



Universidade Estadual de Campinas
Instituto de Computação



Azael de Melo e Sousa

Segmentação Automática dos Pulmões e da Traqueia em Imagem de Tomografia Computadorizada do Tórax

CAMPINAS
2017

Azael de Melo e Sousa

**Segmentação Automática dos Pulmões e da Traqueia em Imagem
de Tomografia Computadorizada do Tórax**

Dissertação apresentada ao Instituto de
Computação da Universidade Estadual de
Campinas como parte dos requisitos para a
obtenção do título de Mestre em Ciência da
Computação.

Orientador: Prof. Dr. Alexandre Xavier Falcão

Este exemplar corresponde à versão final da
Dissertação defendida por Azael de Melo e
Sousa e orientada pelo Prof. Dr. Alexandre
Xavier Falcão.

CAMPINAS
2017

Agência(s) de fomento e nº(s) de processo(s): CAPES

ORCID: <https://orcid.org/0000-0003-3308-2439>

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca do Instituto de Matemática, Estatística e Computação Científica
Ana Regina Machado - CRB 8/5467

So89s Sousa, Azael de Melo e, 1992-
Segmentação automática dos pulmões e da traqueia em imagem de tomografia computadorizada do tórax / Azael de Melo e Sousa. – Campinas, SP : [s.n.], 2017.

Orientador: Alexandre Xavier Falcão.
Dissertação (mestrado) – Universidade Estadual de Campinas, Instituto de Computação.

1. Segmentação de imagens médicas. 2. Processamento de imagens - Técnicas digitais. 3. Tomografia computadorizada por raios X. I. Falcão, Alexandre Xavier, 1966-. II. Universidade Estadual de Campinas. Instituto de Computação. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Automatic lungs and trachea segmentation on computed tomography images from the thorax

Palavras-chave em inglês:

Medical image segmentation

Image processing - Digital techniques

X-rays computed tomography

Área de concentração: Ciência da Computação

Titulação: Mestre em Ciência da Computação

Banca examinadora:

Alexandre Xavier Falcão [Orientador]

Silvio Jamil Ferzoli Guimarães

Thiago Vallin Spina

Data de defesa: 09-11-2017

Programa de Pós-Graduação: Ciência da Computação



Universidade Estadual de Campinas
Instituto de Computação



Azael de Melo e Sousa

Segmentação Automática dos Pulmões e da Traqueia em Imagem de Tomografia Computadorizada do Tórax

Banca Examinadora:

- Prof. Dr. Alexandre Xavier Falcão
IC/UNICAMP
- Prof. Dr. Silvio Jamil Ferzoli Guimarães
ICEI/PUC Minas
- Prof. Dr. Thiago Vallin Spina
IC/UNICAMP

A ata da defesa com as respectivas assinaturas dos membros da banca encontra-se no processo de vida acadêmica do aluno.

Campinas, 09 de novembro de 2017

We all make choices, but in the end the choices make us (Andrew Ryan - Bioshock)

Agradecimentos

Aproveito essa oportunidade para expressar minha gratidão ao Prof. Dr. Alexandre Xavier Falcão pela sua orientação e apoio durante todo o período de mestrado.

Também gostaria de agradecer à minha família e amigos pela ajuda e encorajamento constante que me mantiveram motivado para superar todas as dificuldades e obstáculos durante os últimos dois anos.

Por fim, dedico um agradecimento a CAPES pelo financiamento do projeto.

Resumo

Atualmente, doenças respiratórias afetam uma grande parcela da população mundial. A melhor maneira para detecção e análise desse tipo de doença é o diagnóstico por imagem, principalmente a tomografia computadorizada (CT). Sistemas de apoio ao diagnóstico foram desenvolvidos para auxiliar especialistas clínicos na análise de imagens de CT e na obtenção de diagnósticos precisos e rápidos. Em tais sistemas, a segmentação dos pulmões é um passo primordial a ser realizado, sendo fundamental para análises quantitativas.

Ao longo dos últimos anos, muitos métodos de segmentação dos pulmões foram propostos. Entretanto, eles sofrem de pelo menos uma das seguintes limitações: alto tempo computacional, fracas condições para separação da traqueia e de cada pulmão, e um número limitado de amostras para validação. Abordando tais limitações, esta dissertação de mestrado propõe um método rápido e automático chamado *Automatic Lung and Trachea Image Segmentation* (ALTIS), para segmentação dos pulmões e da traqueia em imagens de CT do tórax. O método ALTIS se fundamenta na competição ótima de sementes para segmentar os pulmões e a traqueia em tempo proporcional ao tamanho da imagem. Ele consiste de uma rápida sequência de operações de processamento de imagem baseadas em características anatômicas que são robustas para a maioria das variações de forma e aparência dos pulmões. Isto é, a partir da premissa de que o sistema respiratório em uma imagem de CT representa o maior objeto cercado por tecido mais claro, os pulmões e a traqueia são extraídos criando o volume de interesse. Considerando que os pulmões direito e esquerdo são mais largos do que a traqueia e que a traqueia é um objeto longo e distante dos pulmões, sementes com rótulos diferentes dentro de cada um desses componentes são estimadas por meio de transformadas de distância. A competição ótima de sementes propaga esses rótulos para o resto do volume de interesse, realizando o delineamento dos objetos. O delineamento é feito nos volumes de ar da traqueia e dos pulmões até a pleura visceral. Assim, a segmentação da cavidade pleural está fora do escopo deste projeto.

O método ALTIS foi extensivamente avaliado em um conjunto de aproximadamente 1.750 imagens de tomografia, unindo tanto bases de dados internas como públicas. Até onde sabemos, esse é o maior conjunto de imagens para validação dentre os trabalhos reportados na literatura. Além do método ALTIS, outros dois métodos baseados em modelos de forma, MALF e SOSM-S, foram quantitativamente avaliados em 250 imagens desse conjunto. Essa avaliação foi feita através da análise de sobreposição e distância até a borda das segmentações interativas consideradas corretas. Os experimentos realizados indicaram que o método ALTIS é estatisticamente superior e consideravelmente mais rápido que ambos os métodos comparados. As 1.500 imagens restantes foram utilizadas para verificação da robustez do método proposto. Nesta etapa, cada uma das imagens de segmentação geradas pelo ALTIS foram visualmente examinadas à procura de falhas. Foram observados erros de segmentação em uma pequena porcentagem delas.

Abstract

On the present day, respiratory diseases affect a great portion of people worldwide. The best way to detect and analyze this kind of disease is by diagnostic imaging, mainly Computed Tomography (CT). Computer-aided diagnosis systems have been developed to help specialists with the analysis of CT images to obtain an accurate and fast diagnosis. In such systems, the segmentation of the lungs is paramount for quantitative analysis.

In the past years, many lung segmentation methods have been proposed. However, they suffer from at least one of these limitations: high computational time, weak conditions for separating the trachea and each lung with internal structures brighter than the air, and a limited number of samples for validation. Addressing those limitations, this master's thesis proposes a fast lung and trachea segmentation method, called Automatic Lung and Trachea Image Segmentation (ALTIS), on CT images from the thorax. The ALTIS method uses optimum seed competition to segment the lungs and the trachea in a time proportional to the domain of the image. It consists of a fast sequence of image processing operations which takes into consideration anatomical characteristics that are robust for most appearance variations of abnormal lungs. That is, from the premise that the respiratory system on a CT image represents the largest object surrounded by brighter tissue, the lungs and the trachea are extracted creating the volume of interest. Considering that the lungs are larger than the trachea and the trachea is a thin object distant from the lungs, seeds with different labels are estimated inside each component by means of distance transforms. The optimum seed competition propagates these labels to the rest of the volume of interest, delineating the objects. The delineation is performed on the volumes of air inside the trachea and both lungs, limited by the visceral pleura. Therefore, the segmentation of the pleural cavity is not within the scope of this project.

The ALTIS method was extensively evaluated on a set of approximately 1.750 CT images, gathering both in-house and public datasets. To the best of our knowledge, this is the largest set of CT images used for validation ever reported in the literature. Besides ALTIS, two other shape model-based methods, MALF and SOSM-S, were quantitatively evaluated on 250 CT images from the original set. This evaluation was made through overlapping and border distance analysis over the ground-truth segmentations. The performed experiments indicated that ALTIS is statistically superior and considerably faster than both compared methods. The remaining 1.500 images were used to verify ALTIS's robustness. At this stage, each ALTIS's segmentation was visually analyzed on the search for failures. Segmentation errors were observed in a small percentage of them.

Lista de Figuras

1.1	Pulmões e traqueia formando o objeto de interesse.	15
1.2	Imagens com alteração de forma (paciente com escoliose), baixa resolução em uma das dimensões, drástica diferença de brilho e contraste, alteração de tamanho (paciente com derrame pleural) e ruídos.	15
1.3	Imagem de CT cuja traqueia está conectada com a borda da imagem (círculo vermelho) pelo eixo Z.	16
1.4	Imagem onde a traqueia não é o único componente escuro que aparece nas primeiras fatias da imagem.	16
1.5	Exemplos de resultados de segmentações dos pulmões e da traqueia realizado pelo ALTIS.	21
2.1	Primeira linha apresenta os cortes dos planos axial, sagital, e coronal. A segunda linha mostra como os planos estão dispostos em uma imagem de CT, seguido pela disposição dos planos no paciente.	24
2.2	Exemplos de relações de adjacência. (a) Vizinhança-4 em 2D, (b) vizinhança-6 em 3D, (c) vizinhança-8 em 2D e (d) vizinhança-20 em 2D.	25
2.3	A imagem (a) apresenta o grafo original com pesos nas arestas e duas sementes 'a' e 'b'. A imagem (b) apresenta o mapa de custos inicial. As iterações de (c)-(e) particionam o grafo em uma OPF com dois rótulos (vermelho e amarelo). Em (f), a OPF resultante mostra que o rótulo amarelo segmentou o objeto.	28
2.4	Exemplo de execução do filtro de fechamento de bacias pela IFT em uma imagem de exemplo (a). As sementes são os pontos vermelhos em (b) e (c) representa o resultado do filtro.	29
2.5	Exemplo de execução da transformada de <i>watershed</i> pela IFT em uma imagem de ressonância magnética de um cérebro (a). (b) Imagem de gradiente com uma semente dentro do septo pelúcido (1) e uma semente de fundo (2). (c) Segmentação derivada da transformada <i>watershed</i> pela IFT	29
3.1	Imagem CT de um paciente com escoliose segmentado por dois métodos baseados em Modelos de Forma. A curvatura da coluna vertebral dificulta na segmentação.	36
4.1	Diagrama das etapas do método ALTIS. Para uma dada imagem de CT, inicialmente os pulmões e traqueia são extraídos. Em seguida, as sementes são estimadas para realização do delineamento dos objetos.	42

4.2	Pipeline da etapa de extração dos pulmões e traqueia. (a) Mapa de custo mínimo após aplicação da IFT nas fatias do plano axial. (b) Imagem original. (c) Imagem residual obtida subtraindo (b) de (c). (d) Seleção do maior componente conexo em (c). (e) Fechamento morfológico em (d), resultando no volume de interesse.	43
4.3	Um caminho que começa nas bordas do corte axial, passa através do espaço vazio da imagem (verde), seguido pelo ar em volta do paciente (azul) e pelo corpo (vermelho) até chegar em um ponto no pulmões direito. Tal caminho deve visitar pixels mais claros antes de chegar nos pulmões e traqueia. . . .	44
4.4	Pipeline da estimativa das sementes, a rotulação das sementes e delimitação dos objetos. (a) Volume de interesse obtido na etapa de extração dos pulmões e da traqueia (seção 4.1). (b) Sementes dos pulmões e do fundo obtidas por uma dilatação e erosão morfológicas aplicadas em (a). (c) Mapa das distâncias geodésicas a partir das sementes dos pulmões. (d) Estimativa das sementes da traqueia obtidas por meio de uma limiarização e seleção do componente mais alto de (c). Essa seleção é possível devido à orientação do paciente. (e) Imagem original com as sementes rotuladas: sementes verdes representam o pulmão direito, as azuis são do pulmão esquerdo, enquanto que as vermelhas são da traqueia e as brancas são sementes externas. (f) Imagem de gradiente da original. (g) Resultado do delimitação e (h) sua renderização 3D.	47
4.5	Cortes coronal, axial e sagital da imagem de gradiente.	51
4.6	Exemplo das limitações do método ALTIS. (a) Mostra a segmentação dos gases intestinais de um paciente como parte do pulmão. (b) Apresenta a falha da segmentação do método ALTIS para um pulmão com volume de ar reduzido.	52
5.1	Atlas probabilístico dos pulmões e da traqueia.	56
5.2	Diagrama do funcionamento do método SOSM-S	56
5.3	Gráfico com os resultados de similaridade entre os métodos ALTIS, SOSM-S e MALF na métrica DICE. Note que quanto maior o valor de sobreposição, mais similares são as superfícies.	61
5.4	Gráfico com os resultados de similaridade entre os métodos ALTIS, SOSM-S e MALF na métrica ASSD. Note que quanto menor o valor de distância, mais próximas estão as superfícies.	62
5.5	Exemplos de segmentação dos métodos MALF, SOSM-S e ALTIS.	63
5.6	Método ALTIS aplicado em uma imagem com pulmão direito reduzido. . . .	64
5.7	Aplicação dos métodos de segmentação MALF, SOSM-S e ALTIS nas imagens de CT de um paciente com gases intestinais e com o pulmão direito reduzido.	65
5.8	Exemplos de erros encontrados durante a análise visual do grupo B.	66

Lista de Tabelas

5.1	Comparação de similaridade com métrica DICE para Traqueia (T), Pulmão Direito (PD) e Pulmão Esquerdo (PE).	60
5.2	Comparação de similaridade com métrica ASSD (mm).	61
5.3	Análise de variância (ANOVA) com teste de Tukey	62
5.4	Comparação no tempo de execução	65

Sumário

1	Introdução	13
1.1	Análise do Problema	14
1.2	Técnicas Existentes	15
1.3	Objetivos do Trabalho	20
1.4	Contribuição principal	20
1.5	Organização da Dissertação	21
2	Conceitos Fundamentais	23
2.1	Tomografia Computadorizada de Raios-X	23
2.2	Notações e Definições	24
2.3	Transformada Imagem-Floresta	26
2.4	Uso da Transformada Imagem-Floresta	27
2.5	Conclusão	30
3	Trabalhos Relacionados	31
3.1	Métodos baseados em Limiarização	31
3.2	Métodos baseados em Crescimento de Regiões	33
3.3	Métodos baseados em Modelos de Forma	35
3.4	Conclusão	41
4	ALTIS	42
4.1	Extração dos Pulmões e Traqueia	43
4.2	Estimativa das Sementes	47
4.3	Delineamento dos Pulmões e da Traqueia	50
4.4	Conclusão	52
5	Experimentos e Resultados	53
5.1	Bases de Imagens	53
5.2	Métodos usados para a validação	55
5.2.1	Modelo Estatístico de Forma do Objeto	55
5.2.2	Fusão de Rótulos com Múltiplos Atlas	57
5.3	Treinamento	57
5.4	Metodologia dos experimentos	58
5.5	Resultados e Discussão	59
5.6	Conclusão	66
6	Conclusão	68
6.1	Principais Contribuições	68
6.2	Trabalhos Futuros	69

Capítulo 1

Introdução

Na área de Processamento de Imagem, o termo “segmentação” pode ser definido como a subdivisão de uma imagem em suas partes constituintes ou objetos [13]. Técnicas de segmentação são muito utilizadas para definir a extensão espacial de objetos de interesse de uma imagem para posterior análise quantitativa. Por essa razão, uma grande área de aplicação para a segmentação de imagem, atualmente explorada, é a Radiologia. A Radiologia é a área da medicina que visa a realização de diagnósticos por meio de imagens geradas a partir de projeções de uma dada região do corpo humano quando submetido a um certo tipo de radiação ou campo magnético.

Sistemas de apoio ao diagnóstico (*Computer Aided Diagnosis* — CAD) normalmente utilizam como passo inicial a segmentação de um objeto de interesse (*e.g.*, órgão do corpo humano) para diagnóstico e tratamento de diversas doenças. Para isso, são realizadas a quantificação e análise de textura e forma do objeto. Alguns exemplos de doenças a serem diagnosticadas por sistemas CAD são: Alzheimer, aneurisma de aorta abdominal, estenose traqueal e câncer.

Uma das principais características do mal de Alzheimer é a destruição de neurônios por conta da perda de conexão entre eles, causando demência. Nesse caso, a segmentação do cérebro em uma imagem de tomografia computadorizada (CT) ou de ressonância magnética da cabeça do paciente pode ajudar na exclusão de outros fatores causadores de demência. A doença de aneurisma de aorta abdominal é causada por meio de uma protuberância ou dilatação da aorta que passa no abdômen. O tratamento tardio desta doença pode levar a complicações muito mais graves como o infarto. A segmentação da aorta em imagens de CT do tórax pode ajudar na caracterização dessa anomalia. A estenose traqueal é o resultado de um estreitamento da traqueia devido a algum trauma nessa região, causando dificuldades respiratórias. Assim, a segmentação da traqueia pode detectar automaticamente a existência de tal doença. Já o câncer é uma doença que afeta uma grande parte da população mundial, caracterizada pelo crescimento desproporcional das células do corpo invadindo os tecidos e órgãos. Uma forma comum para o diagnóstico dessa doença é a análise de imagem de CT da área afetada. Assim, a segmentação do órgão comprometido pode ajudar na localização espacial de nódulos e massas. Como por exemplo, a segmentação dos pulmões pode localizar nódulos pulmonares, além de fornecer informações quantitativas, tais como volume e outras características de forma.

O escopo deste trabalho está na segmentação dos pulmões direito e esquerdo, e da

traqueia em imagens de CT do tórax.

1.1 Análise do Problema

Doenças respiratórias são enfermidades que afetam as estruturas do sistema respiratório como as vias aéreas e os pulmões. Essas doenças são as mais comuns no mundo e podem surgir por diversas causas, incluindo a inalação de gases tóxicos e estilos de vida prejudiciais (fumo, por exemplo). De acordo com a Organização Mundial da Saúde (*World Health Organization* — WHO) doenças respiratórias estão entre as 10 primeiras causas de morte no mundo¹. Além disso, estimativas mostram que nos próximos 30 anos, doenças respiratórias se tornarão a terceira maior causa de morte em todo o mundo².

Amostragem de material biológico (como sangue, urina, tecidos e células) e procedimentos radiológicos para diagnóstico por imagem (como a radiografia do tórax e CT) são as modalidades de diagnóstico com maior eficácia na avaliação de doenças que afetam os pulmões e a traqueia. Essas modalidades permitem que médicos possam diagnosticar a(s) anomalia(s) específica(s) que estão comprometendo estas estruturas. O primeiro procedimento é considerado invasivo e coloca os pacientes em riscos, tais como infecções, lesões ou outras reações adversas, incluindo a morte em casos extremos. Como consequência, o procedimento preferível para diagnóstico de doenças pulmonares é a análise de imagens, especialmente CT, uma vez que oferece muitas vantagens sobre a radiografia do tórax, como alta resolução espacial, moderado contraste na imagem, e rápida varredura tridimensional do tórax. Portanto, a tomografia computadorizada é o procedimento padrão para o diagnóstico de doenças respiratórias.

De forma a auxiliar no diagnóstico de doenças respiratórias, a segmentação dos pulmões e da traqueia é necessária. A segmentação dos pulmões e da traqueia inclui o volume de ar de cada pulmão, as estruturas vasculares e linfáticas dentro deles (desconsiderando a cavidade pleural), o volume de ar da traqueia e os brônquios principais. A Figura 1.1 mostra os objetos de interesse. Do ponto de vista computacional, tal segmentação é uma tarefa desafiadora devido à grande variação de protocolos de aquisição que afetam o brilho, o contraste e a resolução, além das possíveis variações de forma e tamanho dos pulmões e da traqueia causadas por diferenças de sexo e idade, movimentação durante a aquisição da imagem, presença de ruídos na imagem, doenças congênitas, e deformações no tórax por trauma ou cirurgia. A Figura 1.2 apresenta alguns problemas que podem ser encontrados nas imagens de CT.

Métodos clássicos para segmentação de pulmões iniciam a segmentação por meio de uma limiarização nas intensidades da imagem para extração dos pulmões e traqueia como o maior componente conexo cercado por tecido claro. Essa estratégia sozinha não considera estruturas mais claras dentro dos pulmões como veias, artérias ou nódulos que são importantes para análise. Outra abordagem é o uso de registro deformável de imagem para corrigir problemas na variação de forma, porém não possuem bons resultados para determinadas situações, como pulmões deformados pela escoliose, e requerem alto esforço

¹<http://www.who.int/respiratory/copd/burden/en/>, accessed on Jan 6, 2017

²<http://www.who.int/mediacentre/factsheets/fs310/en/>, accessed on Jan 6, 2017

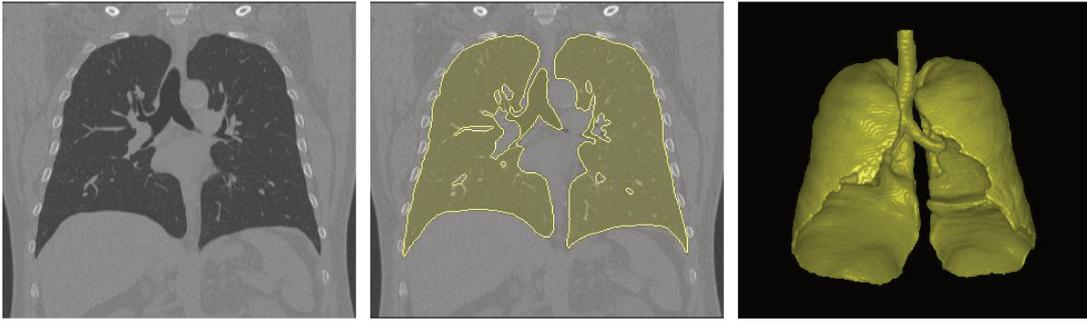


Figura 1.1: Pulmões e traqueia formando o objeto de interesse.



