.7.4.1 Crescimento de Regiões

O método de crescimento de regiões trata-se de um dos métodos mais simples de entender e de fácil implementação no que à segmentação de regiões diz respeito. Esta abordagem de segmentação consiste na escolha de um determinado número de pontos da dada imagem, pontos esses que são denominados de sementes e a partir dos quais é efectuada uma análise dos respectivos vizinhos de cada um. Estes mesmos pontos podem ser escolhidos de uma de duas formas diferentes: ou através de uma forma aleatória, ou através de heurísticas. Esta última, tem uma vantagem em relação à primeira, pois incorpora conhecimento específico da imagem, enquanto que na primeira o factor aleatório encontra-se presente. Esta análise serve para verificar se cada um dos vizinhos dos pontos sementes é semelhante ou não com a semente. Caso se considere semelhante, o vizinho é agregado ao ponto em análise aumentando assim a região em causa [18]. Os passos principais deste algoritmo são os seguintes:

1. **Passo 1.** é escolhido um píxel arbitrário. Este píxel será a semente, rotulado como sendo uma região que irá crescer de acordo com um dado critério de semelhança [18];
2. **Passo 2.** Verificar os píxeis vizinhos e adicioná-los à região se eles forem semelhantes aos píxeis sementes [18];
3. **Passo 3.** O processo indicado pelo passo 2 continua até serem contactados a uma dada região os píxeis que corresponderão à fronteira dessa região. Após isso, a região ficará então completa [18];

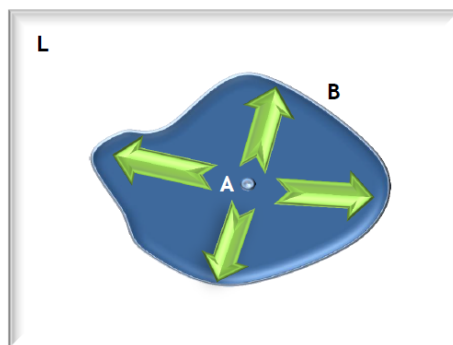


Figura 2.21: Método de crescimento de regiões partindo da semente.

A figura 2.21 ilustra o método de crescimento de regiões partindo da semente. Como se pode ver na figura, o ponto *A* constitui a semente a partir do qual serão analisados os respectivos vizinhos de modo a analisar se pertencem ou não à região em causa. *B* diz respeito aos limites da região, ou seja, partindo da semente a região cresce até aos limites que encontram definidos por *B*, sendo que a imagem total é denotada por *L*. Após o término da segmentação da respectiva região dá-se início a um novo processo, através do qual, partindo de uma nova semente

## Segmentação de Imagens Torácicas de Raio-X

se identifica uma nova região e assim sucessivamente até a imagem se encontrar totalmente segmentada.

Os critérios de semelhança utilizados podem variar entre a intensidade da cor de acordo com os componentes vermelho, verde e azul da cor, a matiz, saturação, luminância e cromaticidade. Existem outros critérios que são mais estatísticos, como por exemplo a média ou desvio padrão [3]. São descritos de seguida alguns desses critérios:

**Valor Escalar dos Píxeis** - Os píxeis podem ser agrupados por proximidade do seu valor escalar. Aqui é feita uma normalização de todos os píxeis, sendo agrupados os que têm valores próximos formando-se assim uma região de interesse. Na figura 2.22, os píxeis com valores não distantes de cinco são agrupados em 3 regiões distintas.




Figura 2.22: Conceito do valor escalar associado ao crescimento de regiões: a) Imagem original b) Imagem segmentada.

**Valor do Desvio Padrão** - Outra técnica que pode ser utilizada é a separação de regiões pelo desvio padrão. Os píxeis que possuírem valores dentro de um determinado desvio padrão desejado formam o segmento de interesse [2]. sendo agrupados na mesma região. Caso contrário, podem pertencer a outras regiões [2]. Este conceito encontra-se ilustrado na figura 2.23.

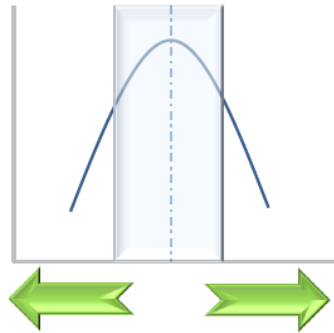


Figura 2.23: Conceito do desvio padrão associado ao crescimento de regiões.

**Valor do Limiar** - Consiste em obter-se a média da região e adicionar o novo ponto  $I_{n+1}(x, y)$  se ele se encontrar perto da média através de um limiar fixo  $T$ , caso satisfaça as condições seguintes:

$$\mu_n - T < I_{n+1}(x, y) < \mu_n + T \quad (2.2)$$

Para imagens a cores, a condição do limiar deve ser satisfeita simultaneamente em três planos para se considerar pertencente a uma dada região [3].

**Critério de Semelhança Haralick e Shapiro** A técnica proposta por Haralick e Shapiro [8] [39] baseia-se na média e na variância da imagem através das quais é calculado um teste estatístico. Se o valor do teste é suficientemente pequeno, então o pixel é adicionado à região sendo recalculados os valores da média e da variância. Caso contrário o pixel é recalculado e utilizado como semente para uma nova imagem [39].

$$T = \sqrt{\frac{(N-1)N}{N+1} \frac{(z - \mu_R)^2}{\sigma_R^2}} \quad (2.3)$$

De seguida são apresentadas algumas das desvantagens do método de crescimento de regiões. O ruído ou a variação de intensidade pode resultar em descontinuidades, isto é, em falhas de segmentação, como também pode resultar em *over-segmentation*. Outra desvantagem é o facto deste método possuir dificuldades em distinguir as sombras dos objectos. Existe também uma elevada complexidade de processamento, isto é, o facto de ser necessário comparar um dado pixel com os seus vizinhos de forma a verificar se deve ou não pertencer à região torna este método num processo lento e com necessidade de um elevado processamento. Por fim existe também a necessidade de informação prévia, como é o caso dos pontos semente. Este é um método que funciona através desses pontos semente, caso essa informação não esteja disponível então o método fica comprometido.

Em termos de vantagens este método apresenta as seguintes. Trata-se de um conceito simples e claro. Apenas é necessário um pequeno número de pontos semente para representar a propriedade que se pretende. Podem-se definir os pontos sementes bem como o critério de semelhança que se deseja. Por último existe a vantagem de se poder escolher vários critérios em simultâneo, podendo desta forma aumentar a eficácia deste método.

#### 2.7.4.2 Divisão e Fusão de Regiões

Normalmente uma segmentação baseada numa intensidade simples resulta em demasiadas regiões, sendo algumas delas desnecessárias. Mesmo em imagens onde se observam claramente as regiões com valor de cinza constante, o resultado da limiarização poderá conter regiões extra. As principais razões para que isso aconteça são: o elevado nível de ruído bem como também uma transição gradual entre os valores de cinzento em diferentes regiões. Deste modo surge o método que une operações de divisão e fusão de regiões de modo a permitir um aprimoramento dessa segmentação [11].

O método de divisão e fusão de regiões é também classificado como baseado no conceito de regiões. Este método SM (*Split and Merge*) é um algoritmo bem conhecido para segmentação de regiões homogêneas de uma imagem, para que isso aconteça, este método baseia o seu funcionamento na ideia de dividir para conquistar [45]. Ao invés de se escolher pontos semente, o utilizador pode dividir a imagem num conjunto arbitrário de regiões desconexas e posteriormente fundir e/ou dividir as regiões numa tentativa de satisfazer as condições de segmentação da imagem. Os seus passos principais são:

1. **Passo 1.** Considerar inicialmente a imagem inteira como uma única região [26];
2. **Passo 2.** Escolher uma região  $R$ . Caso o critério de homogeneidade  $H(R)$  seja falso, então dividir a região em quatro sub-regiões [26];

## Segmentação de Imagens Torácicas de Raio-X

3. **Passo 3.** Considerar duas ou mais sub-regiões  $R_1, R_2, \dots, R_n$ , se  $H(R_1, R_2, \dots, R_n)$  é verdade, então unir as  $n$  regiões numa única região [26];
4. Repetir os passos 2-3 até que não seja possível dividir ou unir mais regiões [26];




Figura 2.24: Segmentação segundo o conceito de divisão e fusão de regiões.

Nas figura 2.24 torna-se mais intuitivo o funcionamento deste método. De início temos a imagem original, sendo dividida em sub-imagens, sendo posteriormente fundidas. A figura 2.25 ilustra o conceito *quadtree* sobre o mesmo método. A raiz da "árvore" diz respeito à imagem no seu todo. Cada nodo da árvore tem apenas um pai (excepto para a raiz) e quatro filhos (excepto as folhas) como se vê na figura 2.25 [10].




Figura 2.25: Conceito *quadtree* na divisão e fusão de regiões.

O algoritmo de divisão e fusão proposto por Pavlidis [6], é um dos mais populares algoritmos de segmentação. Seja  $R$  a região que diz respeito à imagem que será subdividida em  $n$  regiões,  $R_1, R_2, R_3, \dots, R_n$  tais que [45].

- a)  $\bigcup_{i=1}^n R_i = R$  [45];
- b)  $R_i$  é uma região interligada,  $\forall i$  [45];
- c)  $R_i \cap R_j = \emptyset; \forall i, j; i \neq j$  [45];
- d)  $P(R_i) = VERDADEIRO; \forall i$  [45];

e)  $P(R_i \cap R_j) = \text{FALSO}; \forall i, j, i \neq j$  [45];

onde  $P(R_i)$  é o predicado lógico aplicado sobre os píxeis da região  $R_i$  e  $\emptyset$  é o conjunto vazio. A imagem será segmentada num conjunto de *clusters* de píxeis distintos que podem ser chamados de  $R_i$  e o predicado da segmentação  $P(R_i)$  é verdadeiro para uma única região num determinado momento, mas não para mais do que uma região. O algoritmo de divisão e fusão proposto por Pavlidis [6] pode ser descrito brevemente como:

- a) Dividir qualquer região  $R_i$  em quatro regiões iguais;
- b) Continuar a dividir até não existir mais nenhuma região;
- c) Unir quaisquer duas regiões  $R_i$  e  $R_j$  tal que  $P(R_i \cup R_j) = \text{Verdade}$ ;
- d) Continuar a unir até que não restem regiões por unificar;

Relativamente a este método podem-se enumerar as seguintes desvantagens: existência de uma grande carga computacional bem como de requisitos de armazenamento [17] visto ser necessária uma grande quantidade de cálculos, existe também uma incapacidade deste método para segmentar todos os tipos de objectos de uma imagem devido a altas variações entre os objectos no que ao tamanho, forma, cor e intensidade diz respeito [45]. Uma outra desvantagem é o facto de ser um método dependente do valor dos limiares usados.

No que às vantagens diz respeito este método possibilita incorporar conhecimento geométrico. Torna possível dividir a imagem usando o critério que se pretender, como por exemplo a média ou a variância dos píxeis a segmentar. Além disso, os critérios de divisão de regiões podem ser diferentes dos critérios de fusão. É também possível escolher vários critérios em simultâneo. Para além destas vantagens este método permite igualmente a eliminação de falsas arestas bem como de regiões através da fusão de regiões adjacentes que pertencem ao mesmo objecto. Por último permite igualmente a inserção de fronteiras que se encontram em falta através da divisão de regiões que contém partes de diferentes objectos [11].

### 2.7.5 Segmentação baseada no método *Watershed*

Este método de segmentação é um dos mais recentes. Como já vimos anteriormente existem duas formas básicas de segmentar imagens: uma que diz respeito à detecção das arestas dos objectos por meio da análise de mudanças que ocorrem localmente e uma segunda forma que diz respeito à identificação de regiões em imagens, regiões essas que serão identificadas através dos níveis de semelhança entre píxeis. Este método *watershed* diz respeito à segunda abordagem, sendo baseado numa noção de topografia. Considerando que uma imagem de níveis de cinzento pode ser vista como uma mapa de píxeis onde cada um deles terá uma determinada altura em relevo, forma-se assim aquilo que pode ser visto como um relevo topográfico.

Este relevo cria vales que servirão para a segmentação das respectivas regiões, como se pode ver na figura 2.26, onde  $O_1$ ,  $O_2$  e  $O_3$  dizem respeito ao objecto 1 ao objecto 2 e aos objectos 3 respectivamente.




Figura 2.26: Segmentação de regiões segundo a abordagem *watershed*.

O método *watershed* tem sido cada vez mais utilizado na segmentação de imagens. As linhas *watershed* podem efectivamente dividir as bacias hidrográficas num dado gradiente da imagem e gerar contornos fechados para cada região da imagem original [49]. O algoritmo *watershed* que se baseia na morfologia matemática foi proposto pela primeira vez por S. Beucher e L. Vincent [40]. As metodologias de segmentação de imagens baseadas neste método têm sido desenvolvidas e melhoradas durante os últimos anos. Como se vai constatar mais adiante Beucher propõe um algoritmo *watershed* através do uso de marcadores. Por outro lado, Vincent propõe um famoso algoritmo *watershed* denominado *immersion algorithm* ou algoritmo de imersão, que fornece uma efectiva e eficiente implementação da abordagem *watershed* [49].

Sejam  $M_1, M_2, \dots, M_R$  o conjunto de coordenadas dos mínimos locais de uma dada imagem  $g(x,y)$ , onde  $g(x,y)$  é o valor do pixel de coordenada  $(x,y)$ . Denote-se  $C(M_i)$  como as coordenadas numa dada bacia hidrográfica sendo  $M_i$  o mínimo local. Finalmente seja  $T[n]$  o conjunto de coordenadas  $(s,t)$  para os quais  $g(s,t) < n$ :

$$T[n] = \{(s,t) \mid g(s,t) < n\} \quad (2.4)$$

1. **Passo 1.** Determinar o valor do pixel máximo e mínimo de  $g(x,y)$  como sendo o mínimo e máximo respectivamente. Atribuir a coordenada do mínimo a  $M_i$ . O mínimo  $M_i$ , que se encontra inundado na fase  $n$  [5];
2. **Passo 2.** Calcular

$$C_n(M_i) = C(M_i) \cap T[n] \quad (2.5)$$

Se  $(x,y) \in C(M_i)$  e  $(x,y) \in T[n]$ ,  $C_n(M_i) = 1$  na posição  $(x,y)$ ; caso contrário  $C_n(M_i) = 0$ .  $C[n]$  denota a união da bacia alagada na fase  $n$ .

$$C[n] = \bigcup_{i=1}^R C_n(M_i) \text{ sendo que } n = n + 1 [5] \quad (2.6)$$

3. **Passo 3.** Derivar o conjunto de componentes em  $T[n]$  sendo identificados por  $Q$ . Para cada componente ligado  $q \in Q$ , existem três condições:
  - a) Se  $q \cap C[n-1]$  está vazio, o componente  $q$  é introduzido em  $C[n-1]$  formando  $C[n]$

representando que um novo mínimo foi encontrado [5];

- b) Se  $q \cap C[n-1]$  contém um componente de  $C[n-1]$ , o componente ligado é incorporado em  $c[n-1]$  de modo a formar  $C[n]$ , porque isso significa que  $q$  se encontra dentro de uma bacia que corresponde a alguns mínimos locais [5];
- c) Se  $q \cap C[n-1]$  contém mais do que um componente ligado de  $C[n-1]$ , isso representa a totalidade ou parte de uma crista que separa duas ou mais bacias hidrográficas identificadas portanto, é necessário determinar os pontos dos cumes e configurar esses pontos de modo a formar barragens [5] de modo a evitar-se a fusão de regiões disjuntas;

4. **Passo 4.** Construir  $C[n]$  de acordo com as expressões que se encontram no passo 2. Definir  $n = n + 1$  [5];

5. **Passo 5.** Repetir o passo 3 e 4 até que  $n$  atinga  $\max + 1$  [5];

Uma das desvantagens deste método reside na grande possibilidade de existência de segmentação-exagerada (*over-segmentation*), isto é, para um dado objecto é segmentado um conjunto de dados extra que não pertence ao objecto em causa, o que se fica a dever ao facto do *watershed* ser sensível ao ruído da imagem.

A existência deste ruído implica a detecção de uma maior quantidade de mínimos locais que na maioria são irrelevantes, aumentando assim o número de regiões desnecessárias.

Assim, torna-se necessário efectuar um pré-processamento, aplicando um filtro de suavização da imagem de modo a eliminar o máximo possível de ruído sendo que outra das formas será através da utilização de marcadores.

Outro problema reside na fraca detecção de áreas significativas com baixo contraste nas suas fronteiras.