Figura 1.2: Imagens com alteração de forma (paciente com escoliose), baixa resolução em uma das dimensões, drástica diferença de brilho e contraste, alteração de tamanho (paciente com derrame pleural) e ruídos.

computacional levando muito tempo (questão de minutos ou até horas) para executar.

1.2 Técnicas Existentes

Nesta seção são reportadas as vantagens e desvantagens dos métodos encontrados na literatura para segmentação dos pulmões. Mais detalhes de como cada um desses métodos funcionam são dados no capítulo 3.

Muito métodos de segmentação dos pulmões foram propostos nos últimos anos [24, 26]. Apesar do progresso, eles normalmente sofrem de no mínimo uma das seguintes limitações: alto tempo computacional, condições fracas para separação dos pulmões e traqueia, e validação baseada em um número relativamente pequeno de imagens de CT (menos que 100 imagens de CT).

Hu *et al.* [16] propuseram um método de segmentação automática dos pulmões baseado em limiarização. O método em [16] segue a estratégia de extrair os pulmões da imagem de CT por meio de uma limiarização ótima e rotulação de componentes conexos, seguida da extração da traqueia e, caso os pulmões ainda estejam conectados, é feita a separação dos pulmões direito e esquerdo.

As desvantagens do método em [16] estão na etapa de extração dos pulmões, na exclusão da traqueia, e na quantidade de imagens usadas nos experimentos. Após a limiarização ótima, é aplicada a técnica de rotulação 3D de componentes conexos com a exclusão de regiões ligadas com as bordas da imagem. Isso pode gerar problemas, uma vez que a traqueia ainda não foi extraída e está conectada aos pulmões e a uma das bordas da imagem. A Figura 1.3 mostra a traqueia conectada com a borda da imagem.

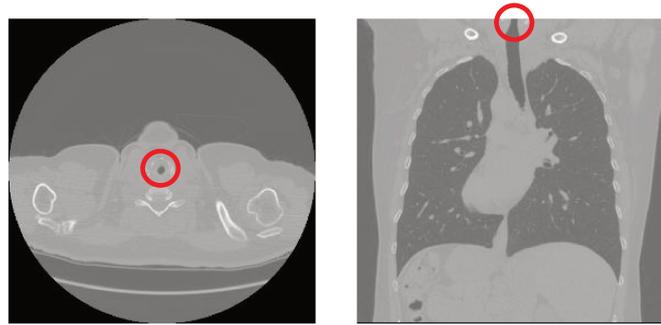


Figura 1.3: Imagem de CT cuja traqueia está conectada com a borda da imagem (circulo vermelho) pelo eixo Z.

Outro problema é na extração da traqueia onde ela é identificada automaticamente (circunferência vermelha da Figura 1.4) perto do centro da imagem como o único componente escuro nas primeiras fatias axiais (a posição da traqueia depende da orientação do paciente, podendo ser nas primeiras ou nas últimas fatias). A Figura 1.4 mostra que isso nem sempre ocorre. Por fim, os experimentos foram conduzidos em 24 imagens de CT. Um conjunto de imagens deste tamanho não é representativo para problemas reais.

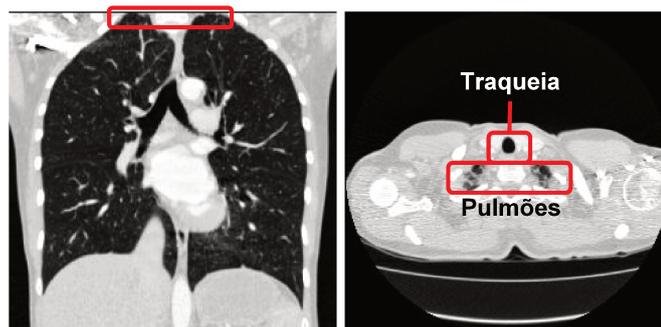


Figura 1.4: Imagem onde a traqueia não é o único componente escuro que aparece nas primeiras fatias da imagem.

Armato *et al.* [2] também propuseram um método de segmentação automática dos pulmões baseado em limiarização. O método em [2] segue a ideia de aplicar duas limiarizações consecutivas, uma para extrair todo o tórax da imagem e outra para extrair os pulmões do tórax, seguido pela remoção da traqueia e inclusão das estruturas internas dos pulmões.

O método de [2] possui algumas desvantagens nas etapas de remoção da traqueia, inclusão das estruturas internas dos pulmões e nos experimentos. A extração da traqueia segue uma ideia parecida com a sugerida em [16]. Pontos nas últimas fatias axiais com baixo brilho e perto do centro de massa da imagem são considerados pontos da traqueia. Entretanto, a figura 1.4 mostra que isso nem sempre é verdade. Outro problema está na forma de inclusão de estruturas internas, como veias e artérias, que é feita por meio de uma limiarização com base no diâmetro de cada estrutura. Objetos importantes para análise, como nódulos, podem ter diâmetro maior do que o valor de limiarização e, conseqüentemente, podem ser excluídos da segmentação. Por fim, dois problemas foram encontrados nos experimentos. Primeiro, somente 60 imagens foram usadas nos testes e, apesar de ser

uma quantidade maior do que a usada em [16] usaram, ainda assim não é representativa. E segundo, a validação do método de segmentação foi feita por meio de medidas baseadas em sua aplicação na análise de nódulos, o que não garante a eficácia nem a robustez do método de segmentação dos pulmões.

Shoujaili *et al.* [34] propuseram um método automático de segmentação dos pulmões baseado em crescimento de regiões. A estratégia por trás do método em [34] é a seleção de marcadores internos e externos dos pulmões seguida pela remoção da traqueia e aplicação da transformada de *watershed* para segmentar os pulmões.

O método em [34] possui algumas desvantagens na seleção dos marcadores internos e na remoção da traqueia. Durante a seleção dos marcadores internos, o fundo é removido eliminando objetos ligados às bordas. Caso essa etapa seja feita no espaço tridimensional, o que não foi reportado, os pulmões e traqueia podem ser removidos como sendo parte do fundo (Figura 1.3). Outro problema está na remoção da traqueia que novamente segue uma ideia muito parecida com a dos métodos em [16] e [2], onde a traqueia é identificada como sendo um objeto largo e circular perto do centro nas primeiras fatias axiais da imagem (Figura 1.4). Por fim, a quantidade de imagens de CT utilizada nos experimentos e o tempo de execução não foram informados.

Mansoor *et al.* [27] propuseram um método automático de segmentação dos pulmões baseado em crescimento de regiões, chamado de *Pathological Lung Segmentation (PLS)*. O PLS utiliza a técnica de conectividade nebulosa (*Fuzzy Connectedness — FC*) para inicialmente segmentar os pulmões, opcionalmente separando-os e extraíndo a traqueia, seguido por uma série de testes para detecção de anomalias e finalizando com uma etapa de refinamento da segmentação, que leva em consideração as anomalias encontradas.

O método PLS possui algumas desvantagens nas configurações do FC, e nos experimentos. O método FC necessita que marcadores sejam selecionados dentro dos pulmões direito e esquerdo. Assim, o método PLS utiliza uma limiarização fixa de -550 unidades Hounsfield³ (HU) para extrair os pulmões da imagem. Então é realizada uma amostragem aleatória para selecionar sementes dentro de cada pulmão separadamente. Apesar de HU afetar a intensidade de cada imagem de CT individualmente, não é possível garantir que a intensidade resultante seja somente referente aos pulmões, considerando os diferentes protocolos de aquisição e ruídos na imagem [21]. Como dito anteriormente, a limiarização sozinha não consegue separar os pulmões e mais detalhes sobre essa separação inicial não foram fornecidos. Além dos marcadores, a segmentação por FC necessita de alguns parâmetros de afinidade que são determinados empiricamente após a análise de centenas de imagens. Entretanto, não foi comentado se estas imagens foram retiradas do conjunto de testes, podendo resultar em um supertreinamento. O método PLS leva de 1 a 15 minutos para segmentar os pulmões, um tempo consideravelmente alto.

Dai *et al.* [9] propuseram um método de segmentação dos pulmões que utiliza a técnica de corte em grafos com modelo de mistura Gaussiana (*Gaussian Mixture Models — GMM*). O método em [9] não entra no escopo de estudo desta dissertação por ser um método interativo, onde o usuário deve escolher marcadores nos objetos e no fundo e a imagem é modelada como um grafo para aplicação do GMM e cômputo do corte no grafo. Além disso, o método leva de 10 a 15 minutos para ser executado.

³Unidades Hounsfield representa uma escala quantitativa que descreve radiodensidade.

Sluimer *et al.* [35] propuseram um método para segmentação de pulmões doentes, que é baseado em atlas probabilístico. Um atlas corresponde a uma imagem e as respectivas máscaras dos objetos de interesse. Um atlas probabilístico é um modelo criado a partir da extração de características de forma dos objetos de um conjunto de atlas. O método em [35] aplica um registro deformável local para registrar 15 imagens de CT de pacientes saudáveis no espaço de uma única imagem de referência, e com isso criar um atlas probabilístico. Em seguida, a imagem de teste é registrada no espaço do atlas, para segmentação.

Os experimentos do método em [35] foram realizados em somente 10 imagens de CT de pacientes doentes, e considerando a grande gama de doenças que afetam os pulmões, esse conjunto de imagens está longe de ser representativo para o problema. Por fim, o método em [35] leva 45 horas para treinamento e criação do atlas probabilístico, o que é feito somente uma vez, e 3 horas para segmentar cada imagem, um tempo inaceitável para a prática médica.

Pu *et al.* [33] introduzem um método automático, chamado de Marcha Adaptativa de Bordas (ABM) para segmentação dos pulmões e correções de erros causados por nódulos justapleurais. O método em [33] primeiramente extrai os pulmões e então aplica um rastreamento da borda dos pulmões para detectar nódulos na pleura e corrigir a segmentação.

O método em [33] utiliza uma limiarização fixa de -500 HU como parte da extração dos pulmões, o que gera problemas caso o filtro Gaussiano usado não consiga remover todos os ruídos da imagem. Além disso, é aplicado um método de crescimento de regiões com sementes na borda da imagem para remover estruturas que não fazem parte dos pulmões (ar em volta do paciente e tecidos mais claros). Isso pode gerar problemas caso sementes não sejam selecionadas no tecido mais claro ao redor dos pulmões. Novamente, foi usada uma base de somente 20 imagens de CT, para teste do método.

Rikxoort *et al.* [40] propuseram um método híbrido para segmentação dos pulmões em imagens de CT. O método realiza uma segmentação inicial utilizando um método similar ao de [35] e [16], seguida por uma etapa de detecção de erros de segmentação e por fim as imagens segmentadas incorretamente são corrigidas utilizando um método de multiatlas.

A segmentação inicial do método em [40] possui os mesmos problemas de detecção da traqueia descritos nos métodos anteriores. A traqueia é extraída com um método de crescimento de regiões, determinando marcadores em regiões de baixo brilho, com determinado diâmetro, nas últimas fatias da imagem. Apesar de um critério de desempate baseado na distância das regiões até o centro da imagem ter sido elaborado, podem existir situações em que esse critério não seja suficiente. Além disso, um total de 16 imagens foram usadas para gerar o modelo multiatlas, uma quantidade pequena para criar um modelo robusto. A segmentação inicial leva em média 55 segundos para segmentar os pulmões e, caso seja necessário, a correção por multiatlas leva 2 horas.

Sofka *et al.* [36] apresentaram um método para segmentação de pulmões afetados por doenças em que outros métodos normalmente falham. O método em [36] inicialmente estima parâmetros de postura, como translação, tamanho, e orientação, e cria um modelo de malhas triangulares. A segmentação é feita a partir de uma deformação dessa malha utilizando os parâmetros encontrados.

As estimativas dos parâmetros são dependentes da detecção da carina traqueal, que não é detalhada. Além disso, de uma base de 260 imagens, 192 foram dedicadas para treino e as outras 68 para teste. Conjuntos fixos de treinamento e teste não comprovam a robustez do método de segmentação. Apesar do método em [36] utilizar uma base de imagens relativamente grande e ser rápido, executando em 35 segundos, comparações foram feitas apenas contra o próprio método sem a etapa de criação do modelo de malhas.

Hua *et al.* [17] propuseram um método de segmentação de pulmões doentes baseado em busca em grafos. A ideia do método em [17] é transformar o problema de segmentação em um problema de fluxo máximo em grafos. Assim, é necessária uma segmentação inicial para extração de um vetor de características. Em seguida, é aplicado um classificador que irá calcular a probabilidade de um elemento da imagem pertencer aos pulmões. Essa probabilidade é utilizada como peso para as arestas do grafo.

O método em [17] utiliza o método em [16] para computar a segmentação inicial. Já foram discutidos os problemas do método em [16] para a segmentação. Além disso, experimentos foram realizados em somente 15 imagens, sendo novamente um problema de base de dados não representativa.

Sun *et al.* [37] propuseram um método automático para segmentação dos pulmões afetados por câncer, onde métodos convencionais (limiarização, por exemplo) normalmente falham. O método proposto em [37] é baseado em modelos ativos de forma (ASM). A ideia do método é criar um modelo de distribuição de pontos a partir de um conjunto de treinamento e inicializá-lo o mais próximo possível dos pulmões, para então aplicar o método ASM robusto. Por fim, a segmentação é refinada utilizando uma abordagem de localização da superfície ótima.

As desvantagens do método em [37] estão principalmente na etapa de experimentos. Testes foram conduzidos em 30 imagens de CT, uma quantidade pequena de imagens, e a comparação foi feita contra o próprio método, só que utilizando o ASM tradicional ao em vez do robusto. Além disso, o tempo de execução é de 6 minutos para segmentar uma única imagem.

Yeary *et al.* [44] apresentaram um método para segmentação dos pulmões em imagens de CT 4D voltado para aplicações de radioterapia. Uma imagem de CT 4D consiste do agrupamento de N imagens 3D ao longo do ciclo respiratório. O método em [44] inicialmente aplica um registro deformável na imagem para alinhá-la com uma imagem de referência, seguido pelo método de descoberta da superfície ótima para segmentar simultaneamente múltiplas imagens. Como discutido sobre o método em [35], registro de imagem pode falhar em situações de bruscas mudanças de forma dos pulmões. Experimentos foram conduzidos em 6 imagens 4D com $N = 10$, totalizando 60 imagens 3D. Uma quantidade pequena de imagens para testes.

Gerard *et al.* [12] propuseram um método de segmentação dos pulmões baseado em formas- α (alfa). O método em [12] necessita de uma segmentação inicial para gerar as formas- α e a segmentação final é realizada por meio de um método de busca em grafos que encontra a superfície ótima na máscara gerada pela segmentação inicial.

As desvantagens do método em [12] estão principalmente na segmentação inicial, e nos experimentos. A segmentação inicial é feita por meio de um software [14] e este, por sua vez, utiliza o método em [16] para segmentar os pulmões. As desvantagens do método

em [16] já foram discutidas anteriormente. O outro problema é que a base de dados utilizada para validação do método em [12] é muito pequena, com apenas 12 imagens de CT para realização dos experimentos.

1.3 Objetivos do Trabalho

O objetivo deste trabalho é o desenvolvimento de um método automático de segmentação dos pulmões e da traqueia baseado em técnicas de processamento de imagem, visando abordar as limitações dos demais métodos da literatura. Como discutido na Seção 1.1, as limitações são: tempo de execução elevado, restrições fracas para a separação dos pulmões entre si e da traqueia, e validação dos métodos utilizando um número pequeno de imagens de CT.

O presente estudo explora os conceitos de morfologia matemática, aplicados a imagens médicas, usando a Transformada Imagem-Floresta (IFT) para o projeto dos operadores principais.

1.4 Contribuição principal

A contribuição principal deste projeto é denominado ALTIS — *Automatic Lung and Trachea Image Segmentation*, um método automatizado para segmentação dos pulmões e traqueia, capaz de concluir a segmentação em poucos segundos. O ALTIS consiste de uma sequência rápida de operações de processamento de imagem baseadas em características dos objetos e da imagem. Tais características são robustas para atender a maioria das variações de aparência e forma de pulmões normais e anormais. As operações são baseadas na IFT pois o seu tempo de processamento é pseudo-linearmente proporcional ao número de voxels em consideração [11]. Além disso, a execução da IFT pode ser restringida apenas no volume de interesse, evitando o processamento desnecessário de outras regiões da imagem.

Para uma dada imagem de CT, o método ALTIS primeiramente identifica o volume de interesse assumindo que o volume de ar dos pulmões e da traqueia formam o maior componente conexo com voxels escuros cercado por tecidos mais claros. A partir dessa premissa normalmente válida (*i.e.*, premissa que é verdadeira para todas as imagens testadas), a identificação é realizada utilizando um método de realce que irá ressaltar o volume de interesse das demais estruturas. Por meio dessa operação, é possível obter a localização espacial dos pulmões e da traqueia na imagem, sendo um processo fundamental para a segmentação.

Uma vez que o volume de ar é identificado, é necessário delimitar a região espacial de cada um dos pulmões e da traqueia. Como modelos de forma eventualmente falham em casos de bruscas mudanças de forma e a limiarização não consegue dividir um componente conexo em seus objetos constituintes, foi adotada uma abordagem de crescimento de regiões baseada em competição ótima de sementes para realizar o delineamento.

O método de crescimento de regiões baseado em competição ótima de sementes exige que marcadores sejam estimados dentro de cada objeto de interesse e no fundo. Assu-

mindando que os pulmões são mais largos do que a traqueia (o que é normalmente válido), marcadores externos (de fundo) e internos de cada um dos pulmões são estimados por meio do algoritmo da IFT que aplica simultaneamente operações morfológicas de dilatação e erosão no volume de interesse. Como a traqueia é uma estrutura longa e fina, a operação de erosão não retorna marcadores nessa região. Desta forma, assumindo que a traqueia é um objeto longo com região distante dos pulmões na parte superior da imagem, marcadores internos à traqueia são estimados por meio de outro algoritmo da IFT baseado no comprimento de caminhos geodésicos a partir dos marcadores dos pulmões sobre o volume de interesse.

Finalmente, os pulmões e a traqueia são delineados por meio de uma última IFT que realiza a competição de sementes ótimas — *i.e.*, cada voxel é conquistado pelo marcador que oferecer um caminho ótimo para ele e cada objeto é definido pelos voxels cujos caminhos tem raiz em seu marcador interno. Nessa sequência de IFTs, informações computadas pela IFT anterior são usadas na seguinte para evitar redundância de operações e deixar o método como um todo mais rápido.

O método ALTIS foi extensivamente avaliado em uma grande quantidade de imagens de CT (aproximadamente de 1750 imagens) formada tanto por bases de dados internas como públicas. Devido a sua robustez, ALTIS consegue segmentar imagens em que outros métodos teriam dificuldades, como mostra a Figura 1.5. Entretanto, a presença de embolismo pulmonar, pneumonia ou gases intestinais podem comprometer o resultado da segmentação pelo ALTIS. Isso ocorre pois tais situações afetam a textura e a forma dos pulmões, podendo prejudicar a identificação do volume de interesse.

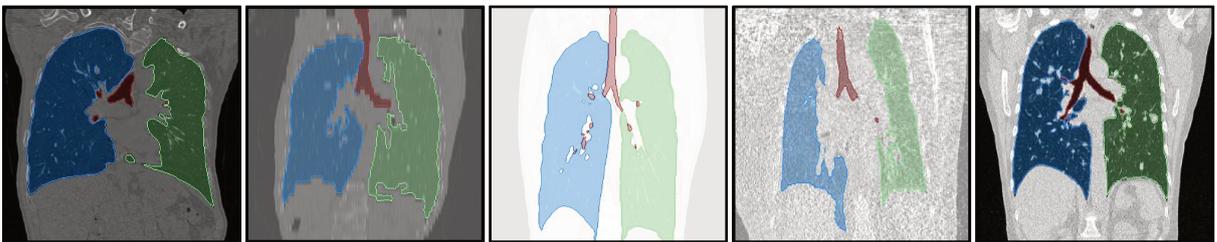


Figura 1.5: Exemplos de resultados de segmentações dos pulmões e da traqueia realizado pelo ALTIS.