Se a relação que existe entre o sinal e o ruído no contorno de interesse não é elevada então o método *watershed* não será capaz de o detectar com a precisão adequada [53]. Uma última desvantagem é o facto de ser computacionalmente pesado, existindo a necessidade de uma grande quantidade de tempo de modo a que se possa efectuar a respectiva segmentação.

Em termos de vantagens este método contém as seguintes: as fronteiras de cada região são contínuas, isto é, cada região encontra-se totalmente delimitada pelas suas fronteiras bem identificadas [5]. Em suma, este método permite uma elevada precisão na detecção das fronteiras dos objectos [40].

Outra das vantagens por parte deste método é o facto de se tratar de uma abordagem simples e intuitiva [53].

#### 2.7.5.1 Método *Watershed* por Inundação

Um dos modelos existentes no método *watershed* é o modelo por inundação. A figura 2.27 serve de ilustração a esse modelo.

Em primeiro lugar é necessário determinar os mínimos locais. Estes mínimos locais são os píxeis em que os valores de cinzento são menores, o que significa que a nível topográfico correspondem aos vales como se pode ver na imagem a) [40].

Este conceito pressupõe a inundação desses mesmos vales, o que acontece através da queda de água que escorre e se vai alojar nos pontos mais baixos. A inundação é feita a um ritmo uniforme até que esses vales fiquem transformados em lagos como se pode verificar através

## Segmentação de Imagens Torácicas de Raio-X

da imagem b) [40]. O que acontece é que para cada mínimo local fica a existir uma bacia hidrográfica, isto é, uma região.

No entanto a subida da água poderá unir vales que até ai se encontravam separados por pontos elevados, isto em termos práticos significa que duas regiões disjuntas de uma dada imagem se unem e se transformam numa só.

Para evitar que isso aconteça são colocadas barreiras nos pontos mais elevados, evitando que a água de regiões diferentes se una verificando-se isto nas imagens d) e e). Através desta inundação são detectadas as diversas regiões que se podem encontrar numa imagem.

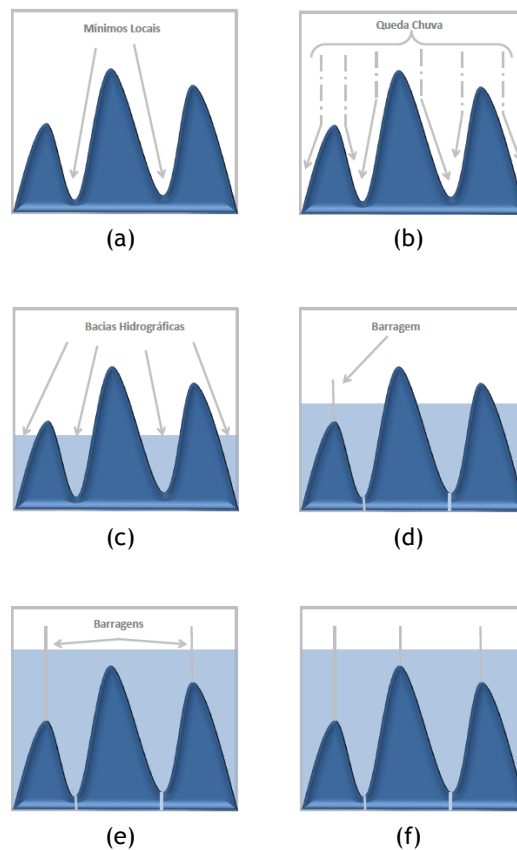


Figura 2.27: Segmentação *watershed* segundo a abordagem de inundação: a) Identificação dos mínimos locais da imagem b) Conceito de queda de água que irá provocar uma inundação gradual c) São criados lagos de água, onde cada lago corresponde a uma região específica d) e) São criadas barragens de modo a evitar que a água de lagos diferentes se una f) Com os lagos devidamente identificados definem-se então as regiões de uma dada imagem.

### 2.7.5.2 Método *Watershed* usando Marcadores

Por forma a compensar algumas das desvantagens anteriormente descritas, o conceito de marcador permite incorporar algum conhecimento prévio da imagem [32].

Cada marcador indica a presença de uma determinada região. Um marcador não é mais do que uma sub-região dentro de cada região que se pretende segmentar. Cada marcador indica a presença de um objecto a ser segmentado. Na figura 2.28 observa-se um exemplo de uma aplicação prática deste método, onde se mostra um conjunto de bolas de bilhar a serem

segmentadas. O método pressupõe que cada bola seja identificada através de um marcador de modo a que a sua segmentação se faça de uma forma mais correcta e precisa. Assim esta abordagem tem a vantagem de incrementar a robustez no local onde o marcador é anexado [23]. No entanto os marcadores originam um novo problema, que diz respeito à quantidade de dados extra a serem processados. Assim é necessário encontrar formas de colocar o menor número possível de marcadores, sem que isso afecte o resultado da segmentação. Assim o objectivo passa por anexar menos marcadores mas com o mesmo resultado que é obtido quando são anexados em maior quantidade [23].




Figura 2.28: Método *watershed* segundo o conceito de marcadores: a) As regiões a branco nas bolas dizem respeito aos marcadores b) A segmentação que resulta do método baseado em marcadores.

Na figura 2.29 é ilustrada a modificação que o método por marcadores acrescenta ao conceito de inundação do método *watershed*.




Figura 2.29: Efeitos do marcador no gradiente: a) Imagem inicial b) Marcador que será aplicado à imagem c) Imagem resultante após a aplicação do marcador já sem os mínimos locais desnecessários.

### 2.7.6 Segmentação baseada em Contornos Activos

O método de contornos activos é outro método utilizado na segmentação de imagens.

Trata-se de um importante método para delinear os objectos de uma forma mais precisa. Os modelos de contornos activos existentes podem ser classificados em duas classes: modelos baseados na aresta e modelos baseados na região. Estes dois tipos de modelos têm os seus prós e contras, e a escolha depende de diferentes características das imagens.

Os modelos baseados em arestas utilizam o gradiente da imagem para definir os contornos nas fronteiras do objecto. Estes modelos têm um critério de paragem baseado no gradiente e um termo de força de balão para controlar o movimento do contorno. O critério de paragem baseado no gradiente serve para parar o contorno na fronteira do objecto desejado, mas apenas tem efeito perto das arestas das imagens [30].

Já os modelos baseados em regiões permitem identificar cada região de interesse através

## Segmentação de Imagens Torácicas de Raio-X

do uso de um certo descritor de região, por forma a guiar a deslocação do contorno activo e assim não utilizar o gradiente da imagem, possibilitando um melhor desempenho em imagens com fronteiras pouco perceptíveis. Esta abordagem é significativamente menos sensível à localização do contorno inicial.

O conceito mais simples de contorno activo é o de *snake*, contendo associado o conceito de energia, possibilita que a sua curva determine os contornos do objecto que se deseja segmentar.

O contorno inicial é visto como uma curva elástica que deve ser deformada através da minimização de uma função de energia entre as forças internas da curva, relacionadas com a suavidade, elasticidade e rigidez do contorno deformável e as forças externas que não é mais do que o potencial de atracção do contorno em direcção ao objecto de interesse que são geradas a partir da imagem [41].

Em suma este método pressupõe a utilização de dois tipos de forças: externas e as internas. As forças externas são responsáveis por colocar a *snake* perto do mínimo local desejado, já as forças externas também designadas de forças da imagem empurram o contorno em direcção às características salientes da imagem como linhas, arestas ou outros contornos [9]. O contorno inicial evolui sob a acção das forças internas e externas. Por este motivo, o modelo deformável de balão equivale a insuflar ou a expandir um contorno inicial, até que esta se adapte de maneira óptima à estrutura de interesse presente na imagem a segmentar.

A minimização da energia conduz a um equilíbrio entre as forças envolvidas no modelo [41].




Figura 2.30: Segmentação segundo o conceito de contornos activos: a) *A* representa o contorno inicial e *B* o contorno que delimita a região de interesse b) As forças começam a actuar no contorno inicial c) O contorno inicial detecta os limites da região de interesse d) Contorno final.

O método original das *snakes* é definido por uma curva paramétrica

$$v(s) = (x(s), y(s)), \quad (2.7)$$

onde  $s$  é o comprimento do arco e  $x$  e  $y$  as coordenadas da curva 2D na imagem. A energia da imagem pode ser descrita como a intensidade da imagem através da expressão [29]:

$$E_{img}(v(s)) = I(v(s)) \quad (2.8)$$

onde  $I$  representa a imagem. Na literatura, a energia da imagem é frequentemente definida como

$$E_{img}(v(s)) = -|\nabla I(v(s))|^2 \quad (2.9)$$

$|\nabla I(v(s))|$  é a norma ou magnitude do gradiente da imagem nas coordenadas  $x(s)$  e  $y(s)$ . Na prática, a energia da imagem  $E_{img}(v(s))$  é calculada através da integração dos valores  $|\nabla I(v(s))|$ , retirados através do pré-cálculo do gradiente da imagem ao longo da linha dos respectivos segmentos que interligam os vértices do contorno. A energia interna é definida como [29]

$$E_{int}(v(s)) = \frac{1}{2} \left( \alpha(s) \cdot |v_s(s)|^2 + \beta(s) \cdot |v_{ss}(s)|^2 \right) \quad (2.10)$$

onde  $v_s$  e  $v_{ss}$  são a primeira e a segunda derivadas de  $v$  respeitantes a  $s$ . A função  $\alpha(s)$  controla o termo de primeira ordem da energia interna: a elasticidade. Quando o objectivo é minimizar  $E_{int}(v(s))$  valores altos de  $\alpha(s)$  deixam que o contorno se torne uma recta entre dois pontos. Já a função  $\beta(s)$  controla a rigidez. Altos valores de  $\beta(s)$  deixam que o contorno se torne mais suave, enquanto valores pequenos permitem a criação de cantos. As funções  $\alpha(s)$  e  $\beta(s)$  necessitam de ser pré definidas com base nas características da forma do objecto de interesse em causa [29].

Em suma, a derivada de primeira ordem permite que o contorno funcione como uma membrana elástica enquanto a derivada de segunda ordem faz com que a snake funcione como uma barreira [9]. Ajustando os pesos de  $\alpha(s)$  e  $\beta(s)$  controla-se a importância da membrana bem como da barreira. Estabelecer  $\beta(s)$  como zero num determinado ponto permite à *snake* ser descontínua na segunda derivada e assim desenvolver um canto [9].

A energia total da snake  $E_{snake}^*$  a ser minimizada é definida como

$$E_{snake}^* = \int_0^1 E_{snake}(v(s)) ds = \int_0^1 \left[ E_{img}(v(s)) + E_{int}(v(s)) + E_{con}(v(s)) \right] ds \quad (2.11)$$

Os modelos de contornos originais necessitam de informações iniciais sobre o contorno a ser segmentado. Isto representa uma considerável desvantagem do método, além do facto de apresentarem dificuldades em se aproximar de contornos de objectos concâvos, uma vez que as forças externas envolvidas são horizontais, deslocando o contorno verticalmente mas não progredindo adequadamente para a concavidade [41].

Outra desvantagem reside no facto deste método ter sido originalmente projectado para ser aplicado em modelos iterativos, isto é, iniciados e melhorados com a intervenção de um operador especialista. Quando se tem modelos não-iterativos, a extracção de regiões de interesse deve ser iniciada em local próximo à estrutura de interesse para garantir um bom desempenho [41]. Caso não seja colocado próximo da região de interesse, existe a possibilidade de existir *over-segmentation* ou mesmo *under-segmentation*. Este é também um método que é depen-

## Segmentação de Imagens Torácicas de Raio-X

dente de parametrização, obtendo melhores ou piores resultados dependendo dos parâmetros que recebe.

Outra desvantagem é o facto de ser necessário recalcular a função de distância em cada iteração aumentando desta forma os recursos computacionais necessários [25].

Em termos de vantagens os modelos de contornos activos baseados nas arestas utilizam o gradiente da imagem de forma a parar o contorno inicial nas fronteiras do objecto, servindo assim como um critério de paragem. Em relação aos modelos baseados na regiões, estes não utilizam o gradiente da imagem, obtendo melhores resultados em imagens onde os limites são fracos. Estes modelos também são menos sensíveis em relação à localização do contorno inicial [33].

### 2.7.7 Segmentação com Métodos Baseados em *Clusters*

O *clustering* no campo da segmentação de imagem é definido como sendo um processo de identificação de grupos onde cada um contém uma primitiva que é similar na imagem [4], isto é, trata-se de uma técnica de agrupamento que usa uma medida de semelhança onde itens similares são colocados no mesmo grupo e os diferentes colocados em grupos diferentes [51].

As técnicas de *clustering* podem ser classificadas em supervisionada ou não supervisionada. Supervisionada visto que contém a intervenção humana que decide os critérios de *clustering*, e a não supervisionada caso contrário [4].

O *data clustering* é amplamente utilizado no campo da visão computacional e processamento de imagem e, como tal, aplicada num vasto leque de domínios tais como: marketing, biologia e imagem médica entre outros [34]. Os métodos baseados em clustering são usados em diversas aplicações, tais como, *data mining*, compressão, *machine learning* e segmentação de imagem [27].

#### 2.7.7.1 Clustering Hierárquico

O *clustering* hierárquico faz parte das técnicas *declustering* não supervisionadas [4].

Trata-se de um processo que permite a integração de diferentes imagens sendo representadas por meio de um *cluster* em forma de árvore, originando um *cluster* final [4].

Em suma este processo gera de forma automática uma hierarquia de imagens [57], que não são mais do que partições de dados da imagem original.

No entanto tem a desvantagem de se tratar de um processo estático onde os pontos anexados a um cluster não podem ser mudados para outro cluster além disso pode falhar ao tentar separar pontos sobrepostos devido ao facto de não conter informação sobre a forma ou tamanho do *cluster* [28].

Em termos de vantagens este processo contém as seguintes: o facto de se tratar de um processo não supervisionado e completamente orientado aos dados assegura que o processo de segmentação possa ser aplicado a qualquer imagem, sem qualquer informação prévia sobre a imagem [57] [28]).

Entre os diversos algoritmos de clustering encontram-se o *K-means clustering*, *Fuzzy K-means*, *Harmonic K-means*.

A maior parte dos métodos baseados em *clustering* funcionam na idéia de que os centros iniciais dos *clusters* são fornecidos. Partindo desses mesmos centros é que então se determinam os *clusters* finais. Se não existir uma correcta inicialização desses centros poderá dar-se origem a um resultado final pouco preciso, não sendo por isso fiável. Assim torna-se importante que a inicialização dos pontos iniciais seja efectuada do modo mais exacto possível. Durante o processo de *clustering* existem três problemas essenciais que afectam o resultado final: os centros mortos, a redundância de centros e os mínimos locais. Os centros mortos não são mais do que centros que não têm membros ou dados associados, situando-se normalmente entre dois centros activos ou fora do intervalo de dados. Este é um dos casos problemáticos que pode acontecer devido a uma defeituosa inicialização dos centros, originando centros que não têm dados associados não formando assim um cluster fiável e preciso. Outro dos problema existentes ao longo deste processo trata-se da redundância de centros, que acontece à medida que aumenta o número de centros aumenta-se ao mesmo tempo a tendência dos centros ficarem muito perto uns dos outros [19].

### 2.7.7.2 Método *K-means*

O algoritmo *K-means* trata-se do algoritmo mais utilizado na categoria dos algoritmos baseados em *clustering*. Este trata-se de um algoritmo que é utilizado principalmente para classificar ou agrupar em  $K$  grupos, objectos baseados em características, sendo  $K$  um número inteiro positivo [50]. Trata-se de um método numérico, não supervisionado, não determinístico e iterativo. Este método é normalmente utilizado em computação visual, mais propriamente no campo relacionado com a segmentação de imagens [42].

$$J = \sum_{j=1}^K \sum_{i=1}^N \|x_i^{(j)} - c_j\|^2 \quad (2.12)$$

onde:  $\|x_i^{(j)} - c_j\|^2$  trata-se da distância entre  $x_i^{(j)}$  e o centro do cluster  $c_j$ ;  
Como exemplo, utiliza-se como métrica a distância eucladiana.

$$d(x_i, x_j) = \left( \sum_{k=1}^N (x_{ik} - x_{jk}) \right)^{\frac{1}{2}} \quad (2.13)$$

O algoritmo é composto pelos seguintes passos:

1. **Passo 1.** Escolhe-se o número de clusters pretendido,  $K$  [50];
2. **Passo 2.** De seguida são escolhidos aleatoriamente  $K$  píxeis que representam o grupo de centróides inicial, ou seja o grupo de pontos que representa o centro de cada clusters [50];
3. **Passo 3.** Efectua-se a atribuição de cada pixel escolhido anteriormente ao cluster que tem o centroide mais aproximado [50];
4. **Passo 4.** Quando todos os píxeis tiverem sido atribuídos, é necessário recalculas as posições dos  $K$  centróides [50];
5. **Passo 5.** Por fim repetem-se os passos 2 e 3 até que os centroides não se movam mais de lugar. Isto produz a separação dos píxeis em grupo a partir dos quais a métrica a ser minimizada pode ser então calculada [50].

## Segmentação de Imagens Torácicas de Raio-X

O facto de se tratar de um método não supervisionado torna os pontos dentro dos clusters estáticos não podendo ser movidos para outro cluster e devido à falta de informação prévia torna-se complicado separar grupos sobrepostos devido à falta de informação sobre o cluster. O número de clusters,  $K$ , deve ser determinado antes da implementação do algoritmo em questão. Este método é pesado computacionalmente. O método *K-means* é considerado demasiado sensível às condições iniciais, isto é, diferentes condições iniciais irão produzir diferentes resultados nos *clusters*. Adicionalmente, os dados que se encontram isolados, encontrando-se demasiado longe dos centros, pode originar uma deslocação do centro do clusters relativamente à sua posição considerada óptima, o que poderá levar a uma representação pobre dos dados [42]. De modo a tentar resolver os problemas que este método apresenta, surgiram posteriormente diversas abordagens também baseadas em *clustering*.

Como vantagem realça-se o facto da utilização de um grande número de variáveis por parte deste método o tornar possivelmente mais rápido do que aquilo que acontece em relação ao *clustering* hierárquico se o  $K$  for pequeno [56].

### 2.7.7.3 Fuzzy K-means

O método *fuzzy K-means* é também conhecido por método *fuzzy C-means* (FCM). Este método surge na tentativa de debelar as fraquezas inerentes ao método *K-means* [42]. A ideia principal deste método é o facto de um mesmo objecto poder pertencer a diversos clusters diferentes. é um método iterativo que tenta separar o conjunto de dados num determinado número de *clusters* compactos, sendo que cada *cluster* é representado pelo seu centro [42].

Em termos de desvantagens este método engloba as seguintes. é sensível ao ruído. Para além disso engloba um tempo de processamento demasiado elevado, sendo também muito sensível à inicialização do centro do cluster [42]. O facto de ser um método fraco no que à inicialização do centro cluster diz respeito influência os resultados finais obtidos, isto é, sem uma inicialização apropriada geram-se resultados probes e pouco confiáveis no que aos centros dos clusters diz respeito [42].

Tal como outros métodos de *clustering*, trata-se de um método de clustering que não é supervisionado, por isso mesmo não é necessário conhecimento prévio acerca do conjunto de dados a serem testados. Pode ser usado não apenas com uma característica, e com qualquer número de classes.

### 2.7.7.4 Moving K-means (MKM)

Na tentativa de resolver os problemas anteriormente descritos em problemas de agrupamento foi criado um algoritmo proposto por Mashor que é chamado de *moving K-means* (MKM). Este algoritmo permite minimizar os centros mortos, bem como os problemas de redundância e os centros detectados em mínimos locais. Ao resolver estes problemas é natural que os resultados finais sejam mais eficazes.

Neste método pode acontecer que os *clusters* não se encontrem localizados no meio ou no centroide de um dado grupo de dados. Esta fraqueza poderá levar ao aparecimento de resultados imprecisos [42]. A introdução neste método do conceito de aptidão poderá levar a um problema onde alguns membros de clusters com maior percentagem de aptidão poderão ser atribuídos como sendo membros de um cluster com pouca capacidade de aptidão. Normalmente, para um conjunto de dados com ruído o centro com a menor percentagem de aptidão representa grupos de dados pouco fiáveis.

## 2.8 Segmentação de Imagem Médica

No campo da medicina a segmentação de imagem desempenha um papel crucial em diversas aplicações médicas, automatizando ou facilitando a delimitação de estruturas anatómicas e outras regiões de interesse.




Figura 2.31: Sistemas inteligentes de imagem médica.

O diagnóstico médico através da imagem é uma ferramenta de valor inestimável na medicina nos dias de hoje. Ressonância magnética, tomografia computadorizada, mamografia digital são exemplos de técnicas baseadas na imagem que possibilitam um eficaz e não agressivo mapeamento anatómico da pessoa. Estas tecnologias permitem um aumento do conhecimento anatómico da pessoa para os médicos, tratando-se assim de um componente importante quer no diagnóstico quer no planeamento do tratamento.

Com este aumento quer do número de imagens quer também do seu tamanho tornou-se necessário o uso de métodos computacionais que facilitem esse processo, em particular algoritmos para delimitar regiões de interesse. Estes algoritmos de segmentação de imagem, têm portanto um papel importante em diversos cenários como são os casos: da quantificação dos volumes dos tecidos, diagnósticos, localização da patologia, estudo da estrutura anatómica, planeamento do tratamento, entre outros. Tornou-se assim cada vez mais necessário o desenvolvimento de sistemas inteligentes como se encontra esquematizado na figura 2.31 que possam apreender através de situações passadas e assim inferir conhecimento acerca de novas imagens, dando assim um importante auxílio aos médicos acerca de possíveis anormalidades que possam existir na imagem.

Os métodos de segmentação estão dependentes de vários factores, isto é, a segmentação do cérebro é diferente da segmentação que é efectuada ao fígado. Em suma não existe uma técnica de segmentação uniforme que consiga produzir resultados satisfatórios para todas as imagens que resultam das mais diversas aplicações. Portanto, a segmentação automática de imagens médicas é uma tarefa difícil, porque essas imagens são complexas por natureza e não contém uma característica que seja comum [59].

### 2.8.1 Dificuldades na segmentação de imagens médicas

Na segmentação de imagens médicas existem diversos obstáculos entre os quais se destacam: o efeito do volume parcial, onde um pixel contém mais do que um tecido associado, sendo a resolução do scanner da ressonância magnética insuficiente, resultando assim em fronteiras turvas que separam os tecidos, levando a uma errada classificação. Outro problema é o da heterogeneidade da intensidade, também designado de intensidade não uniforme originando o facto de um mesmo tecido não apresentar um intensidade constante ao longo da imagem, dificultando a sua detecção [59].

### 2.8.2 Critérios de classificação dos métodos

Apesar de não existir um método que seja uniforme, existem formas de tentar perceber qual poderá ser o melhor para determinado caso específico. Essas formas de medição são: a precisão, a repetibilidade e a eficiência. A precisão é o critério de avaliação mais comum, que indica o grau de delimitação do objecto que corresponde à verdade. A repetibilidade avalia a percentagem com que se atinge o mesmo resultado em diferentes sessões de segmentação. Existe também o critério da eficiência, isto é, o tempo gasto para se efectuar uma dada segmentação e comparar os resultados obtidos tendo em conta o tempo dispendido [21].

### 2.8.3 Métodos de segmentação de imagem médica

De seguida são referidos os métodos de segmentação existentes no campo da medicina. Existem diversas formas de se classificar as diversas técnicas de segmentação de imagem médica como se constata de seguida.

#### 2.8.3.1 Limiarização

Neste tipo de técnica uma dada imagem é dividida em grupos de píxeis com valores menores que o limiar e grupos com valores maiores ou iguais ao limiar. Os métodos baseados nesta técnica têm a vantagem de serem fáceis de implementar e de rápido processamento, no entanto são sensíveis ao ruído sendo necessário efectuar um pré-processamento.

1. **Limiarização global** - Este método pertence à categoria dos métodos baseados no limiar. Neste método é usado um único valor de limiar para a totalidade da imagem. O resultado deste método é satisfatório quando a imagem tem uma intensidade homogénea e existe um contraste elevado entre o objecto e o fundo. No entanto este método não é eficiente quando existem diversos tecidos sobrepostos [59].
2. **Limiarização local** - Este método efectua a divisão da imagem em sub-imagens e calcula o valor do limiar para cada uma das sub-imagens. Este método apesar de necessitar de um maior tempo de processamento do que o método global, possibilita uma melhor extracção de pequenas regiões [21].
3. **Método Niblack** - O método Niblack é uma variante do método de limiarização local. Implica o cálculo da média local e um desvio padrão local de forma a obter-se o valor do limiar [59] [61].
4. **Método de Sauvola and Pietikainen** - Este método é também uma variante da limiarização local, obtendo melhores resultados do que o método Niblack. Este algoritmo surge de uma transformação que parte do algoritmo Niblack [21] [24].

#### 2.8.3.2 Método baseados em regiões

Este tipo de técnicas são usadas no sentido de fragmentar uma imagem em regiões disjuntas, de acordo com propriedades que são comuns. Propriedades essas que variam entre valores de intensidade, cor, brilho, propriedades geométricas entre outras [21].

1. **Método de divisão e fusão** - é um método baseado em regiões. Este método baseia-se na árvore de quadrantes. À imagem inicial é aplicado o critério de semelhança de uma

dada propriedade, caso não seja homogênea a imagem é dividida em quatro quadrantes. O processo é aplicado até que cada uma das imagens seja homogênea [21]. Apesar de ser um método de rápido processamento, existe a dificuldade de identificar o ponto de divisão da imagem, não existindo uma única solução [35].

2. **Crescimento de regiões** - Técnica que parte da ideia de *bottom up*, começando apenas com  $n$  píxeis sementes, sendo cada semente tratada como uma região. Cada semente cresce através da anexação dos seus píxeis vizinhos com propriedades semelhantes. Obtém-se bons resultados em imagens com ruído no entanto tem dificuldade em detectar arestas. Necessita normalmente de um *input* manual como indicação daqueles que vão ser os píxeis semente [21].
3. **Método watershed** - Este método surge a partir da morfologia matemática onde uma imagem é uma superfície onde os píxeis mais brilhantes, isto é, de maior intensidade formam os pontos altos dessa superfície, por outro lado os píxeis mais escuros são considerados os vales dessa topografia. Os vales são então inundados e antes da água passar para um vale vizinho constrói-se uma barragem. Esse vale com água representa então uma região devidamente delimitada [59].

### 2.8.3.3 Métodos baseados em arestas

Este tipo de técnica tem como ideia principal a utilização do gradiente das arestas. Os algoritmos baseados nesta técnica têm dois conceitos essenciais: detecção das arestas e ligação das arestas. De modo a determinar o valor do gradiente da imagem os métodos dessa técnica usam normalmente as derivadas de primeira e segunda ordem. Tem a sua grande desvantagem no facto dos seus resultados dependerem do nível de ruído presente, não existindo a garantia de arestas bem definidas que possam definir as regiões convenientemente [59].

1. **Modelos de contornos activos** - A ideia deste método depende da fronteira do objecto bem como de uma curva inicial. A detecção da curva está relacionada com a função de energia, sendo que a fronteira do objecto é determinada por um processo de minimização de energia. Estes modelos deformáveis são robustos perante o ruído da imagem, sendo que outra vantagem é o conhecimento prévio da forma do objecto, o que pode ajudar no processo. No entanto tem a desvantagem de ser necessário a inicialização do contorno inicial perto das fronteiras do objecto [59] o que ajuda a determinar as fronteiras com maior veracidade. Caso contrário poderá ocorrer uma menos precisa segmentação.

### 2.8.3.4 Métodos de Clustering

Este tipo de técnicas depende da classificação na medida em que classifica os píxeis da imagem em classes sem ser necessária informação prévia. O treino das técnicas de *clustering* é feita usando as características do pixel com as propriedades de cada classe.

1. **K-means** - Este método de clustering determina uma média para cada classe. O resultado da imagem segmentada é o conjunto dos píxeis que se aproximam mais da média determinada para essa class [59].
2. **Fuzzy C-means** - Este trata-se de um método não supervisionado. Trata-se de uma generalização do algoritmo *K-means* [59]

### 2.8.3.5 Métodos Híbridos

1. **Método Híbrido semi-automático N.Sharma** - Este tipo de algoritmos [38] depende do uso de uma rede neuronal artificial (ANN) para extracção de características da imagem [59]. O objectivo deste método é o de possibilitar auto-segmentação e uma caracterização dos tecidos. Para além disso, este algoritmo foi desenvolvido para análise de imagens médicas com base na conjugação de abordagens sintáticas e estatísticas usando uma ANN [38] .
2. **Método Híbrido automático M. stella, B. Mackiewich** - Este algoritmo [14], consiste em três passos principais que são: remoção do fundo através do histograma de intensidade, remoção de pequenas conexões entre o cérebro e tecido circundante e por fim, uso de um algoritmo de contorno activo para uma afinação final do contorno do cérebro. Este algoritmo é afectado por tecidos parciais, sendo que também é igualmente afectado pela máscara utilizada [59].



## Capítulo 3

### Caso de Estudo

Este capítulo é dedicado à descrição dos métodos de segmentação estudados nesta dissertação. Utilizam-se três algoritmos distintos mas que pertencem à mesma abordagem de segmentação, baseada em contornos activos. São métodos que utilizam abordagens diferentes, sendo um deles híbrido, fundindo dois métodos, outro utiliza a noção de contornos activos baseados em regiões e o último igualmente baseado em regiões, numa perspectiva mais local.

#### 3.1 Métodos Base

##### 3.1.1 Método de Contornos Activos Híbrido segundo Shawn Lankton

Este é um método baseado na técnica de contornos activos e que foi desenvolvido por Shawn Lankton. Este método foi originalmente concebido para segmentar estruturas do córtex em imagens que provêm de ressonâncias magnéticas. É um método híbrido que junta o método de contornos activos baseado no local geodésico com o método de contornos activos baseado em regiões. No final é originada uma função de custo que será avaliada ao longo da curva, onde o custo em cada ponto da curva é baseado na análise das médias interior e exterior dos vizinhos desse mesmo ponto [31].




Figura 3.1: Imagem proveniente de ressonância magnética, segmentada por diferentes métodos: a) Contorno inicial b) Segmentação usando o método de contornos activos Chan Vese baseado em regiões c) Segmentação usando método de contornos activos geodésico baseado na aresta d) Segmentação usando o método híbrido segundo Shawn Lankton [31].

As estruturas do córtex representam um problema interessante na medida em que não possuem um perfil homogêneo de intensidade, tornando-se difíceis de caracterizar. Além disso o facto destas estruturas conterem fronteiras de fraca intensidade e a proximidade de outras estruturas com gradientes mais fortes, tornam a segmentação destas estruturas difícil usando o método de contornos activos[31].

##### 3.1.1.1 Contornos Activos Geodésico

Este método parte da abordagem de contornos activos base e reformula o problema para determinar o mínimo local em termos de custo através de uma métrica euclédiana. A ideia chave é

a de que na fronteira do objecto existe um gradiente alto. Um benefício desta abordagem é o facto de introduzir uma parameterização da curva baseada em propriedades geométricas [31].

A energia da curva deste método é demonstrada através da expressão

$$E = \oint_{C(s)} f(I) ds \quad (3.1)$$

onde  $C$  representa a curva e  $I$  representa a imagem. A variável  $f$  é a função positiva decrescente da imagem. Estes valores são determinados à medida da evolução da respectiva curva.

Em termos de desvantagens este método apresenta alguns pontos fracos: a função de energia apenas examina a imagem na curva, isto é, trata-se de uma função demasiadamente local, significando isto que a menos que a curva seja inicializada muito perto da fronteira desejada é de prever que serão determinados mínimos locais insignificantes. Adicionalmente a porção externa desta energia depende apenas do gradiente da imagem  $I$  que é susceptível ao ruído [31].

### 3.1.1.2 Contornos Activos com Base em Regiões

Outra abordagem usada para definir as energias de contorno é através das propriedades das regiões. A idéia presente neste método é a de que quando a curva se encontra na fronteira do objecto a imagem é particionada em duas ou mais regiões distintas em que as propriedades são parcialmente caracterizadas. Este tipo de contornos incluem métodos famosos como o método segundo Chan e Vese e também o método segundo o paradigma de Mumford-Shah [31].

Neste tipo de métodos a função de energia é dada por,

$$E = \int_{\Omega} (I - \mu)^2 dA + \int_{\bar{\Omega}} (I - \nu)^2 dA \quad (3.2)$$

onde  $\Omega$  e  $\bar{\Omega}$  representam o interior e o exterior da curva,  $\mu$  e  $\nu$  representam a média da imagem sobre  $\Omega$  e  $\bar{\Omega}$  respectivamente e  $I$  representa a imagem.

Esta energia é minimizada quando a média da imagem em  $\Omega$  e  $\bar{\Omega}$  é o mais aproximada em termos de precisão de  $\mu$  e de  $\nu$ .