1.5 Organização da Dissertação

Durante este capítulo, foi apresentada uma introdução sobre o problema abordado por esta dissertação, a análise do problema, os trabalhos existentes na área, os objetivos do trabalho e suas contribuições. O capítulo 2 apresenta a fundamentação teórica, definindo conceitos básicos e necessários para o entendimento do trabalho, junto com a explicação dos operadores utilizados pelo ALTIS. O capítulo 3 apresenta uma revisão bibliográfica mais detalhada sobre os métodos da literatura. O capítulo 4 apresenta um aprofundamento do método ALTIS, mostrando os algoritmos e uma explicação mais detalhada de cada etapa de sua execução. O capítulo 5 apresenta os detalhes dos experimentos realizados, como organização da base de dados, métodos comparados, métricas, metodologia dos

experimentos, e uma discussão sobre os resultados obtidos. Por fim, o capítulo 6 apresenta a conclusão do trabalho, revisando as maiores contribuições e trabalhos futuros.

Capítulo 2

Conceitos Fundamentais

Neste capítulo serão retratados os conceitos básicos necessários para a realização do trabalho. Inicialmente são apresentadas algumas noções sobre tomografia computadorizada de raios-X, mencionando a orientação do paciente, e características dos protocolos de aquisição. Em seguida, é feita a abstração de uma imagem de CT como um grafo, que é um passo fundamental para a discussão sobre a formulação da IFT. Então, serão apresentadas possíveis aplicações da IFT em operadores de processamento de imagem.

2.1 Tomografia Computadorizada de Raios-X

A tomografia computadorizada, é um exame não invasivo semelhante à radiografia de Raios-X onde é utilizado o mesmo tipo de raio para obter imagens de partes internas do paciente, como ossos, órgãos e outras estruturas. A partir de projeções transversais (também chamadas de “fatias” ou “cortes”), o tomógrafo reconstrói a imagem 3D (volume) de uma região do corpo do paciente.

Existem três tipos principais de cortes, também chamados de planos: transversal (axial), sagital e coronal. O plano axial é definido como qualquer plano transversal que passa através do corpo, dividindo-o em porções superior e inferior. O plano sagital é qualquer plano longitudinal que divide o corpo em partes direita e esquerda. E o plano coronal é representado por qualquer plano longitudinal que divide o corpo em partes anterior e posterior. A Figura 2.1 mostra um exemplo destes cortes em uma imagem de tomografia do tórax.

O método ALTIS assume que a orientação do paciente na imagem de tomografia seja de inferior para superior ao longo do plano axial (eixo z), da esquerda para a direita ao longo do plano sagital (eixo x) e de anterior para posterior ao longo do plano coronal (eixo y). Esta orientação pode ser automaticamente gerada a partir das informações presentes no arquivo de protocolo DICOM das imagens de CT.

A qualidade de uma imagem de CT é afetada por vários componentes e parâmetros técnicos, como dose de radiação e tempo de exposição a ela. Apesar de sempre se almejar imagens com alta resolução e detalhes bem definidos, altas doses de radiação, principalmente para pacientes pediátricos, são um problema. Os impactos da diminuição na dose de radiação está diretamente ligado à qualidade da imagem, influenciando na sua reso-

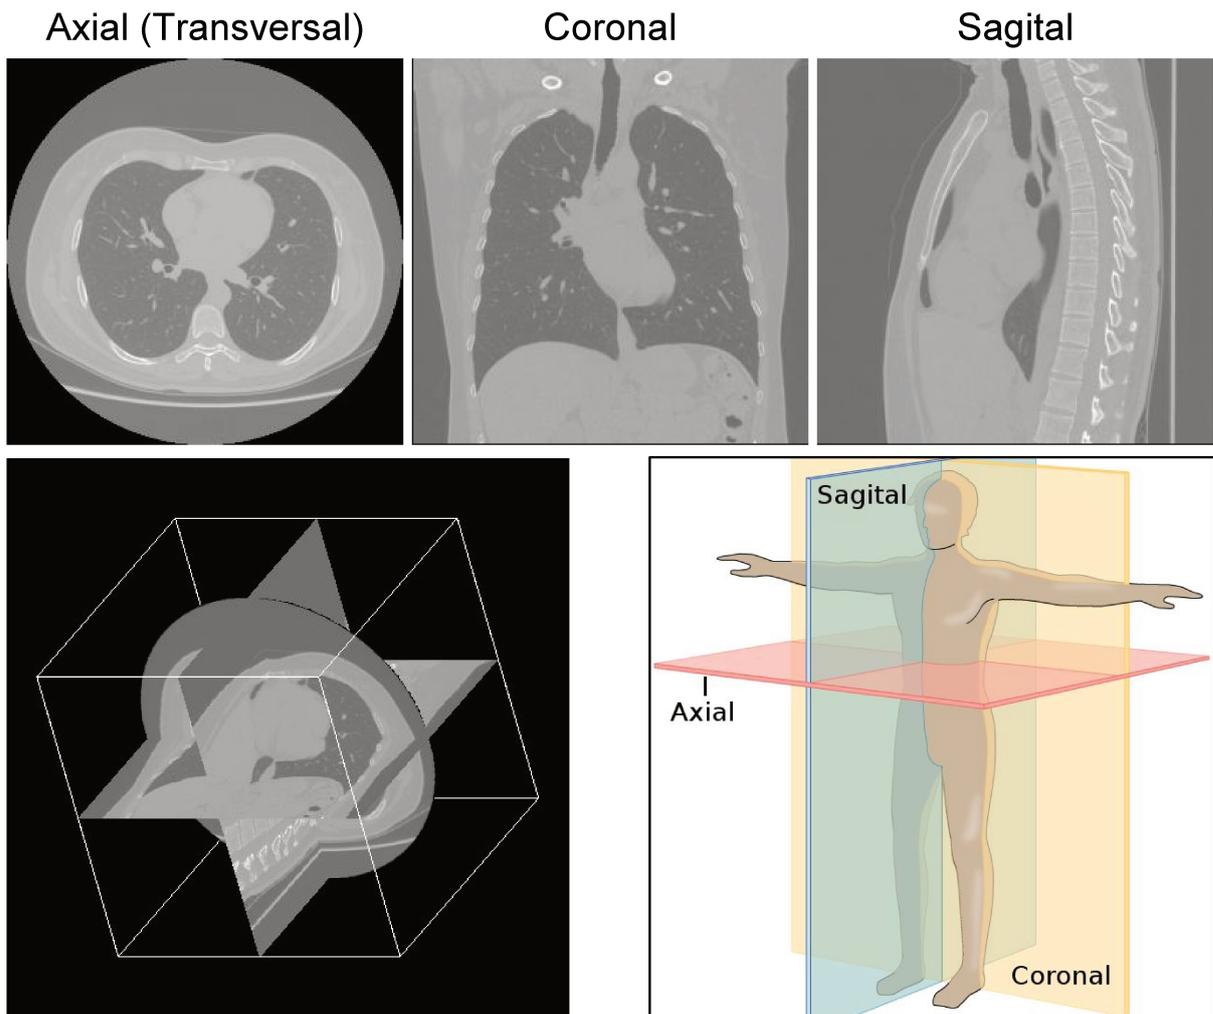


Figura 2.1: Primeira linha apresenta os cortes dos planos axial, sagital, e coronal. A segunda linha mostra como os planos estão dispostos em uma imagem de CT, seguido pela disposição dos planos no paciente².

lução, espessura das fatias e na presença de ruídos. Portanto, existem situações em que métodos de pré-processamento, como filtros lineares, devem ser aplicados na imagem de forma a diminuir os problemas provenientes de sua aquisição (Figura 1.2).

2.2 Notações e Definições

Uma imagem \hat{I} é definida como um par (D_I, I) , onde $D_I \subset \mathbb{Z}^n$, com $n \in \mathbb{N}^*$, é um conjunto finito de spels que define o domínio espacial da imagem, sendo spel uma abreviatura para *spatial element* que representa qualquer elemento no domínio do espaço da imagem, podendo ser um pixel (2D) ou voxel (3D). Enquanto que $I : D_I \rightarrow \mathbb{R}^m$, onde $m \in \mathbb{N}^*$ representa a quantidade de canais de \hat{I} , é um mapeamento que atribui para cada spel $p \in D_I$ um vetor de atributos $I(p)$ com m valores reais. Neste trabalho, as imagens de

²Imagem retirada de <https://figures.boundless-cdn.com/19472/full/figure-33-01-04.jpeg>, último acesso em 31 de Agosto, 2017

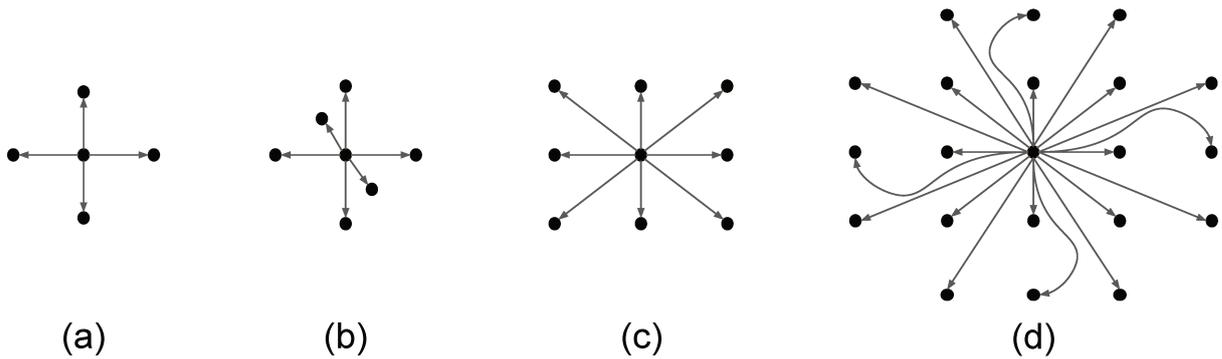


Figura 2.2: Exemplos de relações de adjacência. (a) Vizinhança-4 em 2D, (b) vizinhança-6 em 3D, (c) vizinhança-8 em 2D e (d) vizinhança-20 em 2D.

CT são volumétricas, em escala de cinza, e o vetor de atributos I possui apenas valores inteiros, então $I : D_I \rightarrow \mathbb{Z}^m$, com $n = 3$ e $m = 1$.

Uma imagem \hat{I} pode ser interpretada como um grafo direcionado (D_I, A) , cujos vértices são os spels da imagem (D_I) e as arestas são pares de spels definidos por uma relação de adjacência A . Uma *relação de adjacência* $A \subset D_I \times D_I$ é um relação binária não reflexiva entre os spels de \hat{I} baseada em algum critério de distância e representada por um par ordenado (p, q) , onde $p, q \in D_I$. Ou seja, dois spels p e q são considerados adjacentes se a distância entre eles satisfizer um critério pré determinado. Assim, $A(p)$ representa o conjunto de todos os adjacentes de p . Um exemplo de relação de adjacência é a adjacência esférica, com raio $\gamma \geq 1$ e pode ser definida como

$$A_\gamma: \{(p, q) \in D_I \times D_I \mid \|q - p\| \leq \gamma\}. \quad (2.1)$$

Onde $\|q - p\|$ é a norma de distância Euclidiana entre os spels p e q . Alguns exemplos de relação de adjacência são apresentados na Figura 2.2.

Um *caminho* π é uma sequência finita de spels distintos $\pi = \langle p_1, p_2, p_3, \dots, p_k \rangle$, com $(p_i, p_{i+1}) \in A$ para $1 \leq i \leq k - 1$. Um caminho é dito ser trivial se possuir um único spel, isto é $\pi = \langle p_1 \rangle$, e não trivial caso contrário. Um pixel q é dito estar conexo com outro pixel p se existir um caminho de p a q . Em um grafo, um componente conexo é um subgrafo onde para quaisquer dois vértices existe pelo menos um caminho ligando esses vértices.

Uma função de conectividade $f(\pi)$ associa um valor escalar a qualquer caminho da imagem, com base em propriedades da imagem ao longo deste caminho. Por exemplo, para a segmentação de um objeto, características locais da imagem e do objeto (cor, textura e forma) podem ser exploradas no cálculo de $f(\pi)$ para indicar a força de conexidade entre os nós terminais através do caminho π . Toda função de conectividade precisa de uma regra de inicialização e de extensão do caminho. Um exemplo comum é a função de conectividade de soma, definida por

$$\begin{aligned} f_{soma}(\langle q \rangle) &= h(q) \\ f_{soma}(\pi_p \cdot \langle p, q \rangle) &= f_{soma}(\pi_p) + w(p, q) \end{aligned} \quad (2.2)$$

Onde π_p indica que o prefixo tem término em um nó p , $h(q)$ é um valor inicial para caminhos triviais, e $(s, t) \in A$ e $w(s, t)$ é o peso fixo e não negativo atribuído à aresta (s, t) .

2.3 Transformada Imagem-Floresta

A Transformada Imagem-Floresta é um arcabouço para desenvolver operadores de processamento de imagem baseados em conectividade ótima [11]. Para um dado grafo de imagem (D_I, A) , uma função de conectividade $f(\pi_q)$ deve ser definida para qualquer caminho no conjunto Π_q de todos os possíveis caminhos com término em q , incluindo os caminhos triviais $\pi_q = \langle q \rangle$. O algoritmo geral da IFT essencialmente minimiza (ou maximiza) o mapa de custo $C(q) = \min_{\pi_q \in \Pi_q} \{f(\pi_q)\}$ (ou $C(q) = \max_{\pi_q \in \Pi_q} \{f(\pi_q)\}$) por meio do particionamento do grafo em uma floresta de caminhos ótimos P (OPF) — *i.e.*, um mapa sem ciclos que atribui a q ou um predecessor $P(q) = p \in D_I$ no caminho ótimo π_q^* ou o símbolo $P(q) = nil \notin D_I$ quando q é raiz do mapa. Isso implica que cada caminho ótimo π_q^* é armazenado de trás para frente em P .

No modelo tradicional da IFT, os caminhos ótimos são calculados para $\Pi_q, \forall q \in D_I$. Entretanto, em típicas aplicações da IFT, a função de conectividade é restrita em uma busca por caminhos ótimos iniciados em $S \subseteq D_I$, chamados de sementes ou marcadores. Com isso, a função de conectividade inicial para as sementes é $h(q) = 0, \forall q \in S$ e $h(p) = +\infty, \forall p \in D_I \setminus S$. Caso seja atribuído rótulos para as sementes e esses mesmo rótulos sejam disseminados através dos caminhos ótimos, o algoritmo da IFT é adaptado para uma propagação de rótulos, com aplicações em segmentação

O algoritmo da IFT é a generalização do algoritmo de Dijkstra para uma função de conectividade menos restritiva [8]. O algoritmo é iniciado a partir de um mapa de predecessores com apenas caminhos triviais. Em cada iteração, um caminho ótimo π_p^* é estendido por uma aresta $\langle p, q \rangle$, resultando em $\pi_p^* \cdot \langle p, q \rangle$ toda vez que o custo $f(\pi_p^* \cdot \langle p, q \rangle)$ for menor do que o custo $f(\pi_q)$ do caminho atual com termino em q . Nessa situação, π_q é substituído por $\pi_p^* \cdot \langle p, q \rangle$. Em outras palavras, os mínimos de um mapa de custo inicial C_0 , onde $C_0(q) = f(\langle q \rangle) \forall q \in D_I$, competem entre si para estender os caminhos para seus vértices adjacentes com maior força de conexão, semelhante a um método de crescimento de regiões com raízes. No final, as raízes da floresta são os mínimos do mapa de custo final $C(q) \leq C_0(q), \forall q \in D_I$. A IFT é descrita no Algoritmo 1.

Algoritmo 1 – ALGORITMO GERAL DA IFT

ENTRADA: Imagem de entrada $\hat{I} = (D_I, I)$, relação de adjacência A , e função de conectividade f .
 SAÍDA: Floresta de caminhos ótimos P e seu mapa de custo C .
 AUXILIARES: Fila de prioridades Q e variável tmp .

1. **Para Cada** $p \in D_I$ **Faça**
2. \perp Atribua $C(p) \leftarrow f(\langle p \rangle)$, $P(p) \leftarrow nil$, e insira p in Q .
3. **Enquanto** $Q \neq \emptyset$ **Faça**
4. \perp Remova p de Q tal que $p = \arg \min_{q \in Q} \{C(q)\}$.

5. **Para Cada** $q \in A(p) \mid q \in Q$ **Faça**
6. Atribua $tmp \leftarrow f(\pi_p \cdot \langle p, q \rangle)$.
7. **Se** $tmp < C(q)$ **Então**
8. Atribua $C(q) \leftarrow tmp$ e $P(q) \leftarrow p$.
9. **Retorne** P e C .

Mingireanov Filho *et al.* (2013) [30] fez uma analogia sobre a ideia por trás da IFT, relacionando com o particionamento da população em comunidades. Pode-se assumir que cada indivíduo tem o desejo de se tornar o líder de uma comunidade. Os indivíduos com maior desejo oferecem aos seus conhecidos um recompensa para se juntarem a sua comunidade. Se a recompensa oferecida for maior do que a recompensa/desejo atual do conhecido, então, este concorda em trocar de comunidade. Os verdadeiros líderes são aqueles cujos desejos são tão fortes que nenhuma recompensa pode atraí-lo para outra comunidade. A recompensa é propagada a partir do líder através dos membros de sua comunidade, que não oferecem uma recompensa maior do que a que já possuem. Portanto, a população é dividida em comunidades numa ordem não-incremental de recompensas e desejos, tal que cada indivíduo pertence à comunidade que lhe oferecer a maior recompensa.

A IFT representa a “população” de uma imagem como uma rede, em que os indivíduos (spels) estão conectados com seus conhecidos (spels vizinhos). Mais especificamente, essa rede pode ser representada por um grafo, onde os nós são spels da imagem, as arestas são dadas por uma relação de adjacência e os caminhos entre dois nós quaisquer são estimados por meio de uma função de conectividade (recompensa/desejo). A figura 2.3 apresenta uma simples e resumida aplicação do algoritmo da IFT para a função de conectividade f_{max} (Equação 2.3).

$$\begin{aligned}
 f_{max}(\langle q \rangle) &= \begin{cases} 0 & \text{if } q \in S, \\ +\infty & \text{caso contrário.} \end{cases} \\
 f_{max}(\pi_p \cdot \langle p, q \rangle) &= \max\{f_{max}(\pi_p), w(p, q)\}.
 \end{aligned} \tag{2.3}$$

2.4 Uso da Transformada Imagem-Floresta

Nesta seção são mencionados alguns operadores e aplicações que podem ser implementados pela IFT. Apesar dos exemplos serem para imagens em escala de cinza, eles podem ser facilmente estendido para imagens coloridas alterando a função de conectividade para levar em consideração todas as bandas da imagem.

A IFT pode ser usada para implementação de filtros. Um exemplo é o filtro de fechamento de bacias. Esse filtro tem o propósito de remover áreas dentro de um objeto que são mais escuras do que as regiões que as cercam. Assim, os valores de intensidade das regiões do entorno se propagam para essas áreas com menor brilho. Para isso, pode-se usar a função de conectividade f_{pico} (Equação 2.4) e um conjunto de sementes que corresponde à borda externa do objeto. O mapa de custo C resultante será o resultado da aplicação do filtro na imagem. A Figura 2.4 mostra um exemplo desse filtro.