Ela permanece robusta perante o ruído da imagem. Permanece igualmente robusta relativamente à posição da inicial do contorno [31]. No entanto é normal que o objecto a ser segmentado, o fundo ou mesmo os dois não sejam descritos com precisão pelas intensidades médias o que poderá levar a uma fraca ou incorrecta segmentação.

Em suma a idéia chave deste método híbrido é que em cada ponto da aresta do objecto, os pontos próximos dentro e fora do objecto serão moldados assim como as intensidades médias das regiões locais como se pode ver na figura 3.2 [31].

### 3.1.1.3 Função Energia do Método Híbrido

De seguida é descrita a função de energia deste método híbrido que resulta da junção das equações de energia de cada um dos métodos que o compõem [31].

## Segmentação de Imagens Torácicas de Raio-X




Figura 3.2: Regiões locais analisadas: a) Região representada por  $\Omega \cap \chi(x, s)$  como sendo a parte escura do perímetro de circunferência b) Mostra a região especificada por  $\bar{\Omega} \cap \chi(x, s)$  como sendo a parte escura da circunferência. Estas regiões são analisadas em cada ponto ao longo da curva [31].

$$E = \oint_{C(s)} \int_{x \in \Omega} (I\chi(x, s) - u_l(s))^2 + \int_{x \in \bar{\Omega}} (I\chi(x, s) - v_l(s))^2 ds \quad (3.3)$$

Sendo que nesta expressão  $s$  diz respeito à parameterização da curva e a partir daí cada ponto da curva é avaliado e onde  $I\chi$  corresponde a uma região local da imagem  $I$ . Nesta função da energia híbrida  $u_l$  e  $v_l$  dizem respeito às médias aritméticas dos vizinhos do ponto  $C(s)$  [31].

As médias locais são especificadas através de  $S_{I_l}(s)$ ,  $S_{E_l}(s)$ ,  $A_{I_l}(s)$  e de  $A_{E_l}(s)$  que dizem respeito à soma das intensidades locais interior e exterior da imagem, e à área da região interior e exterior [31].

$$u_l(s) = \frac{S_{I_l}(s)}{A_{I_l}(s)} \quad v_l(s) = \frac{S_{E_l}(s)}{A_{E_l}(s)} \quad (3.4)$$

$$S_{I_l}(s) = \int_{z \in \Omega} I\chi(x, s) dA \quad S_{E_l}(s) = \int_{z \in \bar{\Omega}} I\chi(x, s) dA \quad (3.5)$$

$$A_{I_l}(s) = \int_{z \in \Omega} I\chi(x, s) dA \quad A_{E_l}(s) = \int_{z \in \bar{\Omega}} I\chi(x, s) dA \quad (3.6)$$

A função  $\chi(x, s)$  retorna 1 quando um ponto  $x$  se encontra dentro do círculo  $B(C(s))$  centrada no ponto da curva especificada por  $s$ , retornando 0 caso contrário.

$$\chi(x, s) = \begin{cases} 1, x \in B(C(s)) \\ 0, \text{ caso contrário} \end{cases} \quad (3.7)$$

Em suma, este método combina as abordagens geodésica e de regiões no que aos contornos activos diz respeito, originando assim um método de segmentação que combina os benefícios dessas duas abordagens [31].

Tal como outros modelos geodésicos, esta abordagem é capaz de identificar soluções correctas localmente através de propriedades globais da imagem. Este método ao englobar igual-

mente a abordagem baseada em regiões, permite um aumento da robustez perante o ruído, reduzindo igualmente a dependência no que diz respeito à posição do contorno inicial [31].

Em contrapartida, este método apresenta alguns pontos negativos. Embora com uma menor dependência em relação à posição do contorno inicial em relação a outros métodos, a sua posição continua a ser importante, sendo necessário inicializar o contorno próximo do objecto a ser segmentado, caso contrário existe o risco de ocorrer uma segmentação incorrecta [31]. Em suma, este método não é ideal para todas as imagens, existindo casos onde é difícil distinguir a fronteira do objecto da restante imagem [31].




Figura 3.3: Evolução da segmentação de uma imagem do conjunto de dados utilizando a abordagem híbrida segundo Shawn Lankton.

### 3.1.2 Método de Contornos Activos segundo Chan e Vese

O método de contornos activos de Chan e Vese é um método poderoso e flexível que é capaz de segmentar inúmeros tipos de imagens, incluindo algumas que seriam difíceis de segmentar através de uma segmentação mais clássica, isto é, usando métodos baseados no limiar ou no gradiente [20].

Este modelo é baseado no método de segmentação Mumford-Shah. É um método usado largamente no campo das imagens médicas especialmente no que diz respeito à segmentação do cérebro, coração e traqueia sendo baseado na minimização de energia [20].




Figura 3.4: Diferença entre o método Chan Vese e um método mais clássico: a) Região segmentada usando o método Chan Vese b) A mesma região a ser segmentada por um método baseado no gradiente.  
<http://arxiv.org/ftp/arxiv/papers/1107/1107.2782.pdf>

### 3.1.2.1 Descrição do modelo

No modelo existe a região  $w$  que se encontra dentro contorno traçado por  $C$  e a região fora dessa mesma linha  $C$  que se caracteriza por  $\bar{\Omega}/w$ . Para além disso,  $c_1$  denota a intensidade média dos píxeis dentro da curva  $C$ ,  $c_2$  denota a intensidade média fora de  $C$ , assim  $c_1 = c_1(C)$ ,  $c_2 = c_2(C)$  [20]. O objectivo do algoritmo de Chan Vese é o de mimizar a função de energia  $F(c_1, c_2, C)$ , definida por,

$$\begin{aligned} F(c_1, c_2, C) &= \mu.Length(C) + v.Area(inside(C)) \\ &+ \lambda_1 \int_{inside(C)} |\mu_0(x, y) - c_1|^2 dx dy \\ &+ \lambda_2 \int_{outside(C)} |\mu_0(x, y) - c_2|^2 dx dy \end{aligned} \quad (3.8)$$

Onde  $\mu \geq 0, v \geq 0, \lambda_1, \lambda_2 > 0$  são parâmetros fixos definidos pelo utilizador. Assim pretende-se determinar os valores de  $c_1$ ,  $c_2$  e  $C$  que serão os valores óptimos e que servirão de solução para o problema de minimização

$$\inf_{c_1, c_2, C} F(c_1, c_2, C) \quad (3.9)$$

Um dos pontos fracos deste método é o facto de ser por vezes algo lento, especialmente quando se tratam de imagens de maiores dimensões. Este pode então ser um sério problema para aplicações em tempo real. Segundo alguns autores, este método necessita de um aperfeiçoamento no que diz respeito ao tempo de processamento [52]. No entanto uma das vantagens é a capacidade de detectar limites de objectos que são suaves e que seriam ignorados por outros métodos de segmentação. Outra vantagem é a robustez que apresenta perante imagens com ruído [20].




Figura 3.5: Evolução da segmentação de uma imagem do conjunto de dados utilizando a abordagem de Chan e Vese.

### 3.1.3 Método de Contornos Activos baseado em Regiões segundo Shawn Lankton

Este trata-se de um método de contornos activos desenvolvido por Shawn Lankton [36]. Implementa a ideia base inerente a todos os métodos de contornos activos, aplicando-a com base em regiões. Isto diz respeito ao facto de como em todos os restantes métodos de contornos activos, ser deformado um contorno de modo a existir uma minimização de energia afim de se obter a segmentação pretendida.

Esta abordagem segundo Shawn Lankton aplica uma técnica já utilizada no método híbrido desenvolvido pelo mesmo autor. Em vez de se considerarem as estatísticas globais da imagem,

são consideradas as estatísticas locais da mesma.

Esta abordagem é direccionada para imagens que possuem objectos com características heterógeneas, que seriam difíceis de segmentar usando uma abordagem de características globais. Esta técnica local é versátil o suficiente para poder ser usada juntamente com um método igualmente baseado em regiões mas tendo em conta estatísticas globais da imagem [36].

Em suma, este tipo de abordagem baseada em regiões, surgiu como uma tentativa de complementar os métodos de contornos activos em regiões, visto que são técnicas com resultados fracos quando os objectos e o *background* são heterogêneos, partilhando uma característica global próxima, levando a uma segmentação pouco precisa [36].

Esta abordagem leva à construção de uma família de energias locais em cada ponto da curva. De forma a otimizar estas energias locais, cada ponto é considerado de uma forma separada, movendo-se de forma a minimizar ou maximizar a energia na sua região local.

De forma a processar estas energias locais, os vizinhos de cada ponto são divididos em interiores ou exteriores locais. A energia de optimização é então determinada através de um modelo que engloba cada uma das regiões locais.




Figura 3.6: Análise das regiões locais em cada ponto da curva [36].

É descrita de seguida a forma como Shawn Lankton calcula a energia final do contorno. Sendo  $I$  uma dada imagem definida no domínio  $\Omega$ , onde  $C$  é um contorno fechado que é representado como sendo o nível zero de uma determinada função de distância  $\phi$ , isto é,  $C = x | \phi(x) = 0$ , o interior de  $C$  é especificado através da aproximação da seguinte função,

$$H\phi(x) = \begin{cases} 1, & \phi(x) < -\varepsilon \\ 0, & \phi(x) > \varepsilon \\ \frac{1}{2} \left\{ 1 + \frac{\phi}{\varepsilon} + \frac{1}{\pi} \sin \left( \frac{\pi\phi(x)}{\varepsilon} \right) \right\}, & \text{caso contrário} \end{cases} \quad (3.10)$$

De um modo semelhante o exterior do contorno  $C$  é definido por  $(1 - H\phi(x))$ . De modo a especificar a área em redor da curva será usada a derivada de  $H\phi(x)$ .

$$\delta\phi(x) = \begin{cases} 1, & \phi(x) = 0 \\ 0, & |\phi(x)| < \varepsilon \\ \frac{1}{2\varepsilon} \left\{ 1 + \cos \left( \frac{\pi\phi(x)}{\varepsilon} \right) \right\}, & \text{caso contrário} \end{cases} \quad (3.11)$$

É introduzida uma segunda variável espacial  $y$ . Cada uma das variáveis  $x$  e  $y$  representam cada uma um ponto único em  $\Omega$ . Assim obtem-se  $B(x,y)$  que representa as regiões locais. Esta função devolve 1 quando o ponto  $y$  se encontra dentro da circunferência de raio  $r$  centrada em

## Segmentação de Imagens Torácicas de Raio-X

$x$ , devolvendo 0 caso contrário, estando o conceito ilustrado na figura 3.6.

$$B(x, y) = \begin{cases} 1, & \|x - y\| < r \\ 0, & \text{caso contrário} \end{cases} \quad (3.12)$$

Assim, através de  $B(x, y)$  é possível definir a função energia deste método representada na equação 3.13, onde  $F$  representa uma medida interna de energia usada para representar a aderência local ao modelo em cada ponto do contorno.

$$E(\phi) = \int_{\Omega_x} \delta\phi(x) \int_{\Omega_y} B(x, y) \cdot F(I(y), \phi(y)) dy dx \quad (3.13)$$




Figura 3.7: Evolução da segmentação de uma imagem do conjunto de dados utilizando a abordagem de contornos activos baseados em regiões segundo Shawn Lankton.

## 3.2 Conjunto de Dados

Este capítulo é referente às imagens que foram utilizadas neste estudo. As imagens utilizadas foram retiradas de <http://www.isi.uu.nl/Research/Databases> e alguns exemplos encontram-se ilustrados na figura 3.8.




Figura 3.8: Exemplos de imagens do conjunto de dados.  
<http://www.isi.uu.nl/Research/Databases>

### 3.2.1 Propriedades do Conjunto

Neste estudo utilizou-se um total de 100 imagens torácicas de raio-x. Estas imagens diferem umas das outras em várias perspectivas: posição dos pulmões, tamanho do pulmão, contraste, foco e quantidade de informação visível. Cada uma das imagens tem a dimensão de 256x256 píxeis, encontrando-se no formato RGB.

Propriedades	Descrição
Número de Imagens	100
Altura	256 píxeis
Largura	256 píxeis
Extensão	jpg
Média de Intensidade	74,3247
Resolução	256x256 píxeis

Tabela 3.1: Propriedades das imagens.

### 3.2.2 Limitações do Conjunto de Dados

Foram sentidas diversas dificuldades na utilização destas imagens, dificuldades essas que tornam a sua segmentação um pouco mais difícil e com resultados de menor precisão.

1. Uma dificuldade encontrada trata-se do facto de existirem diversas imagens que contém secções a preto, secções essas que dificultam um pouco mais uma segmentação mais precisa e rigorosa por parte dos algoritmos utilizadas nessas imagens.




Figura 3.9: Limitações do conjunto de dados.

2. Existem diversas imagens em que os pulmões não se encontram bem identificados, isto é, imagens em que os contornos dos pulmões são pouco definidos. O facto de os contornos de diversos pulmões não se encontrarem bem delineados faz com que os métodos de segmentação tenham mais dificuldade em identificar o pulmão como sendo um objecto novo, evitando-se desse modo uma possível *over-segmentation* ou mesmo *under-segmentation*.

### 3.2.3 Estatísticas do Conjunto de Dados

Em termos estatísticos das imagens que compõem o conjunto de dados, é de salientar o facto da intensidade máxima ser de 255. Já no que diz respeito à intensidade mínima o valor é zero para

## Segmentação de Imagens Torácicas de Raio-X

cada um das respectivas 100 imagens. Na figura 3.10 encontram-se ilustradas outras estatísticas do conjunto de dados. É possível observar a mediana, a intensidade média e a entropia.

Em termos de mediana observa-se que o menor valor observado é de 174, atingindo o valor máximo de 200 na ultima imagem analisada, sendo que o conjunto de dados apresenta valores não muito dispares no conjunto das 100 imagens.

Em termos de média o menor valor não desce abaixo de 155 sendo que a imagem com média máxima atinge os 175. As primeiras 30 imagens são as que apresentam um média mais baixa, sendo que as últimas 15 do conjunto de dados atingem valores superiores às restantes.

Por fim em relação à entropia, as primeiras e as últimas imagens são as que apresentam valores mais elevados, sendo que as intermédias apresentam valores mais baixos como se pode constatar na figura 3.10.




Figura 3.10: Dados estatísticos do conjunto de dados: a) Mediana b) Intensidades médias c) Entropia.

### 3.3 Contorno Inicial

A fase inicial do trabalho consiste em identificar um conjunto de pontos-chave, que são identificados pelos algoritmos de segmentação. Nesta secção encontram-se identificados esses pontos que foram estabelecidos, a partir dos quais são definidas cada uma das máscaras que serviram de contornos iniciais em cada um dos três métodos base.

Ponto	Coluna	Linha
A	$L/2$	$\min(I(:, L/2)) \neq 0$
B	$L/4$	$\max(I(:, L/4)) > 140$
C	$3L/4$	$\max(I(:, 3L/4)) > 140$
D	$L/4$	$\min(I(:, L/4)) > 140$
E	$3L/4$	$\min(I(:, 3L/4)) > 140$
F	$L/2$	$C/2$
G	$\max(\text{sum}(I(C/2, 1 : 50)))$	$C/2$
H	$\max(\text{sum}(I(C/2, 206 : 256)))$	$C/2$
I	$\min(\text{sum}(I(C/2 : C/2 + 40, L/2 : 1 : L/2 + 50)))$	$\max(\text{sum}(I(C/2 : C/2 + 40, L/2 : 1 : L)))$
B'	$L/2$	$\min(\text{sum}(I(C/2 : C/2 + 15, L/2 : 1 : L/2 + 50)))$
C'	$3L/4$	$\min(\text{sum}(I(C/2) + 15 : C - 10, 1 : 1 : (L/2)))$
D'	$\min(I(\max(\text{sum}(I(1 : 50))), 5 : 1 : (L/2) - 10))$	$\max(\text{sum}(I(1 : 50, :)))$
E'	$\min(I(\max(\text{sum}(I(1 : 50, :))), (L/2) + 10 : 1 : 215))$	$\max(\text{sum}(I(1 : 50, :)))$
D''	$L/4$	$\max(\text{sum}(I(1 : 50, :)))$
E''	$3L/4$	$\max(\text{sum}(I(1 : 50, :)))$

Tabela 3.2: Coordenadas dos pontos utilizados na construção de cada uma das máscaras.  $L$  diz respeito à largura e  $C$  corresponde ao comprimento.

Na figura 3.11 encontram-se ilustrados os contornos iniciais que se implementaram para cada método e que resultam da união dos pontos-chave referidos. Estas imagens anatómicas não são uniformes e como tal é natural que estes contornos se adaptem de maneiras diferentes a cada uma delas.