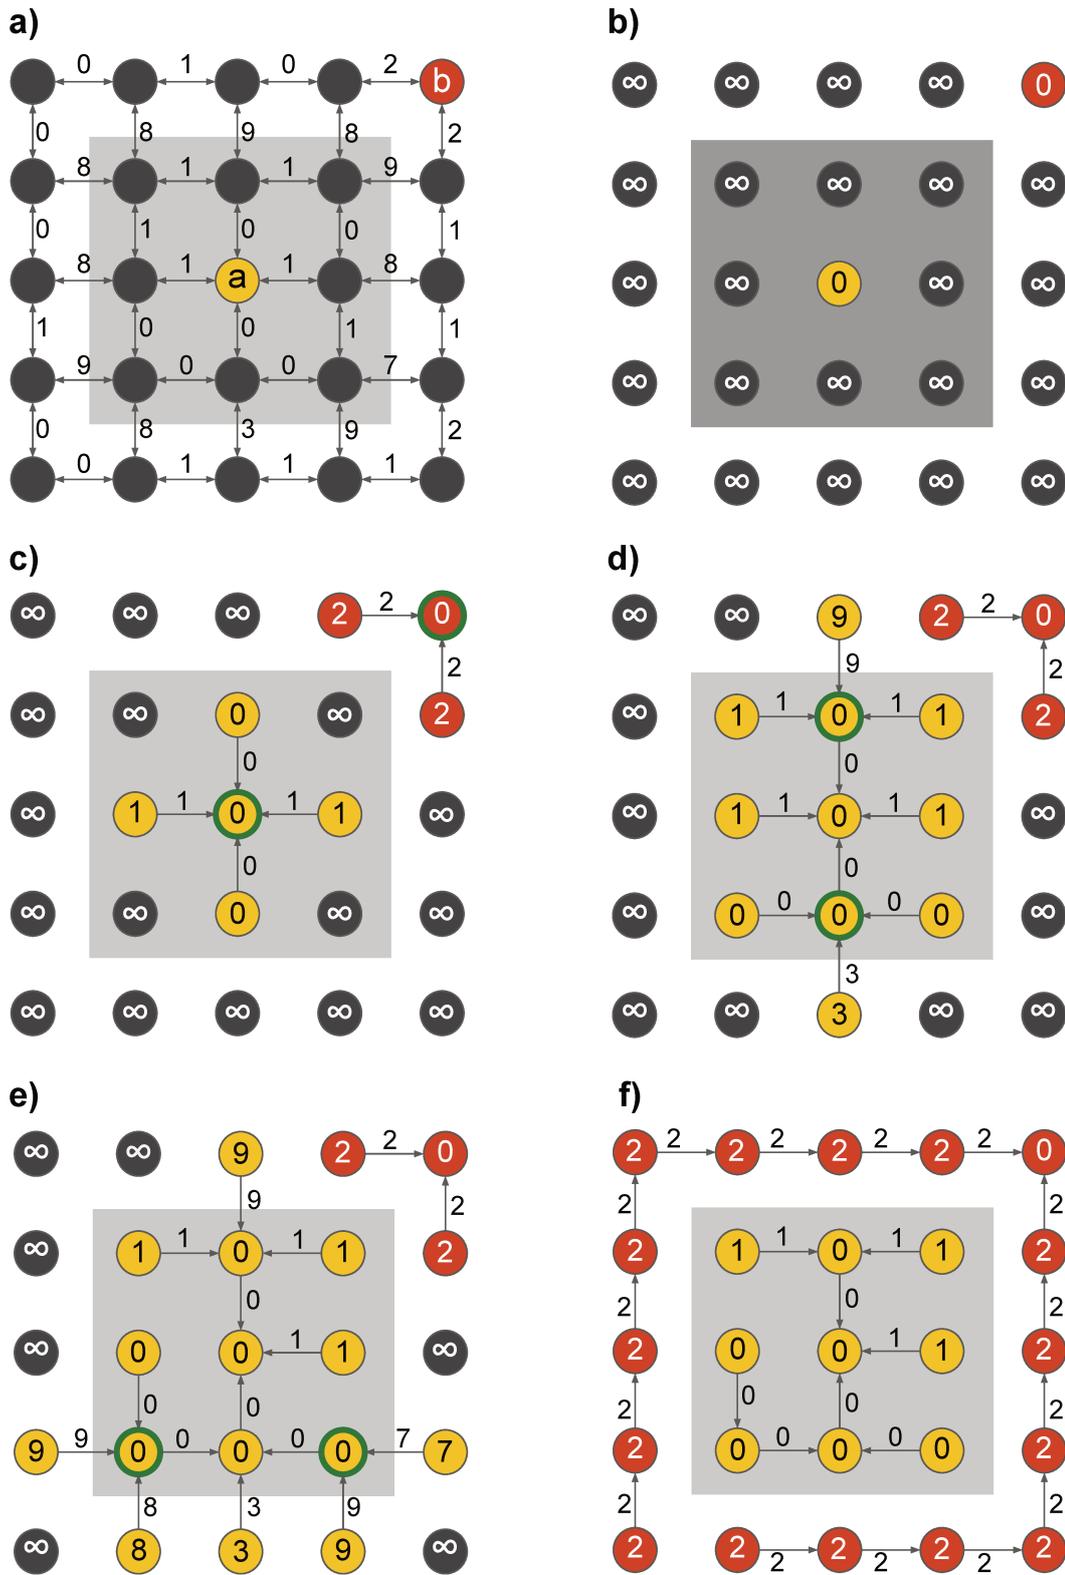


Figura 2.3: A imagem (a) apresenta o grafo original com pesos nas arestas e duas sementes 'a' e 'b'. A imagem (b) apresenta o mapa de custos inicial. As iterações de (c)-(e) particionam o grafo em uma OPF com dois rótulos (vermelho e amarelo). Em (f), a OPF resultante mostra que o rótulo amarelo segmentou o objeto.

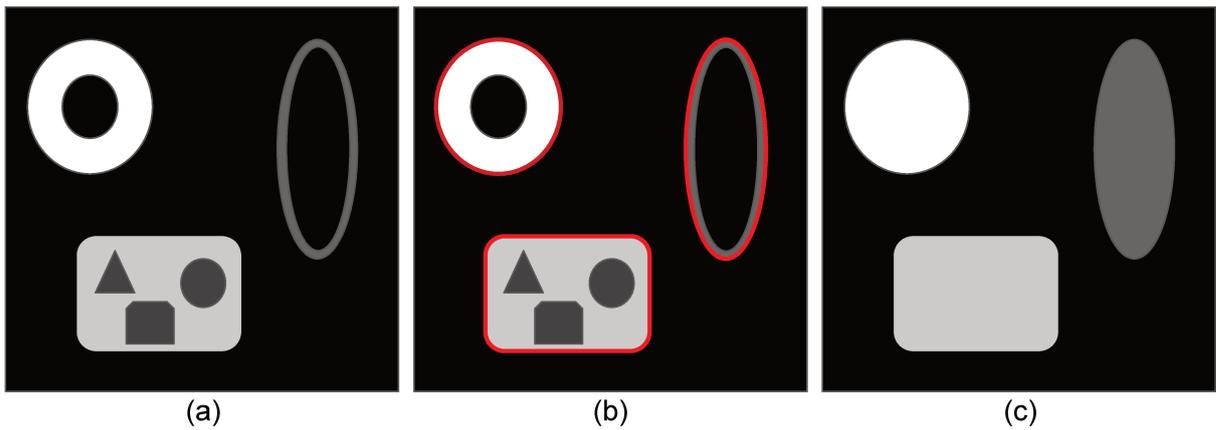


Figura 2.4: Exemplo de execução do filtro de fechamento de bacias pela IFT em uma imagem de exemplo (a). As sementes são os pontos vermelhos em (b) e (c) representa o resultado do filtro.

Seja \hat{I} uma imagem e \hat{B} uma máscara binária que representa algum objeto de interesse de \hat{I} . A transformada de distância calcula as distâncias mínimas dos elementos de \hat{B} até as bordas do objeto. Qualquer medida de distância pode ser utilizada para o cálculo da distância até a borda, como Euclidiana, Manhattan ou Geodésica. Como a IFT já calcula os caminhos mínimos, a transformada distância é obtida pelo mapa de custo final C da própria IFT com a função de conectividade sendo uma das medidas de distância. Ainda é possível modificar o algoritmo da IFT de forma a restringir o cálculo da transformada somente para elementos contidos no objeto de \hat{B} .

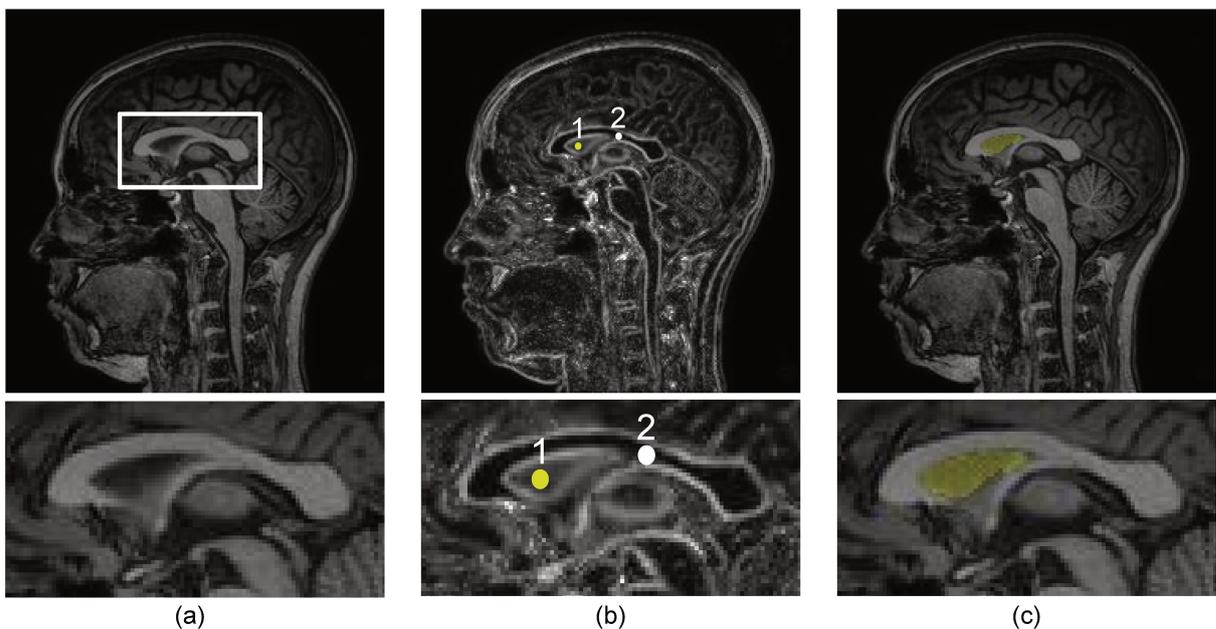


Figura 2.5: Exemplo de execução da transformada de *watershed* pela IFT em uma imagem de ressonância magnética de um cérebro (a). (b) Imagem de gradiente com uma semente dentro do septo pelúcido (1) e uma semente de fundo (2). (c) Segmentação derivada da transformada *watershed* pela IFT

A transformada de *Watershed* é um famoso e poderoso método de segmentação no processamento de imagens morfológicas. Ele é inspirado em um princípio físico muito conhecido na geografia: se uma gota de água cai em uma superfície topográfica, esta segue o maior declive até alcançar o vale [3]. Suponha que a imagem seja uma superfície 3D, onde $I(t)$ seja a altitude do spel t e os objetos de interesse sejam delimitados por cumes que são maiores do que qualquer outra região tanto dentro como fora do objeto. Essa situação ocorre com a magnitude do gradiente da imagem, onde a região com baixa magnitude (vale) corresponde a uma região homogênea e possivelmente o mesmo objeto.

Por meio da IFT, é possível separar os objetos escolhendo uma ou mais sementes dentro de cada objeto, com rótulos diferentes para cada uma. Utilizando a função f_{pico} (Equação 2.4) definida pela maior intensidade ao longo do caminho e propagando o rótulo do predecessor, obtém-se o resultado da segmentação com as características essenciais da transformada de *Watershed*. A Figura 2.5 ilustra essa operação.

$$\begin{aligned} f_{pico}(\langle q \rangle) &= I(q) \\ f_{pico}(\pi_p \cdot \langle p, q \rangle) &= \max\{f_{pico}(\pi_p), I(q)\} \end{aligned} \tag{2.4}$$

Onde o valor inicial do spel raiz q é o seu próprio brilho $I(q)$, π_p é um caminho qualquer com término em p , e $\langle p, q \rangle \in A$. A função 2.4 é semelhante a função 2.3 com $w(p, q) = I(q)$.

2.5 Conclusão

Durante este capítulo foi apresentado a definição de imagem digital de tomografia de raios-X, juntamente com a introdução de conceitos de processamento de imagem, a forma de representar uma imagem como um grafo, e um arcabouço para projeto e implementação de operadores em imagens, chamado Transformada Imagem-Floresta, o qual reduz essas operações a um cálculo de uma floresta de caminhos ótimos seguido por operações locais sobre os atributos dessa floresta.

Capítulo 3

Trabalhos Relacionados

Trabalhos reportados na literatura referentes à análise por computador de radiografias do tórax são datados desde a década de 60 [4, 29]. Durante a década de 90, com os avanços tecnológicos na área de processamento de imagem digital e de sistemas de computador voltados ao auxílio de especialistas para a realização de diagnósticos, avanços consideráveis no diagnóstico automático de doenças pulmonares foram obtidos [19, 43]. Grande parte destes trabalhos necessitam como um primeiro passo, a extração de uma área, ou volume, de interesse (ROI ou VOI), como por exemplo os pulmões ou o sistema respiratório. Consequentemente, novas abordagens para a segmentação dos pulmões tem sido exploradas [24, 26].

Os métodos de segmentação dos pulmões podem ser divididos em três classes principais: baseados em limiarização, crescimento de regiões e modelos de forma. Normalmente a traqueia é segmentada separadamente e devido a sua forma irregular e por estar conexa com os pulmões, métodos mais elaborados e específicos para segmentá-la são usados, tais como crescimento de regiões [2, 16, 34, 40], FC [38, 39] ou classificação de voxels [23]. Assim, esta taxonomia foi criada levando em consideração apenas a estratégia de segmentação dos pulmões.

Durante este capítulo serão detalhadas as técnicas encontradas na literatura para segmentação dos pulmões e da traqueia, incluindo aquelas apresentadas na seção 1.2.

3.1 Métodos baseados em Limiarização

Os métodos baseados em limiarização pertencem à classe mais básica de segmentação de imagem. A limiarização pode ser definida como sendo uma classificação binária de spels com base nos valores de intensidade da imagem. A equação 3.1 descreve o procedimento de limiarização da imagem \hat{I} para uma determinada intensidade T , onde $I'(p)$ é o valor do spel p na imagem resultante \hat{I}' .

$$I'(p) = \begin{cases} 1, & I(p) \geq T \\ 0, & I(p) < T \end{cases} \quad (3.1)$$

Métodos de limiarização são muito eficazes e rápidos para segmentar objetos que possuem um contraste muito bem definido com os outros componentes da imagem. Por

esse motivo, esta classe de métodos tem um alto desempenho em imagens de CT. Contudo, são muito sensíveis à ruídos e anomalias, uma vez que informações espaciais e da forma do objeto (neste caso, os pulmões) não são levados em consideração. Além disso, esses métodos excluem tecidos claros dentro dos pulmões, que são importantes para a análise da imagem.

A limiarização por si só não resolve o problema da segmentação dos pulmões e traqueia, por isso os métodos baseados em limiarização utilizam outras técnicas para separação desses objetos. Nesta seção são discutidos os métodos em [16], e [2].

Hu *et al.* [16] propuseram um método automático de segmentação dos pulmões baseado em limiarização. Primeiramente, é determinado um limiar assumindo que a imagem de CT contém somente dois tipos de voxels: 1) aqueles com brilho mais intenso localizados dentro do corpo e na parede do tórax (voxels do corpo), e 2) aqueles com brilho mais fraco dentro dos pulmões, da traqueia e no ar ao redor do paciente (voxels de ar). Esse limiar é determinado de forma a separar os voxels do corpo dos voxels de ar.

Após o processo de limiarização, outras estruturas de baixa intensidade como gases intestinais e ruídos oriundos da aquisição podem ser categorizados como voxels de ar. Para reduzir esse problema, uma rotulação 3D de componentes conexos é usada para identificar voxels dos pulmões e da traqueia. Já os voxels de fundo são excluídos removendo regiões conectadas com as bordas da imagem. Os problemas dessa etapa já foram comentadas na seção 1.2.

Com os voxels de pulmão e da traqueia resultantes da etapa anterior, a remoção da traqueia é feita por meio de uma operação chamada *closed-space dilation* [28], que se assemelha a um crescimento de regiões aplicado corte-a-corte na imagem original. Para isso, marcadores dentro da traqueia são selecionados nos primeiros cortes axiais da imagem detectando-a como um componente circular e cheio de ar. Os problemas dessa abordagem já foram discutidos na seção 1.2 (Figura 1.4). A remoção da traqueia tem como objetivo desconectar os dois pulmões, tornando a separação deles um problema de rotulação de componentes conexos. Todavia, existem situações em que as partes anterior e posterior dos pulmões ficam conectadas, formando um único objeto (Figura 1.4). Para resolver este problema, é realizada uma erosão morfológica em cada fatia em que os pulmões estão conectados. Em seguida, para restaurar as bordas da segmentação, é aplicada uma dilatação morfológica.

Por fim, o método foi avaliado em 24 imagens de CT tiradas de 8 pessoas saudáveis. Dois analistas segmentaram manualmente os pulmões esquerdo e direito dessas imagens. A precisão do método foi calculada pela média, raiz do erro quadrático (*root mean square* — RMS) e valor máximo das distâncias mínimas da borda da segmentação manual até a borda da segmentação gerada pelo método. A distância média foi de cerca de 0.5 spels, o RMS foi de aproximadamente 1 spel e a distância máxima foi por volta de 5 spels. O método leva em média de 2 a 3 minutos para ser executado e mais 1 ou 2 minutos para a suavização.

Armato *et al.* [2] também propuseram um método de segmentação dos pulmões baseado em limiarização. A maioria das etapas deste método é realizada em cortes axiais 2D individuais da imagem. Primeiramente, um perfil de níveis de cinza é construído com os pixels da diagonal de cada corte da imagem. A partir deste perfil, um valor de limi-

arização T é estabelecido e aplicado, gerando uma imagem binária para cada corte. Em seguida, o tórax é extraído selecionando o maior componente conexo de cada imagem.

Em sequência, um histograma de níveis de cinza é criado a partir um conjunto de pixels da região do tórax e analisando a distribuição dos pixels nesse histograma, um novo limiar T' é estabelecido. Com o intuito de extrair o sistema respiratório contido na imagem do tórax, uma limiarização inversa é aplicada para destacar todos os pixels que possuem brilho menor que T' . Caso essa limiarização resulte em um único objeto em algum corte da imagem, então pode-se concluir que os pulmões se fundiram. Para separá-los, os pixels da linha de junção anterior são removidos.

A traqueia é identificada automaticamente selecionando o ponto com menor brilho numa região próxima ao centro de massa do tórax no último corte axial da imagem. Esse ponto é então expandido para os outros cortes axiais até que haja um crescimento abrupto de sua área, indicando que a traqueia chegou nos pulmões pelos brônquios. Isso pode gerar problemas caso o topo dos pulmões também esteja visível no último corte da imagem, desta forma, o método pode selecionar incorretamente o topo de um dos pulmões como sendo traqueia. A Figura 1.4 mostra um exemplo de uma imagem com essa característica.

Armato *et al.* validaram o método de segmentação dos pulmões aplicando-o em situações reais, como na segmentação de nódulos pulmonares e medição da espessura de mesoteliomas. Foram usadas duas bases de dados com um total de 60 imagens de CT. De 82 nódulos em toda a base, apenas 4 (4.9%) ficaram fora dos pulmões segmentados. Enquanto que para o mesotelioma, o grau de correlação entre as medidas manuais e do método de segmentação foi de 0.990.

3.2 Métodos baseados em Crescimento de Regiões

A ideia principal por trás dos métodos de segmentação baseados em crescimento de regiões é, como o próprio nome diz, crescer regiões a partir de sementes rotuladas estimadas em certas partes da imagem. Ou seja, cada semente é comparada com seus spels vizinhos e caso uma função critério seja atendida, é dito que o spel vizinho pertence à mesma região que a semente. Ainda, outros métodos baseados em crescimento de regiões foram apresentados na literatura, tais como transformada de *watershed* [5], FC [39] e corte em grafos [6]. Um princípio comum entre eles é de que sementes dentro de um objeto estão fortemente conectadas com os outros elementos desse objeto por uma sequência de spels adjacentes com valores de intensidade similares.

Para aplicações como segmentação de pulmões em imagens de CT, os métodos baseados em regiões são considerados mais eficientes, robustos e precisos do que os métodos baseados em limiarização. Entretanto, esta classe de métodos requer um seleção de sementes precisa e robusta além de uma função critério que separe estruturas com brilho similar e que estão encostadas umas nas outras. Nesta seção são discutidos os métodos em [34], [27] e [9]

Shoujaili *et al.* [34] desenvolveram um método para segmentação de pulmões utilizando a transformada de *watershed*. A transformada de *watershed* é um método que encontra

“bacias hidrográficas” na imagem tratando spels escuros como uma superfície baixa e spels mais claros como relevos mais altos. Para realizar essa transformada, é necessário computar o gradiente da imagem original e estimar marcadores dentro e fora do objeto a ser segmentado, para evitar o problema de super-segmentação. Assim, a imagem de gradiente é obtida aplicando o operador de Sobel, e para estimar os marcadores internos, os spels com valores menores que -400 HU são selecionados, retornando os pulmões com a traqueia e o ar em volta do paciente. Componentes anexados com as bordas da imagem são excluídos, restando somente os pulmões e a traqueia. O problema dessa implementação já foi comentado no método de [16] (Seção 1.2). Ao fim desta etapa, todos os voxels dos pulmões são considerados marcadores.

A traqueia é localizada como o componente circular perto do centro dos últimos cortes axiais, e marcadores são selecionados dentro dela. Em seguida, os marcadores se expandem nos cortes subsequentes até que haja um crescimento muito grande na área da traqueia, indicando que os marcadores chegaram nos pulmões. Essa etapa é muito parecida com a do método de [2] e conseqüentemente, possui os mesmos riscos já mencionados.

Os marcadores externos são calculados por meio da aplicação de um operador morfológico de dilatação dos marcadores internos já estimados. Uma vez que todos os marcadores tenham sido computados, a transformada de *watershed* é aplicada sobre a imagem de gradiente resultando na segmentação dos pulmões.

Os autores não utilizaram nenhuma métrica para medida de acurácia, eficiência ou robustez do método. Além disso, o tempo de execução também não foi anunciado. Contudo, foi reportado a aplicação do método proposto por [34] em mais de 180 imagens de CT.

Mansoor *et al.* [27] propuseram um método automático para segmentação de pulmões baseado em crescimento de regiões chamado de *Pathological Lung Segmentation* (PLS). O PLS utiliza a técnica FC para obter uma segmentação inicial dos pulmões, opcionalmente separando os pulmões e extraíndo a traqueia. A técnica FC necessita que marcadores dentro dos pulmões direito e esquerdo sejam selecionados. Essa seleção é feita por meio de uma limiarização de um valor fixo de -55 HU para extrair a região dos pulmões. Em seguida uma amostragem de pontos é feita em cada um dos pulmões separadamente, e o ponto com menor valor de intensidade em cada pulmão é considerado seu respectivo marcador. Não é possível separar os pulmões utilizando somente a limiarização e mais detalhes sobre isso não foram fornecidos pelos autores.

Além dos marcadores, a segmentação por FC necessita de alguns parâmetros de afinidade que são determinados empiricamente. Centenas de imagens foram usadas para estimativa destes parâmetros. Não foi comentado se estas imagens estão no conjunto de testes, podendo resultar em um super-treinamento. Em seguida, com os marcadores e os parâmetros definidos, a segmentação é realizada. O resultado deste processo é uma máscara binária contendo os pulmões, e a traqueia.

A extração da traqueia é feita utilizando uma transformada 2D de Hough ao longo dos cortes axiais para detectar regiões circulares nos cortes mais altos da imagem. Novamente, pode existir o problema dos pulmões estarem visíveis na parte superior da imagem. Marcadores são estimados dentro da área detectada pela transformada de Hough e novamente o algoritmo FC é executado, segmentando a traqueia. Essa parte do método foi deixado

como opcional de tal forma a não aumentar a complexidade do método como um todo.

Um outro procedimento opcional é a separação dos pulmões direito e esquerdo. Uma transformada de distância é aplicada para estimar um plano de separação dos pulmões, que então é projetado sobre os objetos segmentados, atribuindo novos rótulos aos pulmões.

Experimentos foram executados em uma base com 403 imagens de CT. As métricas utilizadas para comparação foram o coeficiente de DICE e a distância Hausdorff. As médias de 95% de DICE e 19.6 de distância Hausdorff foram obtidas. O método leva de 1 a 15 minutos (quando os pulmões estão muito comprometidos) para realizar a segmentação.

Dai *et al.* [9] propuseram um método para segmentação dos pulmões que precisa de somente uma única iteração e nenhum passo adicional para a separação dos pulmões ou extração da traqueia. Isso é feito por meio do uso de corte em grafos com GMM. O corte em grafo é uma técnica que encontra o corte mínimo em um uma imagem de forma a separar os objetos do fundo. O grafo possui dois vértices terminais com arestas para todos os pixels da imagem, e os pesos de todas as arestas são determinados seguindo uma função de custo previamente estabelecida. Assim, cria-se um corte mínimo baseado nos custos das arestas de forma a separar os dois vértices terminais, segmentando assim os objetos de interesse. Para mais informações sobre corte em grafos veja [7].

A etapa inicial do método é aplicar um filtro gaussiano para remover ruídos gerados na aquisição da imagem. O método de corte em grafos precisa que o usuário selecione sementes de fundo e de objetos. Logo, este método não será considerado no escopo desta dissertação por não ser totalmente automático. Com as sementes selecionadas, elas são modeladas utilizando GMM, calculando assim os pesos das arestas da imagem. Uma vez estabelecidos os pesos das arestas, é feita a segmentação dos pulmões utilizando o algoritmo de corte mínimo.

Os experimentos foram executados em uma base de imagens de CT fornecida pelo Hospital Geral da Universidade de Ningxia, na China. A informação sobre a quantidade de imagens desta base não foi fornecida. A métrica usada foi somente o coeficiente de DICE, com acurácia de 0,9874. O tempo de execução para toda a base foi de 10 a 15 minutos.

3.3 Métodos baseados em Modelos de Forma

A segmentação automática em imagens médicas é uma tarefa desafiadora pois envolve a extração de objetos com formas muito variadas em imagens de baixa qualidade. Muitas vezes, a falta de informação de contraste ou certos artefatos podem levar à segmentações incorretas, conseqüentemente, o delineamento da borda do objeto alvo não pode ser realizado somente pela homogeneidade de brilho da região. Entretanto, mesmo com tais empecilhos, especialistas conseguem delinear o objeto de interesse por conhecerem sua aparência e forma [15]. Assim, métodos baseados em modelos de forma tentam utilizar esse conhecimento prévio sobre a anatomia dos objetos para segmentá-los. Nos últimos anos, o uso dessas informações a priori tem ganhado muita popularidade.

Porém, métodos que não consideram intensidades e variações de forma incomuns estão propensos a falhar. A Figura 3.1 mostra que modelos de forma são um problema

desafiador e métodos baseados nesses modelos podem não ser capazes de capturar todas as possíveis variações de forma dos pulmões. Nesta seção são discutidos os métodos em [35], [33], [40], [36], [17], [37], [44], e [12].

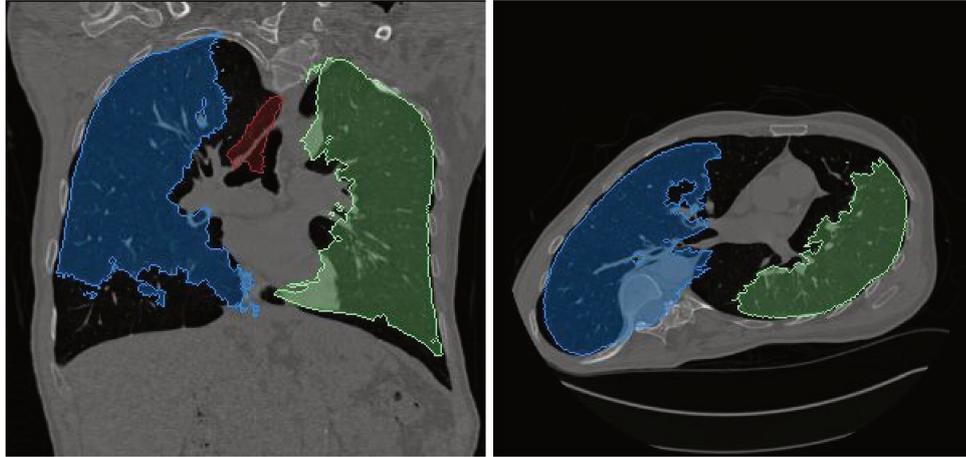


Figura 3.1: Imagem CT de um paciente com escoliose segmentado por dois métodos baseados em Modelos de Forma. A curvatura da coluna vertebral dificulta na segmentação.

Sluimer *et al.* [35] propuseram um método para segmentação de pulmões doentes baseado em registro de imagem. Para a realização do registro, uma imagem de referência foi selecionada de um conjunto de 16 imagens saudáveis de um banco de dados contendo 26 imagens de CT. Novamente tem-se o problema de uma base de dados muito pequena para representar o problema real. O método proposto em [35] é aplicado em cada pulmão separadamente e é dividido em duas etapas principais: registro com um atlas probabilístico e classificação dos voxels incertos.

Primeiramente, todas as imagens saudáveis são registradas no espaço de coordenadas da imagem de referência. Então, um atlas probabilístico é criado para cada pulmão utilizando a média das 15 máscaras binárias deformadas durante o registro das imagens normais. Em seguida, os voxels que possuem probabilidade entre 0 e 1 no atlas probabilístico devem passar pela etapa de classificação dos voxels incertos. Isto é, os voxels que não sabem a qual objeto pertencem, avançam para a próxima etapa. Na etapa de classificação, um vetor de características é computado para cada voxel que ainda não tem um rótulo definido, ou seja, tem probabilidade de ser tanto pulmão como fundo. Em seguida, o classificador kNN (k-vizinhos mais próximos) é utilizado para a classificação. Esse classificador foi escolhido assumindo que pontos próximos no espaço de características são mais similares e consequentemente pertencem à mesma classe. Após essa etapa, as máscaras resultantes dos pulmões direito e esquerdo formam a imagem de segmentação.

Experimentos foram executados nas 10 imagens de CT de pacientes doentes. Os métodos comparados com o proposto foram: o método em [16], e a técnica de classificação de voxels por kNN. As métricas usadas foram DICE, distância de Hausdorff e MADS. O método em [16] falhou na segmentação de 8 das 10 imagens de teste. Entretanto, segmentou corretamente as 15 imagens de pacientes saudáveis. Já o método proposto em [35] teve uma diferença estatisticamente significativa somente na métrica de Hausdorff com relação a segmentação pela classificação de voxels por kNN. Por fim, o método proposto

leva 45 horas para treinamento e criação do atlas probabilístico, o que é feito somente uma vez, e 3 horas para segmentar cada imagem.

Pu *et al.* [33] introduzem um método automático, chamado de Marcha Adaptativa de Bordas (AMB) para segmentação de pulmões e correções de erros causados por nódulos justapleurais. O método é dividido em duas partes: pré-processamento e cômputo da região do pulmão.

O pré-processamento usa um filtro Gaussiano na imagem, de maneira a remover ruídos, seguido por uma limiarização fixa de -500 HU para retornar os tecidos mais claros. Após essa limiarização é aplicado um método de crescimento de regiões em todas as fatias axiais utilizando as bordas da imagem como sementes. É importante que o tecido mais claro do corpo do paciente esteja conectado com a borda da imagem. O objetivo dessa etapa é remover todo e qualquer componente que não faça parte dos pulmões ou da traqueia. A segunda parte começa com um rastreamento da borda dos pulmões. Em caso de pacientes com nódulos localizados na pleura (justapleural), o rastreamento da borda dos pulmões os ignora, fazendo com que sejam tratados como fundo. Assim, o método de AMB altera o método de marcha tradicional (Marcha Não-adaptativa de Bordas) de tal forma a detectar as regiões ignoradas, e para essas regiões alterar o passo da marcha reduzindo esse problema. Ao final deste método, a segmentação é concluída.

Experimentos foram realizados em 20 imagens de CT. O desempenho da segmentação foi medido por meio da relação de inclusão de cada nódulo justapleural e a relação de regiões segmentadas incorretamente. O método proposto em [33] foi comparado com o método tradicional de marcha. Foi reportado que todos os nódulos foram segmentados corretamente com uma média de erro de segmentação de 2.06%. O método leva em média menos de 1 minuto para execução.

Rikxoort *et al.* [40] propuseram um método híbrido para segmentação de pulmões em imagens CT. O método é dividido em três partes: segmentação inicial, detecção de erros e segmentação utilizando multiatlas.

A segmentação inicial é feita utilizando um método comparável com os métodos em [35] e [16]. Inicialmente é feita a identificação da traqueia utilizando crescimento de regiões. As sementes do método de crescimento de regiões são selecionadas na fatia axial mais ao topo da imagem de CT, dentro de uma região com brilho abaixo de -950 HU, tamanho mínimo de 50mm^2 e máximo de 1225mm^2 com coordenadas x e y não mais de 30% das dimensões da imagem. O critério de desempate, caso mais de uma região seja encontrada, é a proximidade das regiões até o centro da imagem. A partir destas sementes, o método de crescimento de regiões é aplicado. Após a traqueia ser determinada, os pulmões também são segmentados utilizando crescimento de regiões. A semente para segmentar os pulmões é determinado como o ponto com menor HU dentro das vias aéreas. A partir deste ponto, o crescimento de regiões é aplicado. A separação entre pulmões direito e esquerdo é feito pelos seus centros de gravidade, entretanto, existem situações, em que os pulmões direito e esquerdo estão conectados na imagem pela pleura. Assim, um método de programação dinâmica é aplicado, semelhante ao descrito em [16].

Após a segmentação inicial, uma série de testes de consistência é aplicado para detectar se ocorreu algum problema com a segmentação. De acordo com os bancos de dados usados no estudo, quatro fatores foram definidos como indicadores importantes para o sucesso

da segmentação, são eles: volume do pulmão esquerdo, volume do pulmão direito, relação entre os volumes e forma consistente da superfície do pulmão. Para os três primeiros, os volumes dos pulmões em 320 imagens foram determinados, e baseados nesses valores, a relação de volumes mínimos e máximos foram estipulados. A checagem da forma dos pulmões serve para encontrar massas com maior brilho perto da borda, deixando a superfície não convexa. Para isso, é feita uma avaliação de convexidade da borda em fatias axiais.

Caso algum destes protocolos de consistência falhe, é feita uma nova segmentação por meio de multiatlas. Nessa nova segmentação, um conjunto de imagens de treinamento (atlas) são registradas no espaço da imagem de teste a ser segmentada. Após esse processo, uma fusão de rótulos é realizada para decidir qual o rótulo de cada voxel da imagem, finalizando assim a segmentação.

Experimentos foram realizados em 150 imagens selecionadas aleatoriamente de três bases de dados diferentes, NELSON [42, 45], LIDC-IDRI [1] e ILD¹. Para realização dos registros, 8 imagens da base NELSON foram usadas para registrar as bases de NELSON e LIDC e 8 imagens da base ILD foram usadas para os registros dela própria. As métricas usadas foram: DICE, distância Hausdorff, e MADS. Foi reportado que a segmentação inicial falhou em 22 casos, os quais foram segmentados utilizando multiatlas. Foi obtido um total de 0.95 de DICE, 23.55 para distância Hausdorff e 1.61 para MADS. O método leva em média 55 segundos para segmentar uma imagem pelo método convencional e 120 minutos para segmentar utilizando multiatlas.

Sofka *et al.* [36] apresentaram um método para segmentação de pulmões afetados por doenças em que outros métodos normalmente falham. O método é dividido em três etapas: predição dos parâmetros de postura (translação, tamanho e orientação), estimativa dos pontos de referência e detecção das bordas.

Inicialmente a carina traqueal (região da traqueia que divide os brônquios) na imagem é localizada. Mais detalhes sobre a localização da carina traqueal não foram reportados. Sua localização é utilizada no método de Rede de Detecção Hierárquica (HDN) para a predição dos parâmetros de postura. O HDN estima estados desconhecidos de objetos (como a postura, por exemplo) por meio de um processo sequencial de decisão. Sua formulação é parecida com a aplicação de cadeias de Markov para rastreamento de objeto, entretanto, nesse caso, existe uma dependência espacial entre os objetos. A etapa de estimativa dos pontos de referência cria um modelo de malhas triangulares a partir de um conjunto de malhas já anotadas, onde os pontos de referência são escolhidos de tal forma que esses pontos estejam bem espalhados ao longo da superfície do pulmão. Com os parâmetros de postura dos pulmões direito e esquerdo, o modelo de malhas triangulares são deformados resultando na segmentação inicial dos pulmões. Por fim, é realizada uma etapa adicional para refinamento de forma livre da segmentação inicial.

Experimentos foram realizados em 260 imagens de CT, com 192 para treinamento e 68 para teste. Os métodos comparados foram com e sem a estimativa dos pontos de referência. Os experimentos mostram que a estimativa dos pontos de referência ajuda a alcançar uma precisão significativamente melhor. Nenhuma métrica de precisão foi mencionada.

Hua *et al.* [17] propuseram um método de segmentação de pulmões doentes baseado

¹<http://14.139.240.55/ilddb/>, último acesso em 10 de Dezembro, 2017

em busca em grafos. O método é dividido em três etapas: pré-segmentação dos pulmões utilizando somente o brilho, extração de características junto com classificação, e a segmentação final por busca em grafos.

A primeira etapa aplica uma segmentação inicial pelo método em [16] e computa a estrutura topológica da superfície dessa segmentação. A extração de características consiste no cômputo de um vetor para cada voxel da imagem com as seguintes informações: intensidade, gradiente e vizinhança anatômica (costelas e coluna). O classificador kNN foi empregado para calcular a probabilidade de um voxel pertencer à borda do pulmão, e essa mesma probabilidade é usada para calcular a função de custo do grafo na segmentação final. Após o grafo ser criado com seus respectivos custos, o problema de segmentação é convertido em um problema de fluxo máximo em um grafo, cuja complexidade é polinomial de baixa ordem.

Experimentos foram conduzidos em 15 imagens de CT, incluindo pacientes com enfisema, fibrose e nódulos. O método proposto em [17] foi comparado com o método em [16]. As métricas usadas foram DICE e distância Hausdorff. Por fim, concluiu-se que o método proposto desempenhou melhor do que o método em [16].

Sun *et al.* [37] propuseram um método automático para segmentação de pulmões afetados por câncer, os quais métodos convencionais (limiarização, por exemplo) normalmente falham. O método proposto por [37] é baseado na combinação de modelos utilizando modelos de forma ativos (ASM) e é dividido em quatro etapas: criação do modelo do pulmão, inicialização do modelo, combinação do ASM e otimização de superfície (OSF).

Na etapa de criação do modelo, um modelo de distribuição de pontos é gerado baseado em pontos de referência automaticamente identificados a partir de um conjunto de treinamento de 41 pulmões saudáveis (nesse artigo, o número total de imagens é de 30, conseqüentemente, o número de pulmões é de 60). Na segunda etapa, para que a inicialização do modelo ASM seja o mais próximo possível dos pulmões, a caixa torácica do paciente na imagem é localizada e dividida em duas, e o centro de cada parte é considerado como a posição inicial do modelo em cada pulmão. A terceira etapa (combinação ASM) é onde os autores fizeram sua contribuição. No algoritmo de combinação ASM tradicional, pontos que não representam a superfície dos pulmões podem ser usados para atualização dos pontos de referência afetando o resultado da segmentação. Porém, o método proposto em [37] utiliza um sistema de votação que evita o uso desses pontos não representativos durante a segmentação. Para isso, são criados vários conjuntos distintos de pontos de referência de cada imagem de treinamento. Em seguida, um valor para o erro de reconstrução (voto) é calculado e o conjunto com menor erro será escolhido para o algoritmo. Por fim, a etapa de otimização de superfície é utilizada para refinar o resultado da segmentação de forma a adaptar o modelo para áreas mais estreitas.

Nos experimentos, comparações foram feitas com o método em [37] sem a etapa de OSF e com o ASM tradicional. As métricas usadas foram: DICE, distancia Hausdorff, média do erro do posicionamento de bordas com sinais e MADS. O método proposto superou os outros métodos para os dois pulmões em todas as métricas. Isso era esperado, uma vez que os métodos comparados são versões mais fracas do método proposto. Além disso, o método proposto leva uma média de 6 minutos para segmentar uma única imagem.

Yeary *et al.* [44] apresentaram um método para segmentação de pulmões em imagens

de CT 4D voltado para aplicações de terapias por radiação. O método é dividido em duas etapas: registro da imagem e descoberta da superfície ótima. Uma imagem de CT 4D consiste no agrupamento de N imagens 3D ao longo do ciclo respiratório.

Na primeira etapa cada imagem 3D de cada imagem 4D é alinhada com uma imagem CT de referência utilizando um registro de imagem deformável. O método não necessita de um registro preciso, por isso utilizou-se um modelo de registro de baixa resolução para reduzir o tempo computacional. Na etapa seguinte, um método de busca em grafos chamado de descoberta da superfície ótima é aplicado para segmentação simultânea de múltiplas superfícies. Em seguida, a imagem 4D é representada por um grafo e um algoritmo de cubos marchantes [25] é usado na imagem de CT de referência para transformá-la em uma malha com aproximadamente 10,000 vértices. Por fim, um algoritmo de fluxo máximo é utilizado para encontrar uma solução ótima e as N superfícies resultantes são transformadas de volta para seus respectivos espaços de coordenadas 3D utilizando transformações obtidas do registro.

Experimentos foram conduzidos em imagens 4D de 6 pacientes com câncer de pulmão. Cada imagem 4D contém 10 volumes 3D. As métricas usadas foram DICE e MADS. Foi reportado que o método produz resultados precisos para segmentação de imagens 4D.

Gerard *et al.* [12] propuseram um método de segmentação de pulmões baseado em formas-alfa (formas- α). O método é dividido em três etapas principais: segmentação inicial por limiarização, geração das formas-alfa, e uma otimização por busca em grafos para refinamento final da segmentação.

A segmentação inicial é realizada por meio do método em [16]. Em seguida vem a geração das formas- α . Uma forma- α é uma maneira de representar uma forma dada por meio de um conjunto finito de pontos. Assim, α é representado por um escalar e caso esse escalar seja ∞ então a forma- α equivale à envoltória convexa do conjunto. A forma- α consiste de um subconjunto de tetraedros, formados pelo método de triangulação de Delaunay sobre o conjunto de pontos, cujo raio de circunscrição seja menor que α . A envoltória convexa da segmentação inicial gera uma boa estimativa das bordas do pulmão na região da pleura, entretanto, na região do mediastino, a superfície não é convexa e a envoltória segmenta incorretamente esta região. As formas- α permitem interpolar suavemente a envoltória e a máscara inicial para representar a forma do pulmão. Por fim, para encontrar a superfície ótima do pulmão, o método de busca em grafos é aplicado. A busca em grafos utiliza a segmentação inicial como superfície de construção do grafo, e a inversa do gradiente da imagem para calcular a improbabilidade de cada nó do grafo pertencer à superfície do pulmão. A superfície ótima é então encontrada por meio do algoritmo de fluxo máximo seguido por uma operação de disjunção lógica entre o resultado da busca em grafos e a segmentação inicial.