Figura 3.11: Máscaras construídas que servem como contorno inicial dos métodos base.

### 3.4 Modelo Proposto

Nesta secção são referidos os passos que permitem a construção das árvores de decisão. Estas árvores resultam dos diferentes valores que se obtêm partindo da segmentação efectuada a cada uma das imagens do conjunto de dados por cada método base. As etapas seguintes, descrevem a forma de obtenção desses valores.

Em primeiro lugar é efectuado um *template matching* quer do pulmão direito quer do pulmão esquerdo. O *template matching* consiste em determinar o resultado médio que advém da sobreposição de cada um dos cem pulmões de ambos os lados. Assim cada imagem do conjunto de dados é recortada, resultando duas imagens, uma do pulmão direito e outra que diz respeito ao esquerdo. Assim das cem imagens que compõem o conjunto de dados, resultam cem pulmões

## Segmentação de Imagens Torácicas de Raio-X

direitos e cem esquerdos devidamente separados formando imagens separadas. Deste modo o *template matching* do pulmão direito, resulta da sobreposição de cada um dos cem pulmões direitos o mesmo acontecendo para o esquerdo, tal como ilustrado na figura 3.12.




Figura 3.12: Separação dos pulmões das imagens.

De seguida foi utilizado a operação de convolução. A convolução de duas funções é uma importante operação matemática em qualquer sistema de processamento de sinal. Em computação gráfica e processamento de imagem, normalmente são utilizadas funções discretas, ou seja, imagens e aplica-se uma função discreta de forma a obter-se informações acerca da imagem entre as quais o domínio da frequência da imagem. Sendo que a convolução é também muito utilizada no pré-processamento de imagem, na aplicação de filtros de remoção de ruído, bem como nos operadores que permitem a detecção de arestas.

Neste caso específico, a convolução é calculada utilizando-se o resultado de cada imagem segmentada por cada um dos 3 métodos base e a imagem que advém do *template matching*. Estes valores da convolução serão utilizados no fim para a construção de cada árvore.

Seguidamente foram determinadas mais características de cada um dos pulmões em separado. Tornou-se necessário analisar os pulmões, tendo a certeza de que estes se encontram bem segmentados. Na figura 3.14 é possível verificar a diferença entre pulmões bem segmentados e mal segmentados.



Figura 3.13: Eficiência da separação dos pulmões: a) Pulmões bem segmentados b) Pulmões mal segmentados.

Caso a segmentação seja defeituosa é necessário efectuar a sua separação como se pode verificar na figura 3.15. É efectuada uma projecção da imagem de modo a determinar-se a

coluna mais susceptível de dividir os pulmões. Esta divisão é necessária porque as árvores de decisão são contruídas de modo a avaliar cada pulmão separadamente. Caso os pulmões se encontrem bem segmentados a projecção resultante permite verificar o ponto de divisão não existindo qualquer dúvida. Caso contrário a projecção devolvida necessita de um filtro gaussiano de modo a perceber-se o ponto de divisão dos dois pulmões.




Figura 3.14: Divisão dos pulmões: A verde encontra-se a projecção vertical de uma imagem com pulmões bem segmentados. Nos casos em que a segmentação resulte em pulmões mal separados, a linha do gráfico encontra-se a vermelho após a projecção da imagem, sendo necessário a aplicação de um filtro gaussiano de suavização da curva de modo a detectar-se o ponto susceptível de divisão.

Após os pulmões se encontrarem separados são calculados os descritores angulares e elípticos de Fourier de cada um deles. Os descritores de Fourier, possibilitam obter a descrição da forma do objecto em causa. A ideia principal é a de caracterizar um determinado contorno através de um conjunto de valores de frequência de toda a forma. Com base nesta análise de frequência, torna-se possível obter um conjunto de valores que possam descrever a forma do objecto [60], em suma, a forma dos objectos é uma das características mais importantes em termos de imagem. Os descritores de Fourier são uma das várias técnicas para descrever essas formas [22].

Estes valores obtidos serão posteriormente utilizados na obtenção de padrões para construção das árvores de decisão, através das quais será possível a extracção dos valores que dão origem ao modelo proposto.

Outras características adicionais referentes à região de cada pulmão que foram extraídas são: a área da região, o número de Euler, a extensão, o perímetro, o centroide, a intensidade máxima, a intensidade mínima, a orientação, a intensidade mínima, localização dos píxeis que pertencem a essa região e os valores de cada um dos píxeis.




Figura 3.15: Critério subjectivo de indicação de um pulmão como sendo bem segmentado: Quanto maior a percentagem de região de interesse bem segmentada, independentemente da over-segmentation associada que se encontra a azul. Os pulmões são indicados como bem segmentados quanto maior for a área verde.




Figura 3.16: Critério subjectivo de indicação de um pulmão como sendo mal segmentado: Os pulmões são indicados pelo autor como mal segmentados quando a área a vermelho é maior indicando falha de segmentação alta.

Após as características todas reunidas e os dados recolhidos todos normalizados através da normalização *minmax*, efectua-se uma análise pessoal e portanto subjectiva onde se refere os pulmões que se consideram bem e os que se consideram mal segmentados, o que servirá como as folhas da árvore de decisão, podendo-se ver exemplos dessa atribuição na figura 3.16 e na figura 3.15. São extraídos então padrões através de todas as características determinadas e o estado (Bem/Mal segmentado) atribuído a cada pulmão.

### 3.4.1 Construção do Modelo

Posteriormente constrói-se um modelo em que partindo dos três métodos base consiga diminuir a percentagem de erro da região de interesse. No fundo, pretende-se um modelo que consiga extrair o que de melhor tem cada um dos métodos base. Para isso foram efectuadas dez experiências. Em cada experiência foram utilizadas oitenta imagens para a construção da árvore de decisão, efectuando-se o seu treino e obtenção de padrões, e vinte imagens para

a avaliação da mesma, sendo que em cada experiência as imagens são diferentes e obtidas de forma totalmente aleatória.

Em cada experiência iremos obter três árvores de decisão distintas, uma para cada método estudado, e serão estas que indicaram se cada pulmão se encontra bem ou mal segmentado, como se pode ver no exemplo da figura 3.17.

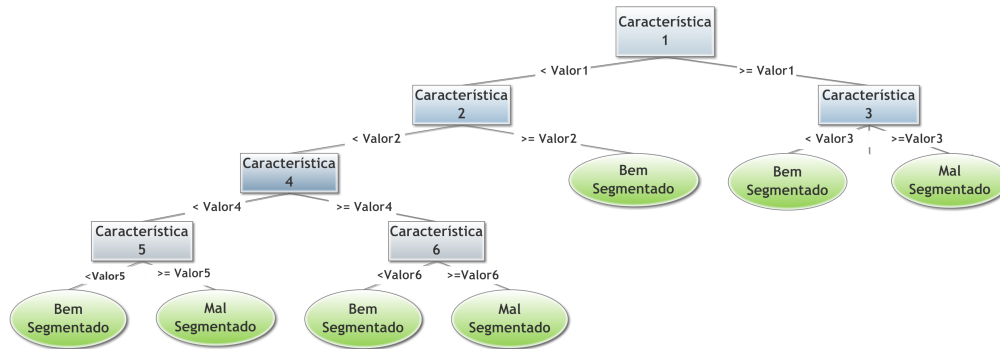


Figura 3.17: Exemplo de uma árvore de decisão utilizada na avaliação de cada método. Cada pulmão avaliado irá percorrer a árvore sendo o seu resultado bem ou mal segmentado dependendo da forma como as suas características se encaixem nos padrões da árvore.

Cada árvore de decisão foi construída segundo o modelo descrito em [7].

Na fase de avaliação, as vinte imagens são divididas de modo a avaliar os pulmões de cada uma de um modo separado, sendo que cada árvore de decisão irá classificar se o pulmão como bem ou mal segmentado. Em cada experiência são analisados os resultados obtidos para cada pulmão em termos da confiabilidade do seu resultado juntamente com o erro de segmentação que cada um tem em termos da ROI. Em cada pulmão o modelo do autor é composto pela margem de erro do método que lhe atribuí maior confiabilidade, como se pode constatar na tabela 3.3. A confiabilidade que se atribui a cada um é obtida através da soma de cada probabilidade de cada nodo por onde a imagem passa na árvore, dividindo-se esse valor pelo número de nodos pelos quais se passou, sendo que cada nodo contém uma probabilidade para mal segmentado e outra caso seja bem segmentado.

Em suma, serão avaliados os pulmões de um modo separado, obtendo-se assim resultados que possam demonstrar se o modelo do autor revela melhorias em relação aos restantes modelos em estudo.

Na tabela 3.3 é possível verificar a forma de obtenção dos valores que irão compor o modelo proposto. A tabela ilustra o resultado de uma experiência onde vinte imagens são avaliadas por cada árvore que resulta de cada método. Cada método indica se um pulmão se encontra bem ou mal segmentado. As células a vermelho indicam que o pulmão foi mal segmentado, indicando-se que foi bem segmentado caso a célula se encontre a verde. Cada célula contém um valor que é a confiabilidade atribuída ao resultado.

## Segmentação de Imagens Torácicas de Raio-X

Imagem	CH(Conf)	Erro	SH(Conf)	Erro	SRGB(Conf)	Erro	Mod. Proposto
1	0,861275	0,2353	0,4992	0,377	0,8463	0,2754	0,377
2	0,861275	0,2493	0,3766	0,2282	0,8463	0,3064	0,2282
3	0,3853	0,1486	0,3766	0,2145	0,8463	0,2355	0,1486
4	0,861275	0,2849	0,4992	0,4497	0,8463	0,4194	0,4497
5	0,861275	0,1599	0,2596	0,2035	0,8463	0,2105	0,2035
6	0,861275	0,1389	0,3766	0,2486	0,8463	0,2119	0,2486
7	0,861275	0,3176	0,3766	0,2628	0,8463	0,3794	0,2628
8	0,861275	0,1146	0,3766	0,2098	0,8089	0,1434	0,1434
9	0,3853	0,1921	0,5417	0,2954	0,8463	0,236	0,1921
10	0,3853	0,1898	0,3766	0,1781	0,8463	0,2525	0,1898
11	0,861275	0,1364	0,4992	0,2592	0,8463	0,2062	0,2592
12	0,861275	0,2156	0,3766	0,3189	0,8463	0,2824	0,3189
13	0,861275	0,1532	0,5707	0,369	0,7972	0,194	0,194
14	0,861275	0,2063	0,3766	0,242	0,8463	0,3159	0,242
15	0,861275	0,3103	0,7656	0,424	0,8463	0,3727	0,424
16	0,861275	0,7381	0,3766	0,1908	0,8463	0,5157	0,1908
17	0,861275	0,1976	0,3766	0,2586	0,8463	0,2758	0,2586
18	0,861275	0,5448	0,3766	0,217	0,8463	0,4895	0,217
19	0,861275	0,2869	0,7656	0,2888	0,8463	0,4593	0,2888
20	0,861275	0,2699	0,3766	0,2486	0,8463	0,3576	0,2486
<b>Média</b>		<b>0,254905</b>		<b>0,274225</b>		<b>0,306975</b>	<b>0,25428</b>

Tabela 3.3: Obtenção dos valores que constituem o modelo proposto. A coluna CH(Conf) diz respeito à avaliação de cada imagem através do método de Chan e Vese. A coluna SH(Conf) refere-se ao resultado da avaliação de cada imagem por parte do método híbrido de Shawn Lankton. A SRGB(Conf) refere-se igualmente ao resultado da avaliação por parte do método baseado em regiões segundo Shawn Lankton. As colunas referentes ao erro contém os valores de erro de segmentação da região de interesse em cada imagem. A coluna Mod. Proposto contém os valores que compõem a proposta do autor na dada experiência.

Quanto maior o valor, maior a confiança atribuída a esse resultado. O valor extraído é sempre aquele que se aproxima de uma boa segmentação do pulmão. A coluna respeitante ao erro indica a percentagem de falha de segmentação da ROI, ou seja, do respectivo pulmão. Assim para se extrair os valores do modelo, escolhe-se o valor de erro do pulmão com melhor confiabilidade de segmentação de entre os três. Se nos três métodos se encontra bem segmentado, escolhe-se o que tiver maior confiabilidade. Caso se encontre mal segmentado segundo os três métodos em simultâneo, escolhe-se o que possuir pior confiabilidade, indicando ser o que se encontra mais perto de estar bem segmentado de entre os três.

### 3.5 Estatísticas de Precisão

Um dos critérios de avaliação de um dado método de segmentação trata-se da sua precisão, ou seja, a capacidade de segmentar apenas e só os objectos que se pretende. Assim, quanto maior for a taxa de precisão de um dado método, melhor para esse método em termos da sua credibilidade. Caso um método segmente mais do que seria desejável diz-se que estamos na presença de *over-segmentation*. Caso não seja segmentado o objecto na sua totalidade diz-se que se está na presença de *under-segmentation*, o que também é negativo, visto que se não encontramos a totalidade dos dados, a análise e classificação não serão tão exactas como desejado.

Por forma a avaliar o desempenho dos métodos automáticos, foi necessário obter dados *ground truth*. Estes resultam da segmentação manual das imagens, e da segmentação que resulta de cada método.

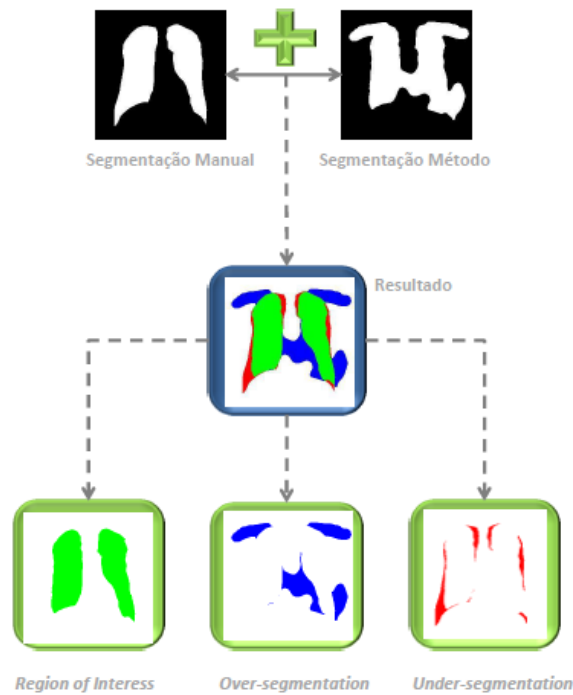


Figura 3.18: Extração dos valores de precisão utilizando cada uma das 10 máscaras por parte de cada método base.

A segmentação manual é efectuada pelo autor, sendo que através dela se pretende representar a segmentação considerada óptima em cada caso do conjunto de dados.

Os resultados de cada método foram avaliados a partir de dez máscaras que definem regiões de interesse, definidas pelo autor e que serviram em cada método como o seu contorno inicial que se ajustará aos pulmões, visto que estes três métodos são baseados na abordagem de contornos activos.

Tendo as duas segmentações para cada imagem do conjunto de dados efectua-se o seu somatório, resultando daí uma terceira imagem. Posteriormente, partindo dessa imagem que resulta do somatório são extraídos os valores de precisão através dos quais os métodos serão avaliados. Este processo encontra-se ilustrado na figura 3.18

De seguida são extraídos três resultados estatísticos: a precisão em termos de ROI, a *accuracy* da imagem, bem como a *over-segmentation* registada. A ROI será a taxa que resulta dos píxeis que correspondem à segmentação manual e àquela que resulta de cada método.

$$ROI = \frac{\text{Píxeis} \in (\text{Seg. Manual} \cap \text{Seg. Metodo})}{256 \times 256} \quad (3.14)$$

Os falsos positivos ou *over-segmentation* é a taxa que resulta dos píxeis que apenas pertencem à segmentação do método não fazendo parte da segmentação manual. Por fim a *accuracy*

## Segmentação de Imagens Torácicas de Raio-X

diz respeito à precisão global da imagem.

$$TN = \frac{\text{Píxeis } \in \text{ Seg. Metodo}}{256 \times 256} \quad (3.15)$$

A *accuracy* é calculada por meio da soma da totalidade dos píxeis que pertencem às duas segmentações com a totalidade dos píxeis que não pertencem a nenhuma das duas, sendo este resultado dividido pela totalidade dos píxeis da imagem.

$$\text{Accuracy} = \frac{(\text{Píxeis } \in (\text{Seg. Manual e Seg. Metodo})) + (\text{Píxeis } \notin (\text{Seg. Manual e Seg. Metodo}))}{256 \times 256} \quad (3.16)$$

Esta análise é efectuada em duas fases. Numa primeira fase são obtidos os resultados de segmentação de cada método base utilizando cada uma das máscaras criadas como contorno inicial do método sobre cada uma das imagens que compõem o conjunto de dados sem qualquer tipo de manipulação prévia.

Numa segunda fase são aplicados os mesmos métodos com cada um dos dez contornos iniciais às mesmas imagens, sendo que essas imagens já foram previamente pré-processadas. De modo a ser possível verificar o seu comportamento sem aplicação e com aplicação de operações de pré-processamento .

### 3.6 Pré-Processamento

Após a segmentação sem qualquer tipo de pré-processamento, é feito posteriormente o pré-processamento descrito nesta secção de modo a verificarem-se os eventuais benefícios que resultam deste tipo de operação.

A etapa de pré-processamento é composta por dois passos: o primeiro diz respeito à remoção do ruído existente na imagem.

Esta remoção de ruído tem como objectivo eliminar informação desnecessária da imagem, capaz de conduzir o método em questão a uma segmentação incorrecta. Após a remoção do ruído é aplicado um filtro designado de *unsharp*, filtro este que tem como objectivo o aumento do contraste da imagem mais precisamente os seus contornos, de modo a tentar-se uma melhor definição dos limites dos pulmões de cada imagem de modo a serem mais fáceis de detectar por cada um dos métodos. É possível observar as diferenças que o pré-processamento permite numa imagem através do exemplo das figuras 3.19, 3.20 e 3.21, onde se encontra uma imagem sem pré-processamento e a mesma imagem com o pré-processamento descrito. Na figura 3.19 observa-se a diferença na mancha abaixo do pulmão direito, encontra-se mais nítida depois de removido o ruído. Em todos os exemplos é possível verificar um aumento da nitidez dos pulmões, bem como uma melhor definição dos mesmos e inclusivamente das costelas.

## Segmentação de Imagens Torácicas de Raio-X




Figura 3.19: Aplicação de pré-processamento: a) Imagem sem pré-processamento b) Imagem com pré-processamento.





Figura 3.20: Aplicação de pré-processamento: a) Imagem sem pré-processamento b) Imagem com pré-processamento.



56 Figura 3.21: Aplicação de pré-processamento: a) Imagem sem pré-processamento b) Imagem com pré-processamento.

## Segmentação de Imagens Torácicas de Raio-X

Com este melhoramento os métodos de segmentação têm uma maior capacidade de detectar os objectos de interesse, não sendo desta forma tão fortemente afectados por informação inútil, informação essa que nos casos dos métodos baseados em regiões, conduz à detecção de mínimos locais o que origina regiões inexistentes, levando a uma segmentação errada.



# Capítulo 4

## Resultados e Discussão

Neste capítulo descrevem-se os resultados obtidos com cada um dos métodos base de segmentação e comparam-se estes com o método baseado em árvores de decisão proposto neste documento.

### 4.1 Resultados da Precisão dos Métodos Base

No método híbrido desenvolvido por Shawn Lankton, o que se pode constatar através da figura 4.1 é que tem um comportamento praticamente igual quer com ou sem técnicas de pré-processamento.

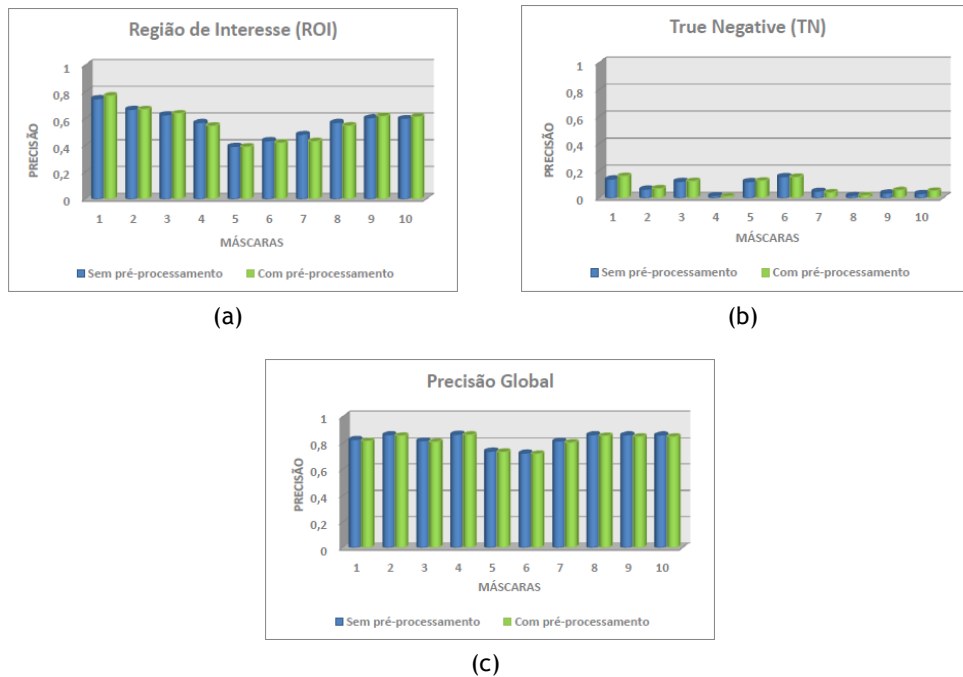


Figura 4.1: Resultados da abordagem híbrida segundo Shawn Lankton com e sem pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* c) Resultados da *accuracy*.

Verifica-se um melhor comportamento em termos da região de interesse (ROI) ao utilizar-se a máscara 1, enquanto as máscaras 5 e 6 apresentam os piores resultados. As máscaras 5 e 6 apresentam igualmente maus resultados no que à *over-segmentation* (TN) diz respeito, bem como na *accuracy* da imagem no seu todo. Conclui-se que estas duas máscaras são as piores para este método. Por outro lado apesar de não apresentar dos melhores resultados em relação à ROI a máscara 4 possui uma *over-segmentation* praticamente nula e apresenta os melhores resultados em termos da *accuracy*, concluindo-se ser a melhor máscara de entre as 10 utilizadas.

Como se pode verificar através da figura 4.2 o método desenvolvido por Chan e Vese, tal como acontece com o método híbrido de Shawn Lankton, apresenta um comportamento seme-

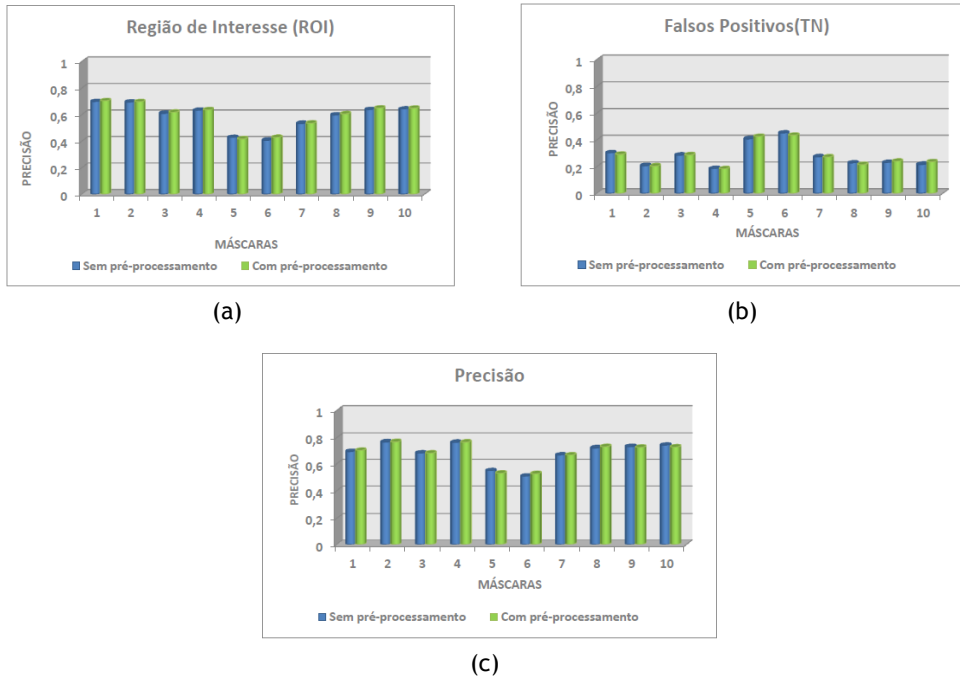


Figura 4.2: Resultados da abordagem segundo Chan e Vese com e sem pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* com e sem pré-processamento c) Resultados da *accuracy*.

lhante em cada uma das máscaras quer com ou sem pré-processamento. Igualmente como o método anterior as máscaras 5 e 6 são as piores, em todos os parâmetros, ROI, TN e na *accuracy* da imagem. Conclui-se portanto que a melhor máscara será a segunda, visto que tem os segundos melhores valores em termos da ROI, o mesmo acontecendo na *over-segmentation*, sendo a melhor máscara em termos de *accuracy*.

A 4.3 tal como os métodos anteriores permite concluir que, o método baseado em regiões segundo Shawn Lankton apresenta um comportamento similar com ou sem pré-processamento em termos da ROI. Em termos da *over-segmentation* apresenta melhorias em algumas máscaras após aplicação do pré-processamento. No entanto é na *accuracy* que se nota a grande diferença. Com a aplicação do pré-processamento nas imagens, este método apresenta melhorias significativas em todas as máscaras utilizadas como se pode constatar na figura referida.

Na figura 4.4 ilustram-se os resultados da comparação entre o método híbrido e o método baseado em regiões sem aplicação de qualquer pré-processamento.

No parâmetro da ROI os dois métodos mostram um comportamento similar, verificando uma melhor performance ainda que ligeira por parte do método baseado em regiões. Já no que diz respeito à *over-segmentation* verifica-se um pior desempenho em todas as máscaras por parte do método baseado em regiões. O facto do método híbrido apresentar uma menor TN, resulta do facto de englobar igualmente uma abordagem geodésica que detecta o gradiente em cada ponto do objecto por onde passa a curva, não sendo assim detectados pontos adicionais insignificantes. No entanto é necessário que a curva se encontre próxima do objecto a segmentar, de modo a não serem detectados pontos adicionais. Em suma quando não foi aplicado qualquer pré-processamento o método híbrido teve um melhor comportamento do que o método baseado em regiões.

## Segmentação de Imagens Torácicas de Raio-X

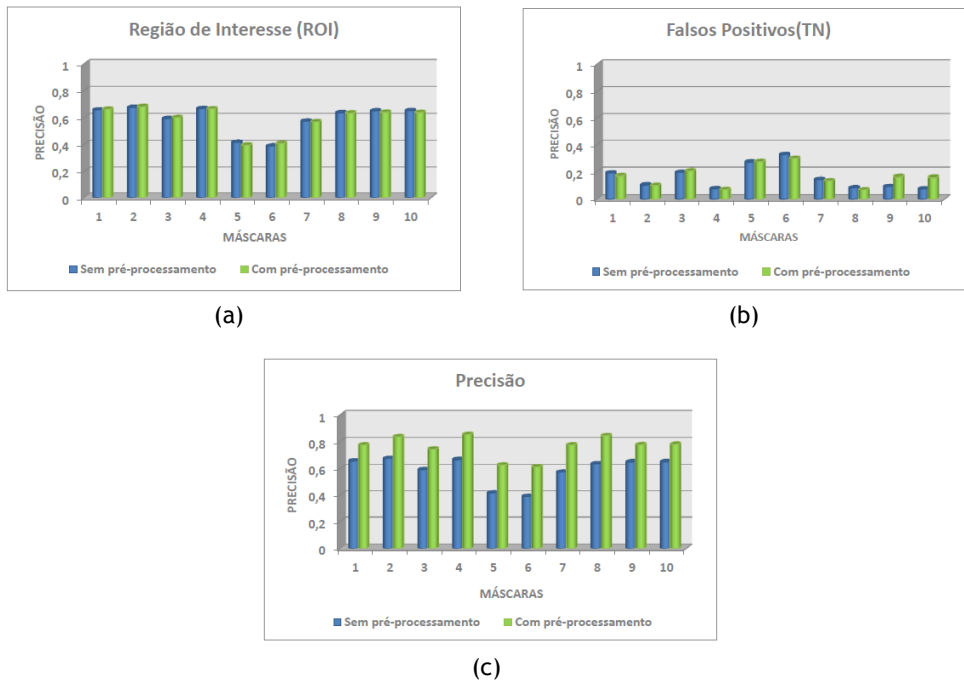


Figura 4.3: Resultados da abordagem baseada em regiões segundo Shawn Lankton com e sem pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* c) Resultados da *accuracy*.

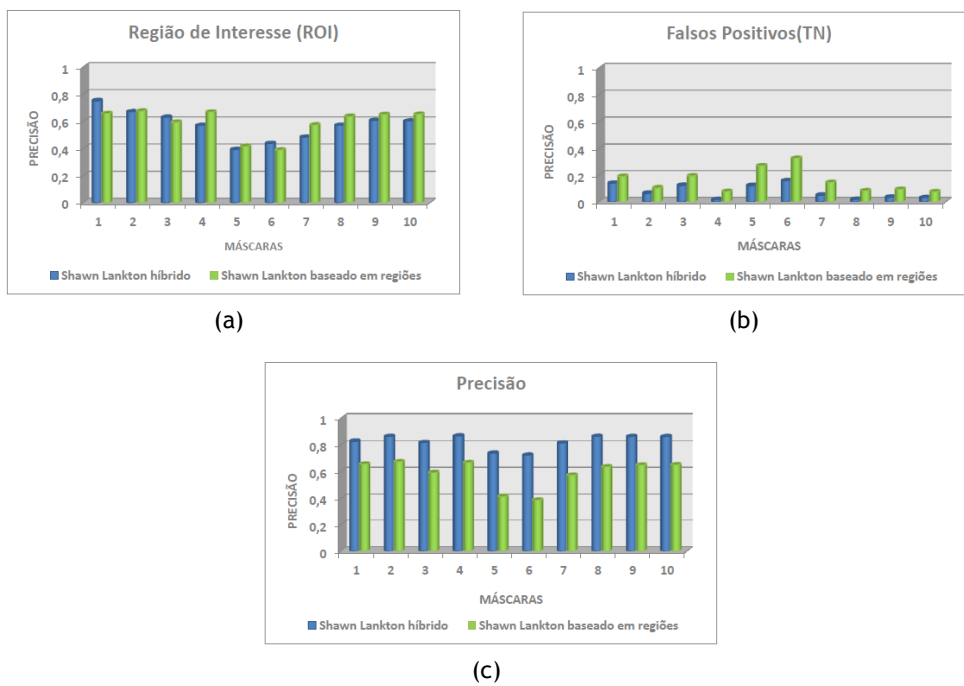


Figura 4.4: Resultados da abordagens híbrida e baseada em regiões segundo Shawn Lankton sem pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* c) Resultados da *accuracy*.

O método híbrido ao englobar um método baseado em regiões torna-se mais robusto ao ruído. No entanto o facto de ter em consideração estatísticas globais da imagem seria o suficiente para obter piores resultados do que o método baseado em regiões que considera estatísticas locais. No entanto o facto de ser complementado com um outro método resulta em melhores resultados.

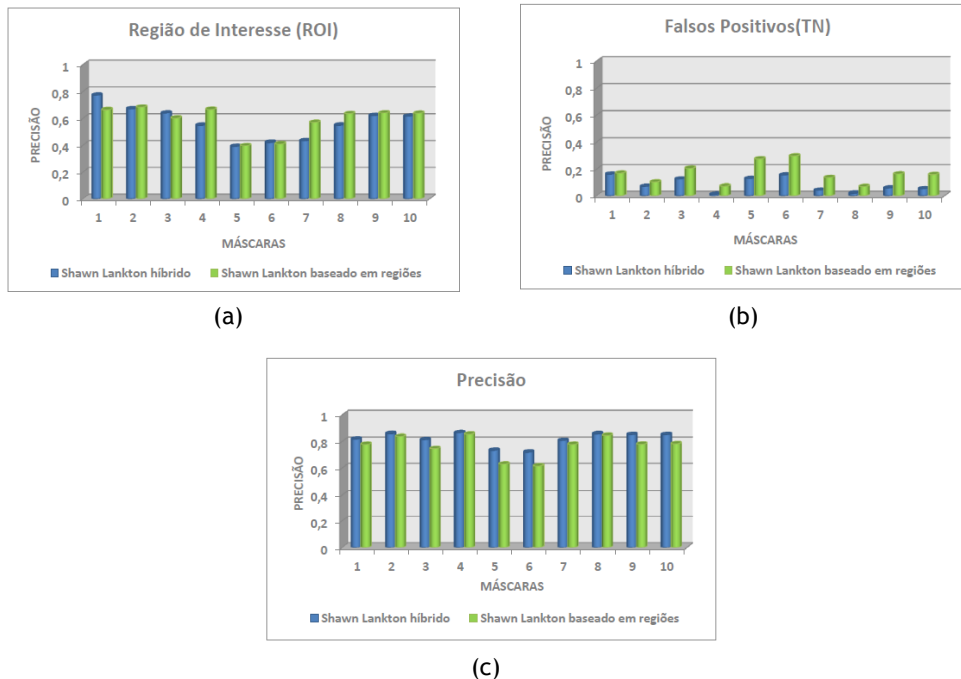


Figura 4.5: Resultados da abordagem híbrida e baseada em regiões com pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* c) Resultados da *accuracy*.