Experimentos foram realizados em 12 imagens de CT. O método foi comparado com a segmentação manual feita por um especialista com o auxílio de um software. As métricas usadas para acurácia foram DICE e MADS. O método proposto em [12] mostrou bons resultados, com um coeficiente de DICE médio de 0.970 e um erro da MADS de 0.727 mm para pacientes com e sem tumor.

3.4 Conclusão

Durante este capítulo, métodos da literatura para segmentação dos pulmões e da traqueia em imagens de CT, foram detalhados. Os métodos estudados foram divididos de acordo com a metodologia utilizada para segmentação dos pulmões, o que levou à criação de três classes principais: baseados em limiarização, crescimento de regiões, e modelos de forma. Estes métodos possuem pelo menos uma das seguintes limitações: alto tempo computacional, fracas condições para separação dos pulmões e traqueia, e validação baseada em um número relativamente pequeno de imagens de CT.

Os métodos baseados em modelos de forma possuem o maior tempo computacional, podendo levar até 3 horas para segmentar uma única imagem [35], o que é inviável no ambiente clínico. Enquanto que os métodos baseados em crescimento de regiões levam alguns minutos para segmentar uma imagem e os métodos baseados em limiarização, menos de 1 minuto. Entretanto, os métodos baseados em limiarização necessitam de etapas adicionais para separação dos pulmões e da traqueia o que pode aumentar o tempo de processamento.

Grande parte dos métodos na literatura utilizam condições fracas para segmentação dos pulmões e da traqueia, tais como: remoção de regiões escuras conectadas com a borda da imagem e identificação da traqueia como sendo o objeto circular mais alto da imagem [2, 16]. Essas condições podem gerar erros em situações onde a traqueia ainda não foi removida ou quando os pulmões aparecem junto com a traqueia na última fatia da imagem.

Levando em consideração a grande quantidade de doenças, traumas, e deformações que podem afetar a forma e a aparência dos pulmões e da traqueia (como derrame pleural ou escoliose), uma base pequena de imagens não representa o problema real de segmentação destes órgãos. Assim, os métodos que foram validados em uma pequena base de imagens podem falhar em situações adversas da rotina clínica.

O método ALTIS proposto, explicado no capítulo seguinte, contorna essas limitações.

Capítulo 4

ALTIS

ALTIS é um método para segmentação automática dos pulmões e traqueia baseado em crescimento de regiões, cujo nome vem da sigla do termo em inglês *Automatic Lungs and Trachea Image Segmentation*. Durante este capítulo, é apresentada uma descrição detalhada das etapas do método, com exemplos e algoritmos. O método ALTIS é dividido em três etapas principais: extração dos pulmões e traqueia, estimativa das sementes para cada objeto, e por fim, delineamento dos pulmões e traqueia. A extração dos pulmões e traqueia tem como objetivo determinar a localização espacial do volume de interesse na imagem, sendo uma etapa essencial para a segmentação. Já a etapa de estimativa das sementes procura determinar sementes dentro de cada objeto e no fundo. A última etapa realiza o delineamento propriamente dito. A Figura 4.1 apresenta um diagrama com todas as etapas do método ALTIS

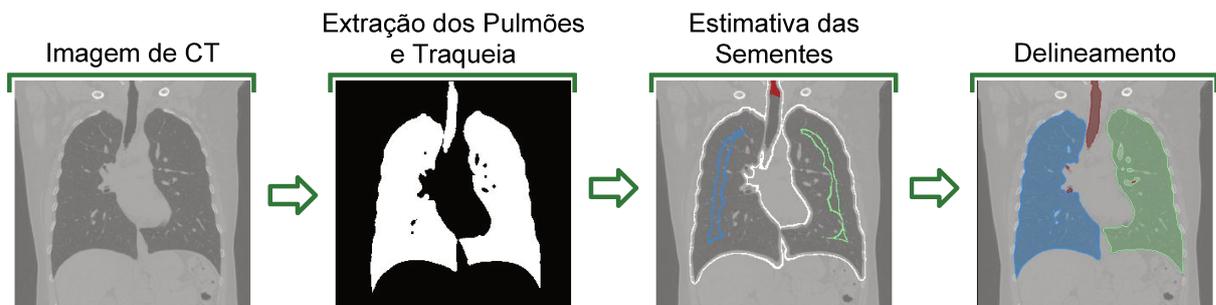


Figura 4.1: Diagrama das etapas do método ALTIS. Para uma dada imagem de CT, inicialmente os pulmões e traqueia são extraídos. Em seguida, as sementes são estimadas para realização do delineamento dos objetos.

O método assume que a orientação do paciente na imagem de tomografia seja de inferior para o superior ao longo plano axial (eixo z), da esquerda para a direita ao longo plano sagital (eixo x) e de anterior para posterior ao longo do plano coronal (eixo y). Esta orientação pode ser garantida a partir das informações do protocolo DICOM.

4.1 Extração dos Pulmões e Traqueia

Muitos métodos na literatura utilizam uma limiarização fixa ou removem regiões escuras conexas com as bordas da imagem para obter a localização dos pulmões, porém, esses métodos possuem problemas (discutidos na Seção 1.2). Assim, a etapa de extração dos pulmões e traqueia determina o volume de interesse utilizando características robustas dos objetos e da imagem evitando tais problemas.

Seja $\hat{I}_1 = (D_I, I_1)$ a imagem de CT de entrada. O plano para extração dos pulmões e traqueia é ressaltar os voxels dentro dessas estruturas, os quais em maioria são mais escuros do que os tecidos ao redor deles. A ideia, no entanto, não é aplicada no volume total, uma vez que a traqueia está ligada com a borda da imagem no espaço tridimensional, fazendo com que os objetos de interesse não estejam cercados totalmente por tecidos mais claros. Essa etapa do método requer a execução do algoritmo geral da IFT (algoritmo 1) para cada fatia da imagem no plano axial $\hat{I}_1^{(k)} = (D_I^{(k)}, I_1^{(k)})$ de \hat{I}_1 , onde $D_I^{(k)} \subset D_I$, $k \in [1, K]$, e K é o número de fatias no plano axial. A Figura 4.2 mostra um diagrama do funcionamento da extração dos pulmões e traqueia no corte coronal. O plano coronal foi utilizado nas figuras somente para fins didáticos.

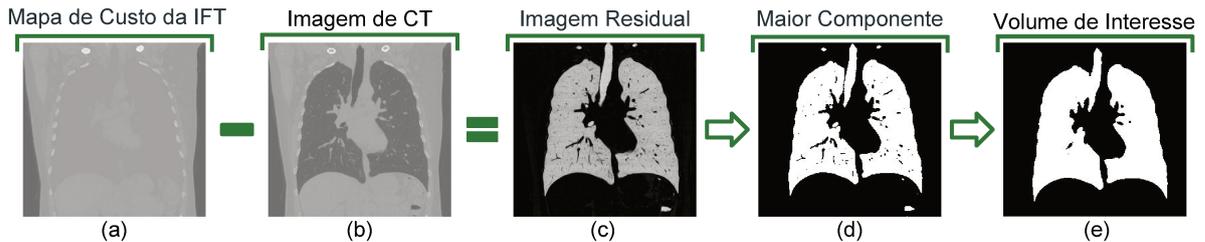


Figura 4.2: Pipeline da etapa de extração dos pulmões e traqueia. (a) Mapa de custo mínimo após aplicação da IFT nas fatias do plano axial. (b) Imagem original. (c) Imagem residual obtida subtraindo (b) de (a). (d) Seleção do maior componente conexo em (c). (e) Fechamento morfológico em (d), resultando no volume de interesse.

A estratégia dessa etapa funciona da seguinte forma: para cada fatia $k \in [1, K]$ da imagem, todo pixel escuro dentro dos pulmões e traqueia só pode ser alcançado por meio de caminhos com raízes S nas bordas da imagem que passam através de pixels circundantes mais claros (Figura 4.3). Considerando todos os possíveis caminhos saindo de S até cada pixel e escolhendo aquele cuja intensidade máxima ao longo do caminho é mínima, o mapa de custo $C^{(k)}$ gerado pela IFT irá preservar o máximo possível das intensidades originais em $\hat{I}_1^{(k)}$ e cobrir os pulmões e traqueia com a intensidade mínima dos tecidos circundantes (Figura 4.2a). Portanto, a diferença pixel-a-pixel $C^{(k)} - \hat{I}_1^{(k)}$ irá remover a maioria dos pixels de fundo e preservar os pixels escuros dentro dos pulmões e traqueia como sendo claros na imagem residual $\hat{I}_2^{(k)} = (D_I^{(k)}, I_2^{(k)})$, onde $I_2^{(k)}(p) = C^{(k)}(p) - \hat{I}_1^{(k)}(p), \forall p \in D_I^{(k)}$, ressaltando assim os voxels do pulmão (Figura 4.2c). Esse realce da imagem é feito por meio do algoritmo da IFT executado no grafo $(D_I^{(k)}, A_1)$ utilizando a função f_{pico} em cada fatia. Essa operação de realce é aplicada em cada fatia 2D da imagem volumétrica e é a única etapa do algoritmo que trabalha com fatias 2D. Por esse mesmo motivo, utiliza-se a relação de adjacência A_1 . Todas as outras operações são feitas sobre o volume. O mapa

de custo $C^{(k)}$ é minimizado, tal que $C^{(k)}(q) = \min_{\forall \pi_q \in \Pi_q} \{f_{pico}(\pi_q)\}$ para cada $q \in D_I^{(k)}$. A linha 6 do algoritmo 1 pode ser simplificada para $tmp \leftarrow \max\{C^{(k)}(p), I_1^{(k)}(q)\}$, e o resultado para $k \in [1, K]$ é a imagem 3D $\hat{I}_2 = (D_I, I_2)$.



Figura 4.3: Um caminho que começa nas bordas do corte axial, passa através do espaço vazio da imagem (verde), seguido pelo ar em volta do paciente (azul) e pelo corpo (vermelho) até chegar em um ponto no pulmões direito. Tal caminho deve visitar pixels mais claros antes de chegar nos pulmões e traqueia.

Note que a imagem realçada contém os pulmões, a traqueia e várias outras estruturas menores. Assim, por meio de uma limiarização automática e seleção do maior componente conexo, uma máscara binária pode ser criada contendo apenas os pulmões e a traqueia (Volume de interesse na Figura 4.2d). O valor da limiarização automática foi estipulado empiricamente, sendo uma porcentagem acima do valor de limiarização de Otsu [31], $T = \kappa T_{otsu}$ onde $\kappa > 1$ e o maior componente conexo é selecionado em $(D_I, A_{\sqrt{3}})$. O valor ótimo κ é determinado a partir de um conjunto de treinamento de imagens normais e suas respectivas máscaras (seção 5.3).

A relação de adjacência $A_{\sqrt{3}}$ é utilizada para que características tridimensionais do volume de interesse sejam consideradas nas operações. Como por exemplo na seleção de componentes conexos. Caso uma relação 2D seja utilizada para isso, cada fatia da imagem terá seus próprios objetos conexos, sendo que estes mesmos objetos podem estar conexos entre si por outras fatias do volume.

A máscara binária resultante é chamada de $\hat{I}_3 = (D_I, I_3)$, onde $I_3(p) = 1$ para voxels que pertencem aos pulmões ou à traqueia e $I_3(p) = 0$ caso contrário. Entretanto, estruturas vasculares e linfáticas dentro dos pulmões aparecem como “buracos”, *i.e.*, voxels com $I_3(p) = 0$. Assim, um fechamento morfológico é necessário para incluir tais estruturas como parte do volume de interesse $\hat{I}_4 = (D_I, I_4)$ (Figura 4.2(e)). O fechamento destes “buracos” é importante pois durante a etapa de seleção de sementes, marcadores externos podem ser estimados dentro deles fazendo com que essas estruturas sejam eliminadas da segmentação.

Pela definição, um fechamento morfológico requer uma dilatação seguida por uma erosão usando um elemento estruturante (esfera) de raio $\gamma \geq 1$. Como \hat{I}_3 é uma máscara binária, tanto a dilatação como a erosão podem ser eficientemente calculadas por meio

da aplicação de uma transformada de distância Euclidiana (TDE). A partir da borda interna S_3 de \hat{I}_3 , definida como $S_3 = \{p \in D_I \mid I_3(p) = 1 \text{ and } \exists q \in A_1(p) \mid I_3(q) = 0\}$, é aplicada a TDE que retorna uma máscara dilatada $\hat{I}'_3 = (D_I, I'_3)$ junto com a borda externa armazenada em S_3 , porém, dessa vez definida como $S_3 = \{p \in D_I \mid I'_3(p) = 0 \text{ and } \exists q \in A_1(p) \mid I'_3(q) = 1\}$. Assim, de forma similar, a erosão pode usar a TDE com o novo S_3 , para propagar os voxels de fundo para dentro da máscara até a mesma distância γ para formar $\hat{I}_4 = (D_I, I_4)$.

Com o intuito de realizar a operação de fechamento morfológico de maneira rápida e otimizada, ambos os métodos de dilatação e erosão morfológica podem ser implementados utilizando a IFT ao se interpretar \hat{I}_3 como um grafo $(D_I, A_{\sqrt{3}})$ e definir uma função de conectividade f_{tde} . O elemento estruturante é esférico e definido por $A_{\sqrt{3}}$.

$$\begin{aligned} f_{tde}(\langle q \rangle) &= \begin{cases} 0 & \text{if } q \in S, \\ +\infty & \text{caso contrário.} \end{cases} \\ f_{tde}(\pi_p \cdot \langle p, q \rangle) &= \|q - R(p)\|^2, \end{aligned} \quad (4.1)$$

Onde $R(p)$ é a raiz do caminho π_p e S é a borda interna do objeto. Os algoritmos 2 e 3 mostram como as operações de dilatação e erosão são implementadas pela IFT.

Algoritmo 2 – DILATAÇÃO MORFOLÓGICA

ENTRADA: Máscara binária $\hat{I}_3 = (D_I, I_3)$, sua borda interna S_3 , e a distância γ .
 SAÍDA: Máscara dilatada $\hat{I}'_3 = (D_I, I'_3)$ e sua borda externa S_3 .
 AUXILIARES: Relação de Adjacência $A_{\sqrt{3}}$, fila de prioridades Q , conjunto $S' = \emptyset$, mapa de custo C , mapa de raiz R , variável tmp .

1. **Para Cada** $p \in D_I$ **Faça** $C(p) \leftarrow +\infty$ e $I'_3(p) \leftarrow I_3(p)$.
2. **Enquanto** $S_3 \neq \emptyset$ **Faça**
3. Remova p de S_3 .
4. Atribua $C(p) \leftarrow 0$, $R(p) \leftarrow p$, e insira p em Q .
5. **Enquanto** $Q \neq \emptyset$ **Faça**
6. Remova p de Q tal que $p = \arg \min_{q \in Q} \{C(q)\}$.
7. **Se** $C(p) \leq \gamma^2$ **Então**
8. Atribua $I'_3(p) \leftarrow 1$.
9. **Para Cada** $q \in A_{\sqrt{3}}(p) \mid C(q) > C(p)$
10. e $I_3(q) = 0$ **Faça**
11. Atribua $tmp \leftarrow \|q - R(p)\|^2$.
12. **Se** $tmp < C(q)$ **Então**
13. **Se** $q \in Q$ **Então** Remova q de Q .
14. $C(q) \leftarrow tmp$ e $R(q) \leftarrow R(p)$.
15. Insira q em Q .
16. **Senão** Atribua $S_3 \leftarrow S_3 \cup \{p\}$.
17. **Retorne** \hat{I}'_3 e S_3 .

Algoritmo 3 – EROÇÃO MORFOLÓGICA

ENTRADA: Máscara binária $\hat{I}'_3 = (D_I, I'_3)$, sua borda externa S_3 , e a distância γ .
 SAÍDA: Máscara dilatada $\hat{I}_4 = (D_I, I_4)$ e sua borda interna S_4 .
 AUXILIARES: Relação de Adjacência $A_{\sqrt{3}}$, fila de prioridades Q , conjunto $S' = \emptyset$, mapa de custo C , mapa de raiz R , variável tmp .

1. **Para Cada** $p \in D_I$ **Faça** $C(p) \leftarrow +\infty$ e $I_4(p) \leftarrow I'_3(p)$.
2. **Enquanto** $S_3 \neq \emptyset$ **Faça**
3. Remova p de S_3 .
4. Atribua $C(p) \leftarrow 0$, $R(p) \leftarrow p$, e insira p em Q .
5. **Enquanto** $Q \neq \emptyset$ **Faça**
6. Remova p de Q tal que $p = \arg \min_{q \in Q} \{C(q)\}$.
7. **Se** $C(p) \leq \gamma^2$ **Então**
8. Atribua $I_4(p) \leftarrow 0$.
9. **Para Cada** $q \in A_{\sqrt{3}}(p) \mid C(q) > C(p)$
10. e $I'_3(q) = 1$ **Faça**
11. Atribua $tmp \leftarrow \|q - R(p)\|^2$.
12. **Se** $tmp < C(q)$ **Então**
13. **Se** $q \in Q$ **Então** Remova q de Q .
14. $C(q) \leftarrow tmp$ e $R(q) \leftarrow R(p)$.
15. Insira q em Q .
16. **Senão** Atribua $S_4 \leftarrow S_4 \cup \{p\}$.
17. **Retorne** \hat{I}_4 e S_4 .

O algoritmo 2 realiza uma propagação dos voxels na borda do objeto para fora da máscara binária para uma dada distância $\gamma \geq 1$, gerando \hat{I}'_3 , enquanto que o algoritmo 3 propaga os voxels na borda externa do objeto de \hat{I}'_3 para dentro da máscara, gerando \hat{I}_4 . Em comparação com o algoritmo tradicional da IFT (algoritmo 1), ambos os algoritmos 2 e 3 inserem inicialmente somente as sementes em Q (linha 4) e processam somente voxels cuja distância até S_3 seja menor ou igual a γ . Assim como κ , o valor de γ foi determinado baseado no conjunto de treinamento com imagens normais (seção 5.3). O tempo de processamento dos laços de repetição principais (linhas 5 a 16 dos dois algoritmos) são proporcionais à quantidade de voxels a uma distância γ de S_3 . Uma outra otimização é o teste da linha 9 e 10, que evita o cômputo desnecessário de distâncias, já que somente voxels fora (para dilatação) ou dentro (para a erosão) da máscara serão considerados válidos.

Ao fim desta etapa, a máscara binária $\hat{I}_4 = (D_I, I_4)$ (Figura 4.2e) não conterà nenhum “buraco” dentro do volume de interesse e será usada na etapa seguinte para seleção das sementes internas e externas dos pulmões e da traqueia.

4.2 Estimativa das Sementes

Métodos baseados em crescimento de regiões necessitam que marcadores (ou sementes) sejam gerados dentro dos objetos de interesse. Assim, a presente etapa do método AL-TIS tem como objetivo principal a estimativa de sementes dentro de cada pulmão (direito e esquerdo), da traqueia e no fundo. Essas sementes serão utilizadas na etapa subsequente de delineamento baseado em competição ótima de sementes. A Figura 4.4 apresenta a sequência de operações realizada por esta etapa.

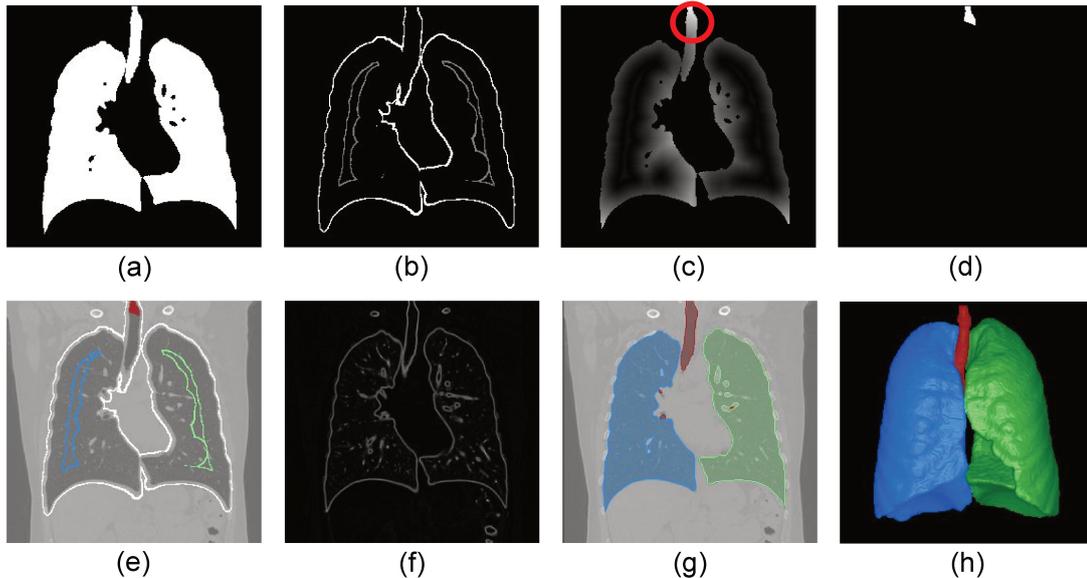


Figura 4.4: Pipeline da estimativa das sementes, a rotulação das sementes e delineamento dos objetos. (a) Volume de interesse obtido na etapa de extração dos pulmões e da traqueia (seção 4.1). (b) Sementes dos pulmões e do fundo obtidas por uma dilatação e erosão morfológicas aplicadas em (a). (c) Mapa das distâncias geodésicas a partir das sementes dos pulmões. (d) Estimativa das sementes da traqueia obtidas por meio de uma limiarização e seleção do componente mais alto de (c). Essa seleção é possível devido à orientação do paciente. (e) Imagem original com as sementes rotuladas: sementes verdes representam o pulmão direito, as azuis são do pulmão esquerdo, enquanto que as vermelhas são da traqueia e as brancas são sementes externas. (f) Imagem de gradiente da original. (g) Resultado do delineamento e (h) sua renderização 3D.