Conclui-se a partir da figura 4.5 que o comportamento dos dois métodos com pré-processamento é semelhante sem ele. No entanto existe uma melhoria e consequente aproximação do método baseado em regiões ao método híbrido no que à *accuracy* diz respeito, tendo em conta o comportamento verificado nos dois métodos sem pré-processamento. Esta melhoria do método apenas baseado em regiões deve-se ao facto do pré-processamento ter permitido melhorar as estatísticas a nível local, verificando igualmente melhorias ao nível da TN. Já o método híbrido ao tratar-se de um método robusto ao ruído e baseado na análise das características globais não apresenta melhorias significativas.

Na comparação dos três métodos sem aplicação de pré-processamento verifica-se que o Chan Vese é o que apresenta maior *over-segmentation* sendo seguido pelo método baseado em regiões e onde o método híbrido apresenta melhores valores neste campo. Em termos da ROI o comportamento é semelhante entre os três.

No entanto é na *accuracy* que se nota a maior diferença. Neste parâmetro o método híbrido apresenta os melhores resultados em todas as máscaras sendo que o método baseado em regiões apresenta os piores de entre os três.

Como se pode constatar através da figura 4.7, o pré-processamento melhora os resultados das características locais, o que permite um aumento substancial do método baseado em regiões em relação aos restantes. De igual modo, tanto com ou sem pré-processamento aquele que apresenta melhores resultados é o método híbrido, isto porque engloba uma abordagem geodésica que detecta o gradiente do objecto a segmentar em cada ponto da curva servindo

## Segmentação de Imagens Torácicas de Raio-X

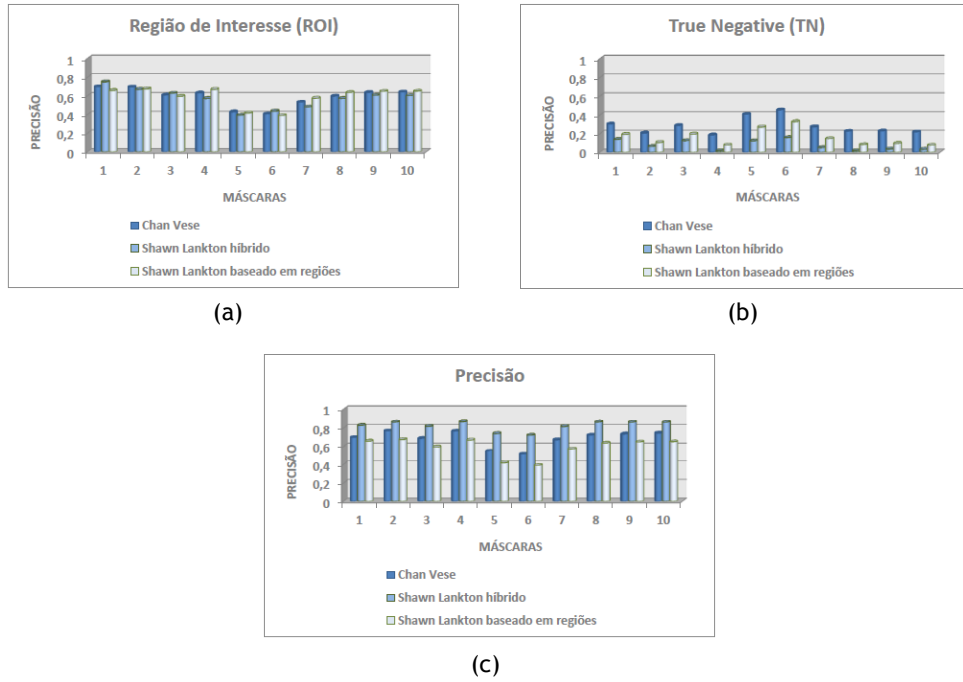


Figura 4.6: Resultados dos três métodos base sem pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* c) Resultados da *accuracy*.

como critério de paragem sendo assim evitada uma segmentação desnecessária.

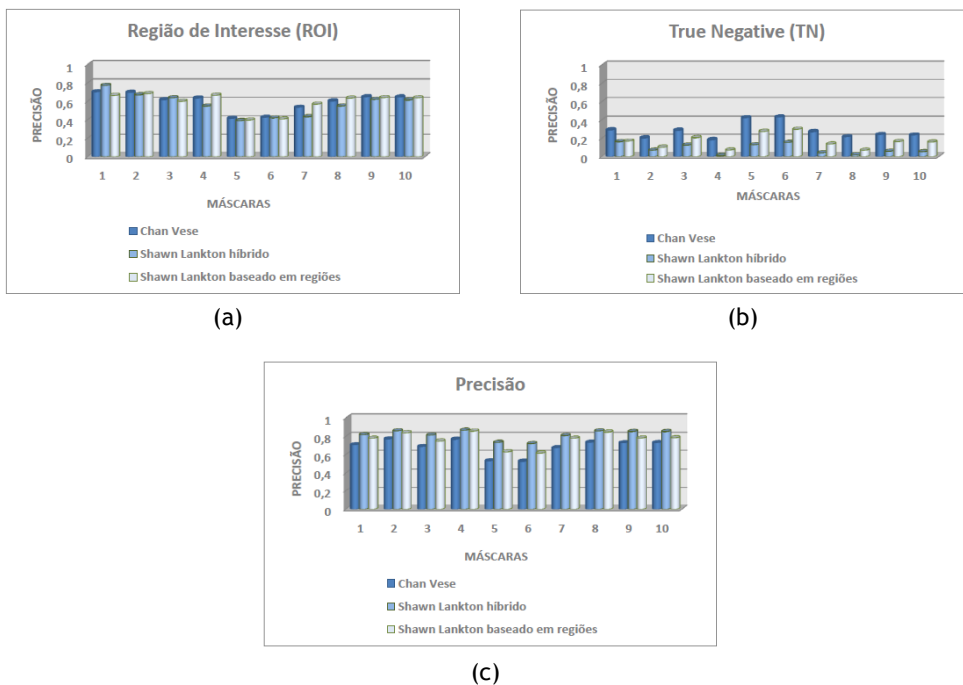


Figura 4.7: Resultados dos três métodos base com pré-processamento: a) Resultados da ROI b) Resultados da *over-segmentation* c) Resultados da *accuracy*.

## 4.2 Resultados das Árvores de Decisão

### 4.2.1 Resultados dos Métodos Base

Após as 10 experiências efectuadas a cada um dos três métodos no que ao pulmão esquerdo diz respeito sendo avaliados 20 pulmões esquerdos em cada experiência, o método híbrido segundo Shawn Lankton (SH) é o método que apresenta uma melhor média de pulmões bem segmentados, com uma taxa de 63.02%, sendo igualmente o método que apresenta uma menor média de pulmões mal segmentados. Assim concluí-se que em termos de pulmão esquerdo este é o método que revela melhor comportamento como se constata na tabela 4.1.

Métodos	Bem Seg. (Pulmões)	Confiança (%)	Mal Seg. (Pulmões)	Confiança (%)
CV	7,3	62,48%	12,7	77,85%
SH	8	63,02%	12	57,66%
SRB	5,5	73,34%	14,5	79,05%

Tabela 4.1: Fiabilidade de segmentação de cada método base em relação ao pulmão esquerdo. A coluna Bem Seg. contém as médias de pulmões bem segmentados no total das dez experiências para cada método. A coluna Mal Seg. contém a média de pulmões mal segmentados. A coluna da confiança contém as taxas de confiança do resultado obtido.

Em relação ao pulmão direito o método SH apresenta igualmente uma melhor performance. No entanto neste caso o método segundo Chan e Vese tem uma média de pulmões bem e mal segmentados muito próxima do método SH tendo inclusive uma confiança de resultado maior por uma larga margem.

Em suma, em termos do pulmão esquerdo o método híbrido apresenta melhores resultados. No que ao pulmão direito diz respeito aquele que apresenta melhor performance é o CV

Métodos	Bem Seg. (Pulmões)	Confiança (%)	Mal Seg. (Pulmões)	Confiança (%)
CV	6,9	71,51%	13,1	86,12%
SH	7,1	67,48%	12,9	52,28%
SRB	5,6	69,60%	14,4	73,77%

Tabela 4.2: Fiabilidade de segmentação de cada método base em relação ao pulmão direito. A coluna Bem Seg. contém as médias de pulmões bem segmentados no total das dez experiências para cada método. A coluna Mal Seg. contém a média de pulmões mal segmentados. A coluna da confiança contém as taxas de confiança do resultado obtido.

### 4.2.2 Resultados do Método Proposto

#### 4.2.2.1 Índices de Correlação

Na figura 4.8 encontra-se ilustrada a correlação que existe entre os resultados dos métodos, incluindo o modelo proposto em relação ao pulmão direito. Esta figura permite ilustrar o nível de semelhança que existe entre cada par de métodos.

Quanto mais próximo o valor de correlação se encontra de 1, maior é o nível de semelhança, sendo que a cor da célula respectiva tende para branco. Assim é natural que a diagonal seja preenchida com o valor 1, visto que diz respeito à correlação de cada método com ele próprio.

Pode-se verificar uma grande semelhança em termos de observações entre os métodos SRB (método baseado em regiões segundo Shawn Lankton) e o método CV (segundo Chan e Vese), com um valor de correlação de 0.9749.

## Segmentação de Imagens Torácicas de Raio-X




Figura 4.8: Resultados de correlação dos métodos em relação ao pulmão direito.

Regista-se uma correlação fraca em três pares de métodos. Obtém-se o valor 0.1548 em termos de correlação do modelo proposto pelo autor e o método híbrido segundo Shawn Lankton (SH). Uma correlação ainda mais fraca verifica-se entre o método SRB e SH, que são curiosamente dois métodos do mesmo autor, registando-se o valor de 0.0965. No entanto a correlação mais baixa regista-se entre o método SH e o método CV, sendo praticamente nula a relação de semelhança que existe entre os dois. Conclui-se igualmente que o modelo proposto pelo autor regista um nível de semelhança razoável com o método CV onde regista um valor de 0,5864 e com o método SRB onde regista um valor de 0,4980. Conclui-se portanto que o modelo proposto, ao longo da sua construção, recolhe um maior número de observações do método CV seguindo-se o SRB, sendo que recolhe poucas observações do método SH como se observa pelo valor de correlação entre ambos.

Na figura 4.9 encontra-se ilustrada a correlação existente entre os métodos no que ao pulmão esquerdo diz respeito.




Figura 4.9: Resultados de correlação dos métodos em relação ao pulmão esquerdo.

Na diagonal, como é natural encontram-se os valores resultantes da correlação de cada um dos métodos com ele próprio, registando-se o valor 1. Visto que cada método é igual a ele próprio.

Tal como aconteceu anteriormente para o pulmão direito, regista-se uma grande semelhança de observações entre o método SRB e CV, verificando-se o valor 0,9533.

Em termos de correlações mais fracas temos o método SH correlacionado com CV, onde se regista uma correlação negativa de -0,2392, existindo no entanto uma correlação ainda mais fraca entre SRB e SH onde se regista o valor de -0,1272.

Em termos de modelo proposto pelo autor, pode-se concluir que a sua construção resultou de um conjunto de observações repartidas pelos três métodos base. Regista uma correlação um pouco mais fraca com o método SH onde regista um valor de 0,4267. Em relação aos outros dois métodos, o modelo proposto regista um índice de semelhança praticamente igual para o CV e o SRB onde regista 0,6903 e 0,6971 respectivamente.

Em suma em termos de observações o modelo proposto regista uma maior utilização dos métodos CV e SRB na sua construção.

#### 4.2.2.2 Percentagem de Erro

No que ao pulmão esquerdo diz respeito, pode-se concluir que o modelo proposto apresenta resultados substancialmente melhores em termos de menores percentagens de erro como se ilustra na figura 4.10.




Figura 4.10: Resultados do modelo proposto em relação ao pulmão esquerdo.

A média dos valores do modelo proposto é a menor entre todos os modelos, com o valor de 0.2385 de erro. Em relação ao método SH obtém-se uma melhoria de 1,5%. Em relação à média de valores do método SRB obtém-se uma redução de erro de 9,9%, obtendo igualmente uma melhoria de 3,5% em relação ao método CV. Através da figura 4.10, observa-se ainda que a maior observação do modelo do autor no valor de 0,2548 é praticamente igual à primeira média de valores do método que mais se aproxima que é o método SH, sendo de 0,25303.

Para além destes resultados observa-se ainda uma boa consistência do modelo, isto é, o modelo apresenta um intervalo curto de observações, não apresentando uma grande disparidade de valores, o mesmo já não acontece com o método CV e SRB que apresentam grandes

## Segmentação de Imagens Torácicas de Raio-X

disparidades de observações. No CV o intervalo vai de 0,2545 até 0,3596 enquanto no SRB vai de 0,2888 até 0,3818.

É necessário referir ainda a boa performance apresentada pelo método SH, onde para além de obter a segunda média de observações mais baixa, apresenta também a melhor consistência de resultados, com uma reduzida disparidade que vai de 0,2457 até 0,2596

Por fim verifica-se igualmente que o método que apresenta observações de erro mais elevadas é o método segundo Shawn Lankton baseado em regiões.




Figura 4.11: Resultados do modelo proposto em relação ao pulmão direito.

No que ao pulmão direito diz respeito o modelo proposto regista novamente uma melhor performance com uma média de valor de 0,20204, sendo um valor ainda mais baixo do que aquele que se regista pelo mesmo modelo no pulmão esquerdo. No entanto neste caso a disparidade de observações é maior, verificando-se um intervalo de 0,1923 até 0,2638 como se verifica na figura 4.11.

A primeira média que se aproxima do modelo proposto é a do método SH com o valor de 0,2494 sendo registada uma melhoria de 5,7. Este método SH que é aquele que mais se aproxima do modelo do autor obteve a menor média de observação com o valor de 0,2094, sendo um valor ainda assim superior à media de valores do modelo proposto.

Em relação aos restantes métodos base o modelo proposto regista uma melhoria de 11,1% em relação à média do modelo SRB e uma melhoria de 6,8% em relação ao modelo CV.

é necessário referir que tal como acontece no pulmão esquerdo o modelo SH regista uma boa consistência de observações com uma curta disparidade de valores, sendo igualmente o método SRB que apresenta valores observados mais elevados.

Por fim como é possível verificar-se através da figura 4.12, todos os métodos incluindo o modelo proposto pelo autor obtém uma melhor performance de observações no pulmão direito do que no pulmão esquerdo. Retira-se esta conclusão devido ao facto de em cada um das propostas, a média dos valores ser sempre sempre menor no pulmão direito, relativamente ao pulmão esquerdo.




Figura 4.12: Resultados do modelo proposto em relação aos dois pulmões.

Pode-se observar que quer no pulmão direito quer no pulmão esquerdo, o modelo proposto é o que apresenta melhores resultados. O método que mais se aproxima é o método híbrido segundo Shawn Lankton, sendo este é o método que apresenta maior consistência, não se verificando uma grande disparidade de valores. O mesmo não acontece com os métodos CV e SRB que como se pode verificar apresentam um grande intervalo em termos de observações.

#### 4.2.2.3 Vantagens do Modelo Proposto

O modelo proposto apresenta vantagens em relação aos restantes, entre as quais se podem destacar a fiabilidade, a robustez e a precisão. A fiabilidade deste método resulta do facto de ser sustentado em três métodos referentes a uma mesma abordagem que é a de contornos activos. O facto de ser referente a uma mesma abordagem produz uma boa fiabilidade o que não significa que não aconteça com um conjunto de abordagens diferentes.

A robustez no sentido da qualidade dos seus resultados é outra vantagem possível de se extrair deste modelo. Sendo baseada no facto desses resultados serem obtidos por meio de três métodos distintos, conferindo confiabilidade e solidez à sua estrutura.