Para uma dada máscara binária $\hat{I}_4 = (D_I, I_4)$ contendo o volume de interesse, sementes dentro do pulmão direito S_r , do pulmão esquerdo S_l , da traqueia S_t e no fundo S_e são estimadas. Os conjuntos S_r , S_l e S_e são estimados por meio de uma única aplicação do algoritmo da IFT. Primeiramente, o conjunto S_4 , obtido na etapa anterior, contendo os voxels da borda interna de \hat{I}_4 deve ser estendido para incluir também os voxels na borda externa. Dessa forma, as operações morfológicas de dilatação, até uma distância $\gamma_e \geq 1$, e erosão, até uma distância $\gamma_i \geq 1$, podem ser executadas simultaneamente para gerar os conjuntos de sementes externas S_e e internas $S_i = S_r \cup S_l$ respectivamente. Os valores de γ_i e γ_e são determinados durante a fase de treinamento (seção 5.3) e devem ser suficientes para não considerar a traqueia e separar S_i em componentes conexos dentro dos pulmões direito e esquerdo. De forma a reduzir o tempo de processamento, a operação

de dilatação retorna o volume de interesse dilatado \hat{I}'_4 que será usado na próxima etapa (delineamento) para reduzir a região viável da imagem para a segmentação. Após as operações de dilatação e erosão simultâneas, os dois maiores componentes de $(S_i, A_{\sqrt{3}})$ são selecionados e definidos como S_l e S_r dependendo valor da coordenada x do centro de massa de cada um deles. Isto é, a coordenada x do centro de massa de S_l deve ser maior do que a mesma coordenada do centro de S_r . A Figura 4.4e mostra as sementes de cada pulmão com rótulos distintos (pulmão direito tem rótulo azul e pulmão direito tem rótulo verde).

O algoritmo 4 descreve o processo de aplicação simultânea da dilatação e erosão morfológica para a estimativa de S_i e S_e sobre \hat{I}_4 . As duas primeiras linhas estendem o conjunto S_4 de \hat{I}_4 para incluir a borda externa do objeto. Então, nas linhas 9 - 19, o conjunto S_e é obtido propagando as bordas externas para fora da máscara \hat{I}_4 (dilatação), enquanto que nas linhas 20 - 29 as bordas internas são propagadas para o interior da máscara \hat{I}_4 (erosão) para obter S_i . As partes de erosão e dilatação são similares aos algoritmos 2 e 3.

Algoritmo 4 – SELEÇÃO DOS CONJUNTOS S_i E S_e

ENTRADA: Máscara $\hat{I}_4 = (D_I, I_4)$, suas bordas S_4 , e distâncias γ_i e γ_e .

SAÍDA: Marcadores S_i e S_e inicialmente vazios, e máscara dilatada $\hat{I}'_4 = (D_I, I'_4)$.

AUXILIARES: Relações de adjacência A_1 e $A_{\sqrt{3}}$, fila de prioridades Q , mapa de custo C , mapa de raízes R , e variável tmp .

1. **Para Cada** $p \in S_4$ **Faça**
2. **Para Cada** $q \in A_1(p) \mid I_4(q) = 0$ **Faça** *Atribua* $S_4 \leftarrow S_4 \cup \{q\}$.
3. **Para Cada** $p \in D_I$ **Faça**
4. **Para Cada** $q \in A_{\sqrt{3}}(p) \mid I_4(q) = 0$ **Faça** *Atribua* $C(p) \leftarrow +\infty$ e $I'_4(p) \leftarrow I_4(p)$.
5. **Para Cada** $p \in S_4$ **Faça**
6. **Para Cada** $q \in A_{\sqrt{3}}(p) \mid I_4(q) = 0$ **Faça** *Atribua* $C(p) \leftarrow 0$, $R(p) \leftarrow p$, e *insira* p in Q .
7. **Enquanto** $Q \neq \emptyset$ **Faça**
8. *Remova* p de Q tal que $p = \arg \min_{q \in Q} \{C(q)\}$.
9. **Se** $I_4(p) = 0$ **Então**
10. *Atribua* $I'_4(p) \leftarrow 1$.
11. **Se** $C(p) \leq \gamma_e^2$ **Então**
12. **Para Cada** $q \in A_{\sqrt{3}}(p) \mid C(q) > C(p)$
13. e $I_4(q) = 0$ **Faça**
14. *Atribua* $tmp \leftarrow \|q - R(p)\|^2$.
15. **Se** $tmp < C(q)$ **Então**
16. **Se** $q \in Q$, *remova* q de Q .
17. *Atribua* $C(q) \leftarrow tmp$, $R(q) \leftarrow R(p)$,
18. e *insira* q in Q .
19. **Senão** *Atribua* $S_e \leftarrow S_e \cup \{p\}$.
20. **Senão**
21. **Se** $C(p) \leq \gamma_i^2$ **Então**
22. **Para Cada** $q \in A_{\sqrt{3}}(p) \mid C(q) > C(p)$
23. e $I_4(q) = 1$ **Faça**
24. *Atribua* $tmp \leftarrow \|q - R(p)\|^2$.

```

25.   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
26.   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
27.   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
28.   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
29.   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
30. Retorne  $S_i, S_e, e \hat{I}'_4$ .

```

Uma vez definidos os conjuntos S_e e S_i , resta apenas definir o conjunto S_t de sementes dentro da traqueia. Como a traqueia está contida no volume de interesse, a busca por S_t pode ser limitada para voxels dentro desse volume, fazendo com que S_t seja obtido em tempo proporcional ao tamanho do conjunto $N \subset D_I$, onde $N = \{p \in D_I | I_4(p) = 1\}$. Considerando a premissa de que a traqueia é um objeto longo com região distante dos pulmões na parte superior da imagem, é realizada uma transformada de distância geodésica (TDG) a partir de S_i em N . Assim, o caminho ótimo terá de passar pelos brônquios principais para chegar na traqueia, o que implica que os voxels na traqueia serão os mais distantes na imagem. A Figura 4.4c mostra o resultado da TDG. Para implementar a TDG de forma eficiente, foi utilizado o algoritmo 5 que é uma alteração do algoritmo geral da IFT (algoritmo 1) com a função de conectividade f_{tdg} (Equation 4.2), tal que o mapa de custo C retorna os comprimentos dos caminhos geodésicos.

$$\begin{aligned}
f_{tdg}(\langle q \rangle) &= \begin{cases} 0 & \text{if } q \in S_i, \\ +\infty & \text{caso contrário.} \end{cases} \\
f_{tdg}(\pi_p \cdot \langle p, q \rangle) &= f_{tdg}(\pi_p) + w(\langle p, q \rangle),
\end{aligned} \tag{4.2}$$

Onde $w(\langle p, q \rangle)$ é a distância de Chamfer entre p e q , a qual é obtida da aproximação inteira de $10\|q - p\|$. O algoritmo obterá o mesmo resultado para termos diferentes de 10 (como 20, 30...), uma vez que a proporção entre as distâncias se manterá. Baseado na premissa previamente estabelecida de que a traqueia é uma estrutura longa e longe dos pulmões, pode-se selecionar os componentes mais distantes de S_i com uma limiarização em C utilizando uma porcentagem α do valor máximo C_{max} de C . Considerando a orientação do paciente, também é necessário selecionar o componente cuja coordenada z do seu centro de massa seja máxima. Assim, o conjunto S_t é obtido da seguinte forma: $p \in S_t$ se $C(p) \geq \alpha C_{max}$, tal que $C_{max} = \max_{p \in N} \{C(p)\}$, $\alpha \in (0, 1)$, e p pertence ao componente mais alto (Figuras 4.4d e 4.4e). Com isso, todos os conjuntos de sementes necessários para o delineamento foram estipulados.

Algoritmo 5 – TRANSFORMADA DE DISTÂNCIA GEODÉSICA PELA IFT

ENTRADA: Imagem de entrada $\hat{I}_4(D_I, I_4)$, relação de adjacência $A_{\sqrt{3}}$, e conjunto S_i .
SAÍDA: mapa de custo C .
AUXILIARES: Fila de prioridades Q e variável tmp .

1. **Para Cada** $p \in D_I$ **Faça**
2. \perp **Atribua** $C(p) \leftarrow \infty$

3. **Para Cada** $p \in S_i$ **Faça**
4. ┌ Atribua $C(p) \leftarrow 0$
5. └ Insira p em Q .
6. **Enquanto** $Q \neq \emptyset$ **Faça**
7. ┌ Remova p de Q tal que $p = \arg \min_{q \in Q} \{C(q)\}$.
8. ┌ **Para Cada** $q \in A(p) \mid q \in Q$
9. ┌ e $I_4(q) = 1$ **Faça**
10. ┌ ┌ Atribua $tmp \leftarrow C(p) + 10\|q - p\|$.
11. ┌ ┌ **Se** $tmp < C(q)$ **Então**
12. ┌ └ ┌ Atribua $C(q) \leftarrow tmp$.
13. **Retorne** C .

4.3 Delineamento dos Pulmões e da Traqueia

Esta é a última etapa do método ALTIS e é responsável pelo delineamento dos pulmões e da traqueia, além de atribuir rótulos distintos para cada um desses objetos. O delineamento dos objetos é realizado por competição ótima de sementes, ou seja, cada voxel da imagem é conquistado pela semente que oferecer o caminho ótimo até ele, e consequentemente cada objeto é definido por todos os voxels que foram conquistados por suas sementes. Isto é, o pulmão direito consiste dos voxels cujos caminhos ótimos estão enraizados em S_r , o pulmão esquerdo consiste dos voxels que estão enraizados em S_l e a traqueia dos voxels que estão enraizados em S_t .

Para realizar o delineamento, a competição ótima de sementes necessita de uma imagem de gradiente. Assim, seja $\hat{I}_5 = (D_I, I_5)$ a imagem de gradiente a partir de $\hat{I}_2 = (D_I, I_2)$, tal que

$$\begin{aligned}
 I_5(p) &= |\vec{I}_5(p)| \\
 \vec{I}_5(p) &= \frac{\sum_{q \in A_{\sqrt{3}}(p)} [I_2(q) - I_2(p)] d(p, q)}{\sum_{q \in A_{\sqrt{3}}(p)} d(p, q)}
 \end{aligned} \tag{4.3}$$

onde $d(p, q) = \exp\left(\frac{-\|q-p\|^2}{6}\right)$. A fórmula 4.3 estima o vetor gradiente baseado na soma vetorial das derivadas da imagem \hat{I}_2 em várias direções. O termo $d(p, q)$ representa um peso aplicado no vetor gradiente, sendo inversamente proporcional à distância dos pontos. Isto é, quanto mais distantes dois pontos estão, menor será o peso sobre o vetor gradiente entre eles. Com isso, as bordas da imagem de gradiente ficam mais finas. A Figura 4.5 mostra a imagem de gradiente resultante.

As sementes são rotuladas por λ tal que para todo $p \in S_e$, $\lambda(p) = 0$, para todo $p \in S_l$, $\lambda(p) = 1$, para todo $p \in S_r$, $\lambda(p) = 2$ e para todo $p \in S_t$, $\lambda(p) = 3$. Em seguida, cada objeto — pulmão esquerdo, pulmão direito e traqueia — é delineado utilizando o algoritmo geral da IFT (algoritmo 1) sobre \hat{I}_5 com a função de conectividade f_{pico} , $S_5 = S_e \cup S_l \cup S_r \cup S_t$ e algumas outras modificações. Para não realizar processamentos desnecessários, o computo da competição ótima de sementes pela IFT será restrito à



Figura 4.5: Cortes coronal, axial e sagital da imagem de gradiente.

mascara binária dilatada $I'_4 = (D_I, I'_4)$. Assim, o domínio da imagem na IFT será alterado para o conjunto $N = \{p \in D_I \mid I'_4(p) = 1\}$. O algoritmo 6 apresenta a operação de delineamento. O mapa de rótulos L resultante da IFT contém a segmentação dos objetos, tal que $L(p) = 0$ quando $p \in D_I \setminus N$ e $L(p) \in \{0, 1, 2, 3\}$ quando $p \in N$ e é referente ao rótulo da semente com maior conectividade a p .

Algoritmo 6 – COMPETIÇÃO ÓTIMA DE SEMENTES

ENTRADA: Imagem de entrada $\hat{I}_5 = (D_I, I_5)$, função de conectividade f_{pico} , conjunto de sementes S_5 e conjunto N .

SAÍDA: mapa de rótulos L .

AUXILIARES: Relação de adjacência $A_{\sqrt{3}}$, mapa de custo C , fila de prioridades Q e variável tmp .

1. **Para Cada** $p \in N$ **Faça**
2. **Se** $p \in S_5$ **Então**
3. $C(p) \leftarrow 0$
4. $L(p) \leftarrow \lambda(p)$
5. **Senão**
6. $C(p) \leftarrow \infty$
7. $L(p) \leftarrow 0$
8. **Insere** p **em** Q
9. **Enquanto** $Q \neq \emptyset$ **Faça**
10. **Remova** p **de** Q **tal que** $p = \arg \min_{q \in Q} \{C(q)\}$.
11. **Para Cada** $q \in A(p) \mid q \in Q$ **Faça**
12. **Atribua** $tmp \leftarrow \max\{C(p), I_5(q)\}$.
13. **Se** $tmp < C(q)$ **Então**
14. $C(q) \leftarrow tmp$
15. $L(q) \leftarrow L(p)$
16. **Retorne** L .

4.4 Conclusão

Durante este capítulo todas as etapas de processamento do método ALTIS foram detalhadas. A eficiência e robustez do método são confirmadas por meio de uma vasta bateria de testes realizada em 1.753 imagens de CT.

Apesar do ALTIS endereçar problemas existentes em métodos da literatura, ele próprio, por sua vez, possui algumas limitações. Na etapa de extração dos pulmões e traqueia, o maior componente conexo da imagem ressaltada é selecionado como sendo o volume de interesse. Entretanto, caso haja alguma estrutura que também tenha sido ressaltada e está conexa ao volume de ar dos pulmões ou da traqueia, essa estrutura será considerada como parte do volume de interesse e fará parte da segmentação. Isso pode acontecer em situações onde o paciente possui uma bolha de gás intestinal e a resolução da imagem de CT é relativamente baixa, como mostra a Figura 4.6. Outro problema que pode acontecer é na etapa de seleção de sementes internas, onde caso o volume de ar de algum dos pulmões esteja muito reduzido, a erosão pela IFT pode não retornar sementes dentro dele, fazendo com que ele não seja segmentado.

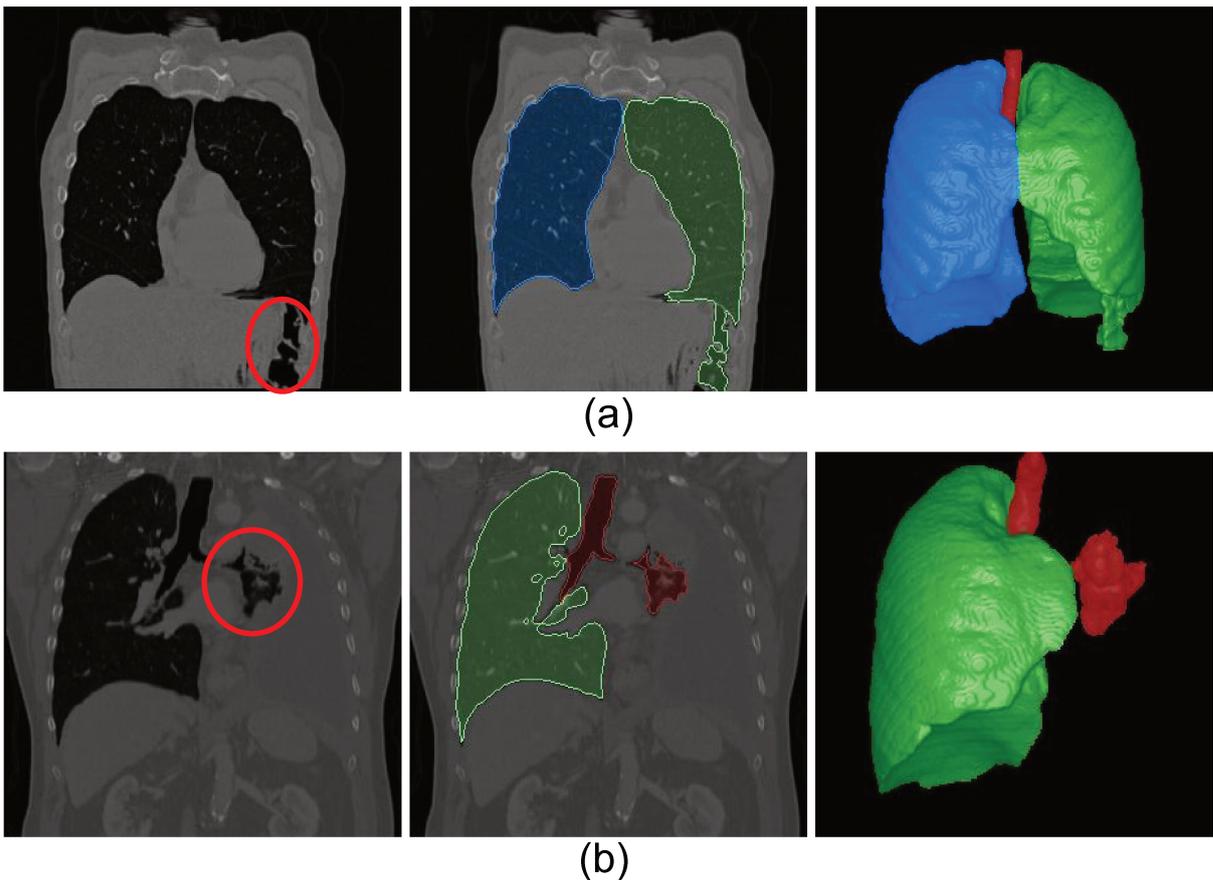


Figura 4.6: Exemplo das limitações do método ALTIS. (a) Mostra a segmentação dos gases intestinais de um paciente como parte do pulmão. (b) Apresenta a falha da segmentação do método ALTIS para um pulmão com volume de ar reduzido.

Capítulo 5

Experimentos e Resultados

Neste capítulo, são retratadas as características dos experimentos com uma discussão sobre os resultados da segmentação do método ALTIS e de outros métodos comparados. Inicialmente são apresentadas as bases de imagens de CT utilizadas nos experimentos juntamente com suas características. Em seguida, os métodos de segmentação usados para validação e comparação são detalhados. Então, é explicado como o treinamento dos métodos de comparação e do ALTIS foram realizados. Em sequência, a metodologia dos experimentos é definida, e por fim é feita a discussão dos resultados.

5.1 Bases de Imagens

Durante a análise dos trabalhos relacionados na literatura, notou-se que muitas técnicas foram testadas em bases pequenas de imagens. Considerando a grande variação de forma e tamanho dos pulmões, proveniente de anomalias ou problemas de aquisição, um número pequeno de imagens não é o suficiente para representar toda a gama de possíveis situações. Nesse contexto, é considerado uma base de imagens pequena se possuir menos do que 100 imagens de CT. Assim, com o intuito de atender essa deficiência, uma base contendo 1.753 imagens de CT variadas foi criada. Para formar tamanha base, foram utilizadas várias outras bases de imagem menores, tanto públicas como internas. Essa variação cria uma grande diversidade de imagens, aumentando a chance de encontrar cenários imprevistos pelos outros métodos. As bases menores são descritas a seguir.

- **ASBESTO**, com 67 imagens normais e 33 imagens de pacientes com anomalias na pleura. Essa base foi fornecida por um grupo de pesquisa da UNICAMP, USP e UNIFESP como parte de um projeto temático chamado “Projeto Asbesto” (financiado pela FAPESP 96/10415-6).
- **LOLA11**¹ é uma base de dados pública com 51 imagens. Essa base foi usada em um desafio de segmentação automática (ou semi) de pulmões e lóbulos pulmonares de imagens de tomografia do tórax, chamado de “Análise de Lóbulo e Pulmão 2011” (*Lobe and Lung Analysis 2011*). Originalmente, essa base continha 55 imagens de CT porém, 4 imagens foram removidas devido a má aquisição.