Outra vantagem trata-se de uma maior precisão, visto que através desta proposta é possível conjugar de uma forma relativamente simples os resultados de três métodos de segmentação, obtendo um modelo final que é superior a qualquer um dos modelos-base.

# Capítulo 5

## Conclusão

Referem-se neste capítulo as principais conclusões do estudo efectuado, bem como futuras contribuições que poderão ser feitas no âmbito deste trabalho.

### 5.1 Conclusões

Em termos de conclusão, deve referir-se que neste trabalho se analisou a eficiência de três algoritmos de segmentação bastante conhecidos, no âmbito da imagem pulmonar torácica. De seguida, propôs-se um modelo baseado em árvores de decisão, que conjuga a saída destes três algoritmos de segmentação, com base num conjunto de características extraídas das imagens originais.

Em termos de conclusão final, é de referir o sucesso no que ao modelo proposto pelo autor diz respeito. Os objectivos foram portanto, plenamente atingidos, registando-se consideráveis melhorias utilizando-se o modelo proposto.

Existe no entanto, claramente a noção de serem necessários um maior número de testes e análises de modo a extrair-se mais conclusões. Este trata-se do primeiro passo para a construção de um método capaz de fundir estes três métodos base, ou numa abordagem mais abrangente com uma maior quantidade de métodos base. O modelo proposto tem claramente uma larga margem de evolução, isto porque se encontra alicerçado em três reconhecidos métodos de segmentação, obtendo bons resultados, assim constata-se que existe a possibilidade de evoluir futuramente para um número maior de métodos. A força do modelo proposto encontra-se na capacidade de extrair o que de melhor existe nos métodos base que o suportam.

É possível ser extraída uma conclusão acerca dos três métodos base que serviram de suporte ao modelo proposto. Tratando-se de três métodos baseados na mesma abordagem de contornos activos poderia ser complicado identificar um que se destacasse. No entanto o modelo híbrido segundo Shawn Lankton é considerado com alguma margem de confiança que advém dos resultados obtidos, o melhor.

Conclui-se que o método de Chan e Vese não engloba um critério de paragem preciso, mesmo iniciando os contornos activos perto dos pulmões este método expande o contorno a toda a imagem, sendo segmentados dados não necessários que apenas servem para tornar o processamento posterior mais lento e impreciso.

Conclui-se igualmente que o método baseado em regiões segundo Shawn Lankton apesar de apresentar melhorias relativamente ao método de Chan e Vese, não é ainda capaz de detectar com segurança as fronteiras do objecto de interesse.

Desta forma, conclui-se que o método híbrido, trata-se de um método que detecta as regiões através de estatísticas globais da imagem o que é algo de negativo em relação ao método baseado em regiões segundo Shawn Lankton que tem em conta estatísticas locais. No entanto o facto de ser complementado com um critério de paragem em termos do gradiente permite uma melhor detecção das fronteiras da região de interesse, evitando-se desta forma segmentação exagerada.

## 5.2 Trabalho Futuro

Como trabalho futuro a ser realizado no âmbito deste estudo, destacam-se as seguintes vertentes: O primeiro objectivo, é a necessidade de escrita de um artigo a ser submetido de modo a ser possível expor os resultados alcançados com este estudo perante a comunidade internacional.

Um segundo objectivo passa pela aplicação do mesmo modelo, mas tentando abranger um maior número de métodos bases que possibilitem uma ainda maior coerência e precisão ao longo da sua construção, fornecendo desta forma uma maior abrangência de valores, possibilitando um estudo ainda mais aprofundado.

Este método a ser implementado, sendo resultado de uma maior abrangência de métodos baseados em regiões, baseados em contornos activos ou qualquer outra abordagem, pode ser encarado como um "super" método capaz de extrair os melhores resultados proporcionados por cada um dos métodos em que será alicerçado.

Os dados obtidos nos métodos base que permitiram o construção do modelo proposto são baseados na margem de erro da ROI, não sendo fundido o conceito da margem de erro em termos de *over-segmentation*. Por isso é natural que o método proposto recolha maiores observações do SRB e do CV como se constata nos dados de correlação visto serem métodos que obtém melhores valores de ROI. Assim, futuramente será necessário um aprofundamento deste estudo, onde os dados do modelo proposto sejam baseados numa ROI mais abrangente mas também numa diminuta *over-segmentation*.

Tal acção consiste na fusão dos dois conceitos, isto numa tentativa de originar um modelo eficiente em termos de ROI e em termos da quantidade de dados segmentados.

## Bibliografia

- [1] J. Canny. A computational approach to edge detection. *IEEE, Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-8(No. 6):679-698. 12
- [2] Comunello E. Pizarro, P. and S. Mantelli. Segmentação por crescimento de regiões. 21
- [3] M. Radojevic and G. Lemaitre. Scene segmentation and interpretation. coursework 1. image segmentation. 21
- [4] S. Thilagamani. *International Journal of Research and Reviews in Information Sciences (IJRRIS)*. 31
- [5] Y.H. Wang. Tutorial: Image segmentation. pages 1-36. 19, 25, 26
- [6] S.L. Horowitz and T. Pavlidis. Picture segmentation by a tree traversal algorithm. *Journal of the ACM (JACM)*, Vol. 23(No. 2):368-388, Abril 1976. 23, 24
- [7] Friedman J H. Olshen R A. Breiman, L. and C.J. Stone. Classification and regression trees. *Wadsworth International Group*, pages 342-346, 1984. 52
- [8] R.M. Haralick and L.G. Shapiro. Image segmentation techniques. *Computer Vision, Graphics, and Image Processing*, Vol. 29(No. 1):100-132, 1985. 22
- [9] W Andrew. K, Michael. and Demetri. T. Snakes: Active contour models. *International Journal of Computer Vision*, Vol. 1(No. 4):321-331, 1988. 29, 30
- [10] Lilly. S. A summary of image segmentation techniques. Technical report, NASA, National Aeronautics and Space Administration, Junho 1993. 23
- [11] Kasturi R. Jain, R. and B.G Schunck. Machine vision. Vol. 5:1-549, 1995. 13, 14, 16, 17, 18, 22, 24
- [12] MC Lohrenz and KB Shaw. A survey of digital image segmentation algorithms. *Naval Oceanographic and Atmospheric Research Laboratory*, pages 1-28, January 1995. 11, 12, 19, 20
- [13] Avadhanam N. Algazi, V.R. and R.R Estes Jr. Quality measurement and use of pre-processing in image compression. *Signal processing*, Vol. 70(No. 3):215-229, 1998. 8
- [14] M.S. Atkins and B.T. Mackiewicz. Fully automatic segmentation of the brain in mri. *IEEE, Transaction on Medical Imaging*, Vol. 17(No. 1):98-107, 1998. 37
- [15] A. Blake and M. Isard. Active contours. the application of techniques from graphics, vision, control theory and statistics to visual tracking of shapes in motion. 1998. 7
- [16] Wilson L. S. Doust B. D. Gill R. W. Sun C. Brown, M. S. Knowledge-based method for segmentation and analysis of lung boundaries in chest x-ray images. *Computerized Medical Imaging and Graphics*, Vol. 22(No. 6):463-477, Setembro 1998. 5
- [17] Dmitrij C. Basic algorithms for digital image analysis a course. Technical report, 1998. 24
- [18] S.A. Hojjatoleslami and J. Kittler. Region growing: A new approach. *IEEE, Transactions on Image Processing*, Vol. 7(No. 7):1079-1084, 1998. 20

- [19] M.Y. Mashor. Hybrid training algorithm for rbf network. *International Journal of The Computer, The Internet and Management*, Vol. 8(No. 2):50-65, Agosto 2000. 32
- [20] Tony. F, C and Luminita. A, V. Active contours without edges. *IEEE, Transactions on Image Processing*, Vol. 10(No. 2):266-277, Fevereiro 2001. 42, 43
- [21] S.D. Olabarriaga and AWN. Smeulders. Interaction in the segmentation of medical images: A survey. *Medical image analysis*, Vol. 5(No. 2):127-142, Junho 2001. 35, 36
- [22] D. Zhang and G. Lu. A comparative study on shape retrieval using fourier descriptors with different shape signatures. pages 1-9, 2001. 50
- [23] R. Lotufo and W. Silva. Minimal set of markers for the watershed transform. *Proceedings of ISMM*, pages 359-368, Junho 2002. 28
- [24] P.L. Rosin and E. Ionnidis. Evaluation of global image thresholding for change detection. *Elsevier, Pattern Recognition Letters*, Vol. 24(No. 14):2345-2356, Outubro 2003. 35
- [25] J. Weickert and Kdotuuhne. Fast methods for implicit active contour models. *Geometric level set methods in imaging, vision, and graphics*, pages 43-57, 2003. 31
- [26] Jian Y. Lu, Y. and Y. Zang. A split-merge based region growing method for fmri activation detection. *Human brain mapping*, Vol. 22(No. 4):271-279, 2004. 22, 23
- [27] Salaman A. Omran, M. and AP Engelbrecht. Dynamic clustering using particle swarm optimization with application in unsupervised image classification. *Pattern Analysis and Applications*, Vol. 8(No. 4):332-344, 2005. 31
- [28] Salman A. Omran, M. and AP Engelbrecht. Dynamic clustering using particle swarm optimization with application in unsupervised image classification. *Fifth World Enformatika Conference (ICCI 2005)*, pages 199-204, Agosto 2005. 31
- [29] M. Butenuth. Segmentation of imagery using network snakes. *Photogrametrie Fernerkund Geoinformation*, Vol. 2(No. 1):1-7, 2007. 29, 30
- [30] K Chiu-Yen. G John C. L, Chunming. and Zhaohua D. Implicit active contours driven by local binary fitting energy. *IEEE, Computer Society Conference on Computer Vision and Pattern Recognition, CVPR '07*, pages 1-7, Junho 2007. 28
- [31] Nain D.-Yezzi A. Lankton, S. and A.R. Tannenbaum. Hybrid geodesic region-based curve evolutions for image segmentation. *Medical Imaging 2007: Physics of Medical Imaging*, Vol. 6510:65104U-1, Março 2007. 39, 40, 41, 42
- [32] S. Lefèvre. Knowledge from markers in watershed segmentation. *Computer Analysis of Images and Patterns*, pages 579-586, 2007. 27
- [33] Kao C.Y. Li, C., J.C. Gore, and Z. Din. Implicit active contours driven by local binary fitting energy. *IEEE, Conference on Computer Vision and Pattern Recognition, CVPR*, pages 1-7, Junho 2007. 31
- [34] S.J. Redmond and C. Heneghan. A method for initialising the *K-means* clustering algorithm using *kd-trees*. *Pattern Recognition Letters*, Vol. 28(No. 8):965-973, Junho 2007. 31

- [35] ABM Faruquzzaman, N.R. Paiker, J. Arafat, M.A. Ali, and G. Sorwar. Literature on image segmentation based on split-and-merge techniques. *The 5th International Conference on Information Technology and Applications, ICITA*, pages 1-8, Junho 2008. 36
- [36] S. Lankton and A. Tannenbaum. Localizing region-based active contours. *IEEE, Transactions on Image Processing*, Vol. 17(No. 11):2029-2039, Novembro 2008. 43, 44
- [37] Y. Luo and R. Duraiswami. Canny edge detection on nvidia cuda. *IEEE, Computer Society Conference on Computer Vision and Pattern Recognition Workshops. CVPRW '08*, pages 1-8, junho 2008. 18
- [38] N. Sharma, A.K. Ray, S. Sharma, KK Shukla, S. Pradhan, and L.M. Aggarwal. Segmentation and classification of medical images using texture-primitive features: Application of bam-type artificial neural network. *Journal of medical physics Association of Medical Physicists of India*, Vol. 33(No. 3):119-126, 2008. 37
- [39] GN. Srinivasan and G. Shoba. Segmentation techniques for target recognition. *WSEAS, World Scientific and Engineering Academy and Society, Transaction on Computers*, Vol. 7(No. 10):1555-1563, Outubro 2008. 22
- [40] L Jianxin.-L Huifen. Z, Yuqian. and Guiyuan L. Improved watershed algorithm for dowsels image segmentation. *Intelligent Control and Automation, 2008. WCICA 2008. 7th World Congress on Intelligent Control and Automation*, pages 7644-7648, Junho 2008. 25, 26, 27
- [41] Denilson Laudares Rodrigues. Elza Marisa Paiva de Figueiredo Chagas. and Jo ao Manuel R. S. Tavares. Método de segmentação de objectos em imagens baseado em contornos activos e algoritmo genético. *Congreso de Métodos Numéricos em Ingeniería 2009, MetNum2009*, 2009. 29, 30
- [42] N.A.M. Isa, S.A. Salamah, and U.K. Ngah. Adaptive fuzzy moving k-means clustering algorithm for image segmentation. *IEEE, Transactions on Consumer Electronics*, Vol. 55(No. 4):2145-2153, 2009. 32, 33
- [43] H.G Kajanami and Z. Beiji. Region-based segmentation versus edge detection. *IEEE, Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing. IHH-MSP'09*, pages 1217-1221, Setembro 2009. 19, 20
- [44] W.X. Kang, Q.Q. Yang, and R.P Liang. The comparative research on image segmentation algorithms. *IEEE, The First International Workshop on Education Technology and Computer Science ETCS '09*, Vol. 2:703-707, Março 2009. 12
- [45] Paiker N.R. Ali M.A. Sorwar G. Karim, Z. and MM Islam. Pattern based object segmentation using split and merge. *IEEE, International Conference on Fuzzy Systems, FUZZ-IEEE*, pages 2166-2169, Agosto 2009. 22, 23, 24
- [46] R. Maini and Himanshu. Aggarwal. Study and comparison of various image edge detection techniques. *International Journal of Image Processing (IJIP)*, Vol. 3(No. 1):1-11, Fevereiro 2009. 14
- [47] Raghuvanshi M. Dharaskar R. Raut, S. and A Raut. Image segmentation - a state-of-art survey for prediction. *IEEE, International Conference on Advanced Computer Control*, pages 420-424, March 2009. 5, 10, 12

- [48] N. Senthilkumaran and R. Rajesh. Edge detection techniques for image segmentation - a survey of soft computing approaches. *IEEE, International journal of recent trends in engineering*, Vol. 1(No. 2):250-254, Maio 2009. 13, 15, 16
- [49] R.K.Krishna. B, Manisha. and V.E.Pise. Image segmentation by improved watershed transformation in programming environment matlab. *International Journal of Computer Science and Communication*, Vol. 1(No. 2):171-174, Setembro 2010. 25
- [50] A. I. Sarpe. Image segmentation with clustering k-means and watershed transform. *IEEE, Second International Conferences on Advances Multimedia, (MMEDIA)*, pages 13-17, 2010. 32
- [51] A.I Sharpe. Image segmentation with clustering k-means and watershed transform. *Second International Conferences on Advances in Multimedia (MMEDIA)*, pages 13-17, Junho 2010. 31
- [52] Rami. C. The chan-veese algorithm. *Arxiv preprint arXiv:1107.2782*, 2011. 43
- [53] Mandeep. K and Gagandeep J. Medical image segmentation using marker controlled watershed transformation. *International Journal of Computer Science and Tecnology*, Vol. 2 Issue. 4(No. 119):548-551, Outubro 2011. 26
- [54] Xiong Yingen. P Kari. L, Dingding. and Linda. S. Estimating image segmentation difficulty. *Machine Learning and Data Mining in Pattern Recognition*, pages 484-495, Setembro 2011. 7
- [55] N. Mezhoud and F Hachouf. Image segmentation, available techniques, developments and open issues. *Journal of Theoretical and Applied Information Technology*, Vol. 26(No. 1):1-15, Abril 2011. 5
- [56] Utkarsh S. The sobel and laplacian edge detectors. Abril 2011. 14, 16, 33
- [57] A. Selvan. Boundary extraction in images using hierarchical clustering-based segmentation. *The 3rd BMVC UK Student Workshop*, pages 1-12, Setembro 2011. 31
- [58] Olugbara O.O. Ojo S.O. Zuva, T. and S.M. Ngwira. Image segmentation, available techniques, developments and open issues. *Canadian Journal on Image Processing and Computer Vision*, Vol. 2(No. 3):20-29, Maio 2011. 5, 9, 10, 19
- [59] Youssif A. Khalifa, I. and H. Youssry. Tissue segmentation techniques of brain mr images: A review. *International Conference on Intelligent Computational Systems, (ICICS)*, pages 17-21, Janeiro 2012. 34, 35, 36, 37
- [60] M. Nixon and A.S. Aguado. Feature extraction & image processing for computer vision. 2012. 50
- [61] O. Wirjadi. *Survey of 3d image segmentation methods*. ITWM, 2007. 35