¹<https://lola11.grand-challenge.org/>, último acesso em 10 de Maio, 2017

- **EXACT09**² é uma base de dados pública com 40 imagens de CT. Essa base também é derivada de um desafio chamado “Extração das Vias Aéreas de CT 2009” (*Extraction of Airways from CT 2009*) que tem como objetivo a comparação de desempenho de algoritmos para extração da árvore respiratória em imagens de CT.
- **VIA/ELCAP**³ é uma base pública com 50 imagens de CT, providenciada pela colaboração entre os grupos de pesquisa ELCAP e VIA da universidade de Cornell, nos Estados Unidos. Foi disponibilizada para avaliação de desempenho em sistemas CAD.
- **LIDC-IDRI**⁴ é uma base pública com 1.012 imagens de CT consistindo principalmente de imagens com câncer de pulmão. Originalmente, essa base continha 1.018 imagens de CT porém, 6 imagens foram removidas devido a má aquisição
- **Tuberculosis**⁵ é uma base pública com 500 imagens de CT de diferentes pacientes diagnosticados com uma das seguintes classes de tuberculose: infiltrativa, focal, miliar, fibrocavosa e tuberculoma.

Essas bases de dados menores foram divididas em dois grupos principais: grupo A para treinamento e avaliação quantitativa, e grupo B para verificação de robustez e eficácia. O grupo A consiste de 250 imagens de CT, formado pela união das bases ASBESTOS (100 imagens), LOLA11 (51 imagens), EXACT09 (40 imagens), VIA/ELCAP (50 imagens) e mais 9 imagens da base LIDC-IDRI para completar o grupo. Dentro do grupo A, 50 imagens foram selecionadas aleatoriamente entre os casos normais da base ASBESTOS para serem usadas como treinamento, e as 200 imagens restantes foram usadas para comparação quantitativa entre o ALTIS e outros métodos. O grupo B é formado por 1.503 imagens retiradas das bases LIDC-IDRI e Tuberculosis e tem como objetivo a verificação de eficácia e robustez do método ALTIS apenas. Considerando essa grande quantidade de imagens e o tempo de processamento para uma única imagem tanto do método SOSM-S quanto do método MALF, a execução desses métodos para o grupo B se torna impraticável. Note que tamanha variedade de bases inclui pacientes com pulmões normais, e pacientes com anatomias distorcidas, que podem ser consequência de pneumonia, tumores, lesões cavitantes, colapso total ou parcial do pulmão (atelectasia), cicatrizes, calcificações, placas pleurais, e deformações pós-cirúrgica.

Todas as imagens foram linearmente interpoladas para um mesmo tamanho de voxel, $1.25 \times 1.25 \times 1.25 \text{ mm}^3$, e por meio de transformações geométricas foram fixadas em uma orientação pré-determinada, como descrito na seção 2.1 e no capítulo 4. Essa padronização nos tamanhos dos voxels e na orientação é importante para que todos os testes sejam realizados sobre um mesmo protocolo de imagem.

Cada objeto de interesse (pulmão esquerdo, pulmão direito e traqueia) de todas as imagens do grupo A foram interativamente segmentadas utilizando o algoritmo da Transformada Imagem Floresta Diferencial (DIFT) [10] para gerar as segmentações padrão-ouro,

²<http://image.diku.dk/exact/>, último acesso em 10 de Maio, 2017

³<https://veet.via.cornell.edu/lungdb.html>, último acesso em 10 de Maio, 2017

⁴<https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI>, último acesso em 10 de Maio, 2017

⁵<http://tuberculosis.by/>, último acesso em 10 de Maio, 2017

ou *ground-truth*. O padrão-ouro pode ser definido como sendo a segmentação considerada “correta”, e é utilizado para computar medidas de desempenho e similaridade entre as segmentações geradas pelo ALTIS e pelos outros métodos comparados. Devido ao grande número de imagens no grupo B, as segmentações interativas não foram computadas.

5.2 Métodos usados para a validação

Muitos métodos na literatura utilizam modelos de forma para a segmentação dos pulmões, onde foram reportados bons resultados. Uma vez que o ALTIS não explora tais modelos, foram selecionados dois métodos para servirem como base de comparação. São eles: Modelos estatísticos de forma do objeto com atlas único e procura ótima de objeto (*Statistical Object Shape Models with Single Atlas and Optimum Object Search* — SOSM-S) [32], e Fusão de rótulos com múltiplos atlas (*Multi-Atlas Label Fusion* — MALF) [18, 41].

5.2.1 Modelo Estatístico de Forma do Objeto

O método SOSM-S proposto por Phellan *et al.* [32] utiliza a abordagem de modelo estatístico de forma do objeto, também conhecido como atlas probabilístico, que é comum na segmentação de imagens médicas. O SOSM-S é a fusão dos métodos: Modelo Estatístico de Forma do Objeto (SOSM) e Modelos Fuzzy de Forma do Objeto (FOSM). Isto é, o SOSM-S utiliza a etapa de procura ótima de objeto do FOSM para melhorar a segmentação pelo SOSM tradicional.

O método SOSM-S inicialmente constroi um atlas probabilístico, selecionando um conjunto de treinamento juntamente com suas segmentações no padrão-ouro do(s) objeto(s) de interesse. Dentro do conjunto de treinamento, é feita uma análise de similaridade entre todas as segmentações no padrão-ouro utilizando uma determinada métrica (neste trabalho, usou-se a métrica DICE) e a imagem com maior similaridade dentre todas é considerada a imagem de referência. Após selecionar a imagem de referência, todas as imagens de treinamento, incluindo suas segmentações, são registradas⁶ no seu espaço de coordenadas. Uma vez que todas as imagens e suas respectivas segmentações tenham sido registradas, a probabilidade de cada voxel pertencer a algum objeto é computada como sendo a quantidade de vezes que o valor daquele voxel for maior do que 0 em cada segmentação do conjunto de treinamento. Isso retorna um mapa de probabilidade onde os voxels com absoluta certeza de pertencer ao objeto terão probabilidade 1, voxels que não fizeram parte de nenhum objeto em nenhuma imagem de treinamento terão valor 0, e voxels que fizeram parte de algum objeto em alguma imagem terá probabilidade]0, 1[. A Figura 5.1 mostra o atlas probabilístico gerados para os pulmões e para a traqueia.

Uma vez que o atlas tenha sido gerado, a imagem de teste a ser segmentada deve ser registrada no espaço da imagem de referência. Em seguida, uma região de procura ótima do objeto é definida como sendo as coordenadas mínimas e máximas entre os centros geométricos das máscaras de segmentação do conjunto de treinamento e do objeto de interesse. A etapa de procura ótima translada o atlas dentro dessa região, e para

⁶O registro foi feito por meio do software Elastix [20], <http://elastix.isi.uu.nl/>, último acesso em 18 de Agosto, 2017

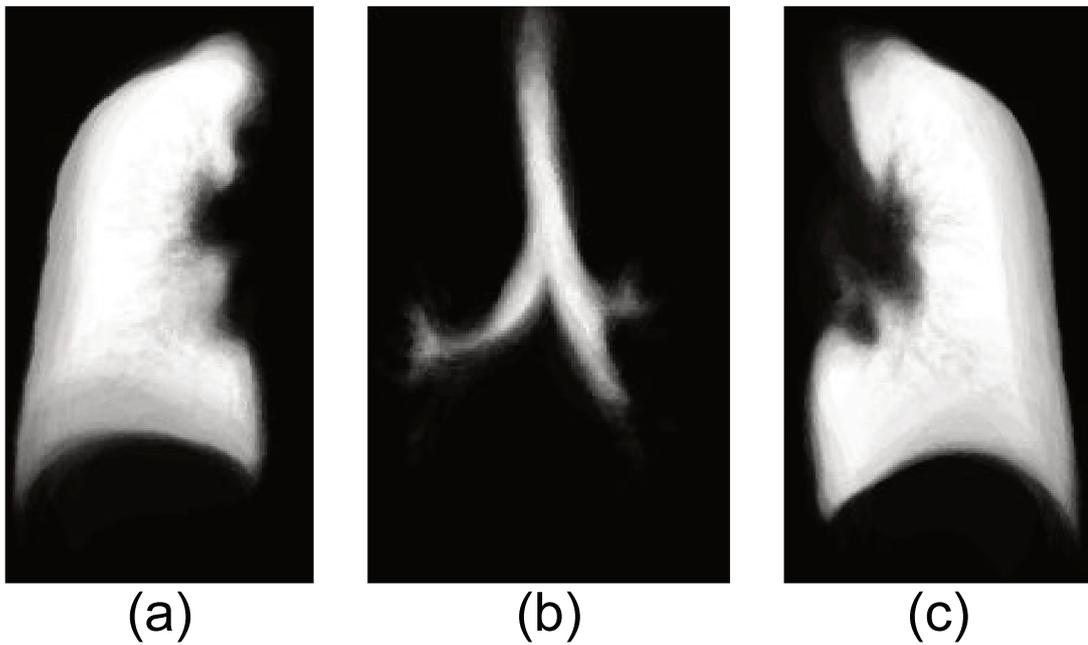


Figura 5.1: Atlas probabilístico dos pulmões e da traqueia.

cada posição do atlas, os objetos são delineados na imagem de teste por meio da IFT. Todos os voxels com valor 1 no atlas probabilístico são considerados sementes internas, enquanto que os voxels com valor 0 são considerados sementes externas. Dentre todos os delineamentos pela IFT, a segmentação escolhida é aquela cuja média do gradiente na borda é máximo. O diagrama da Figura 5.2 mostra o funcionamento completo do método SOSM-S.

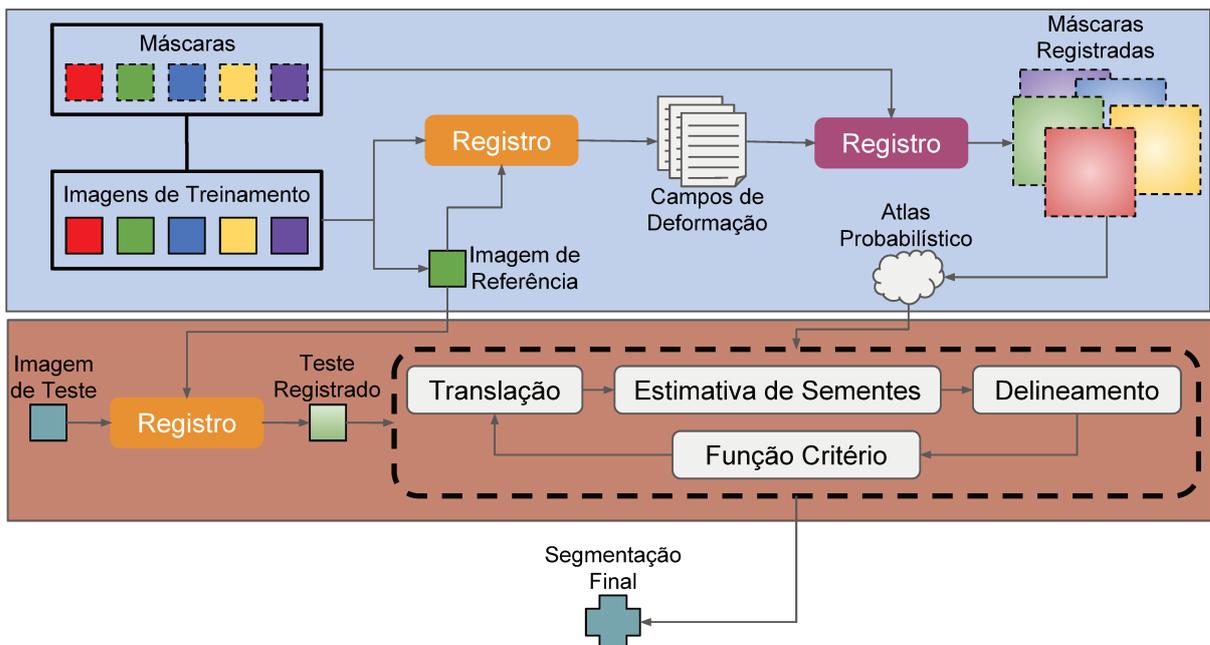


Figura 5.2: Diagrama do funcionamento do método SOSM-S

5.2.2 Fusão de Rótulos com Múltiplos Atlas

A segmentação baseada em atlas parte do princípio de que a segmentação está diretamente ligada com a aparência do objeto. Normalmente, a segmentação por atlas é feita transformando o atlas no espaço da imagem a ser segmentada por meio de um registro deformável e transferindo diretamente os rótulos do atlas para a imagem. Entretanto, a utilização de um único atlas pode gerar problemas devido a dissimilaridade na estrutura e aparência do objeto entre o atlas e a imagem que será segmentada. Dessa forma, a utilização de um método de segmentação por fusão de rótulos com múltiplos atlas (MALF) tem se tornado cada vez mais comum na comunidade de análise de imagens médicas por ser altamente paralelizável e produzir uma segmentação mais precisa do que quando se utiliza apenas um atlas [18, 41]. O método de [40] utiliza MALF para realizar a segmentação dos pulmões caso seja detectado algum erro na segmentação inicial por crescimento de regiões.

O método MALF segue a seguinte estratégia: um conjunto de treinamento formado por vários atlas é transformado no espaço de coordenadas de uma imagem de teste a ser segmentada, por meio da aplicação de um registro deformável. Cada atlas registrado gera um candidato de segmentação da imagem de teste, porém, esses candidatos podem conter erros de segmentação derivados de falhas do registro. Assim, a fusão de rótulos irá integrar os candidatos para melhorar a precisão da segmentação final. Isto é, o método de votação majoritária é utilizado para realizar um contagem da ocorrência dos rótulos de cada candidato para cada voxel da imagem. O rótulo resultante para um determinado voxel é o rótulo com a maior quantidade de votos (ocorrências), produzindo assim a segmentação final. Ou seja:

$$L(p) = \arg \max_{r \in \{1..R\}} \sum_{i=1}^n \hat{L}_i^r(p), \forall p \in D_L \quad (5.1)$$

Onde $L(p)$ é o rótulo do voxel p da imagem de segmentação final L , r é o índice dos rótulos, R é maior rótulo, n é o tamanho do conjunto de treinamento de atlas, e $\hat{L}_i^r(p)$ é o voto do voxel p referente ao rótulo r da i -ésima imagem candidata \hat{L} do conjunto de treinamento de atlas. O voto pode ser 1 caso $\hat{L}_i(p) = r$ ou 0 caso contrário.

5.3 Treinamento

Como descrito no capítulo 4, o método ALTIS possui algumas operações que necessitam de parâmetros. São eles:

- **Fator** da limiarização de Otsu. Esse parâmetro é representado por κ e é utilizado para adaptar o valor de limiarização de Otsu durante a etapa de Extração dos Pulmões e Traqueia (seção 4.1), de tal forma que, junto com o método de seleção do maior componente conexo, retorna o volume de interesse.
- **Raio** do fechamento morfológico. É representado por γ e é utilizado para definir

os raios de dilatação e erosão da operação de fechamento morfológico na etapa de Extração dos Pulmões e Traqueia (seção 4.1).

- **Raio** de Erosão. É representado por γ_i e tem como objetivo definir a distância de erosão para obter as sementes internas dos pulmões, S_i e S_r . É usado na etapa de Estimativa de Sementes (seção 4.2).
- **Raio** de Dilatação. É representado por γ_e e, similarmente ao parâmetro anterior, tem como objetivo definir a distância da dilatação para obter as sementes externas S_e . Também é usado na etapa de Estimativa de Sementes (seção 4.2).
- **Fator** de limiarização da Traqueia. Esse parâmetro é representado por α e tem como objetivo definir o valor de limiarização do mapa de distâncias geodésicas para estimar sementes internas na traqueia S_t . Também é usado na etapa de Estimativa de Sementes (seção 4.2).

De forma a tornar tais parâmetros robustos o suficiente para que a segmentação funcione na grande maioria de imagens, o método de busca em grade foi executado sobre o conjunto de treinamento de 50 imagens do grupo A. Isto é, foi realizada uma exploração exaustiva de todos os parâmetros com valores dentro de uma faixa pré-determinada, e para cada tupla de parâmetros, a segmentação de todo conjunto de treinamento foi feito pelo método ALTIS. Os parâmetros ótimos são aqueles com maior média de similaridade entre as segmentações e os padrões-ouro. Foram encontrados os seguintes valores para cada parâmetro: $\kappa = 1.2$, $\gamma = 2.5mm$, $\gamma_i = 18.75mm$, $\gamma_e = 2.5mm$, e $\alpha = 0.9$. Esses valores foram fixos para todos os experimentos.

As 50 imagens de treinamento do grupo A também foram usadas para formar o atlas probabilístico do método SOSM-S e para segmentação das imagens de teste pelo método MALF.

5.4 Metodologia dos experimentos

Os experimentos foram conduzidos nos grupos A e B de imagens, tal que o grupo A foi usado para análise quantitativa de similaridade e comparação de desempenho entre os métodos ALTIS, SOSM-S e MALF, enquanto que o grupo B foi usado para confirmar a robustez do método ALTIS proposto. Um dos motivos que levaram a execução somente do método ALTIS no grupo B, foi o tempo computacional elevado dos métodos SOSM-S e MALF. A análise quantitativa foi realizada por meio de duas métricas diferentes: o coeficiente de DICE e distância simétrica média entre superfícies (*Average Symmetric Surface Distance* — ASSD).

O coeficiente de DICE é uma métrica que calcula a sobreposição entre duas imagens binárias e é muito utilizado na validação de segmentações de imagens médicas. Para duas imagens binárias \hat{I} e \hat{J} , o coeficiente de DICE pode ser calculado pela seguinte fórmula:

$$DICE(\hat{I}, \hat{J}) = \frac{2V(\hat{I} \cap \hat{J})}{V(\hat{I}) + V(\hat{J})} \quad (5.2)$$

Onde $V(\cdot)$ representa o volume de uma imagem binária. O coeficiente de DICE pode ser adaptado para imagens com múltiplos rótulos, aplicando-o uma vez para cada objeto na imagem. Apesar dessa métrica ser popular na validação de imagens médicas, ela possui o problema de retornar o volume relativo de sobreposição entre as segmentações e, assim, pequenas regiões segmentadas incorretamente, não terão muito efeito no resultado final.

Apesar da popularidade da métrica DICE na área de segmentação de imagens médicas, ela não captura as diferenças entre as bordas dos objetos, como a ASSD. A ASSD é uma medida baseada na distância euclidiana entre as superfícies (bordas) de duas imagens binárias \hat{I} e \hat{J} , por exemplo, e pode ser definida como segue:

$$\begin{aligned} ASSD(\hat{I}, \hat{J}) &= \frac{1}{2}(ASD(\hat{I}, \hat{J}) + ASD(\hat{J}, \hat{I})) \\ ASD(\hat{I}, \hat{J}) &= \frac{1}{D(B(\hat{J}))} \sum_{v \in B(\hat{J})} d_e(v, B(\hat{I})) \end{aligned} \quad (5.3)$$

Onde, $B()$ é a borda da imagem binária, $D()$ denota o número de voxels (domínio) e $d_e(v, B(\hat{I}))$ é a distância euclidiana do voxel v até $B(\hat{I})$ medido na direção do vetor normal local na borda de $B(\hat{I})$. Langerak *et al.* (2011) [22] propôs o uso dessa métrica pois a DICE pode irrelevaer pequenos erros de sobreposição das imagens.

Além da análise quantitativa e da comparação de desempenho, uma análise de variância estatística (ANOVA) foi realizada com teste *post-hoc* de diferença honestamente significativa (HSD) de Tukey. Esse processo foi chamado de ANOVA & Tukey para simplificar. A ANOVA visa fundamentalmente verificar se existe alguma diferença significativa entre as médias de populações e se o fator quantitativo exerce influência sobre a variável dependente. No caso deste trabalho, as médias de populações se referem às médias de similaridade entre os métodos comparados (ALTIS, SOSM-S e MALF). O nível de significância usado foi de 0.05 (valor-p). Como a ANOVA somente identifica a existência de uma diferença estatística dos métodos, é necessário realizar um teste *post-hoc* de tal forma a determinar a superioridade estatística de um método com relação aos outros. Assim, o teste escolhido foi o HSD de Tukey, pois é um teste rigoroso, de fácil aplicação, e permite fazer a comparação dois a dois entre os métodos.

Para as imagens do grupo B, o método ALTIS foi executado e as renderizações das segmentações resultantes foram analisadas uma-a-uma para detectar erros de segmentação.

5.5 Resultados e Discussão

Nesta seção são reportados os resultados obtidos dos experimentos. As tabelas 5.1 e 5.2 apresentam os resultados de similaridade nas métricas DICE e ASSD respectivamente para os métodos ALTIS, SOSM-S e MALF. Os números nessas tabelas são os valores de média e desvio padrão de cada métrica para cada objeto de interesse (traqueia, pulmão direito e pulmão esquerdo) das segmentações das 200 imagens do grupo A. As 50 imagens do grupo A usadas para treinamento foram desconsideradas durante esta etapa de forma a

evitar supertreinamento e enviesamento dos resultados. Note que os resultados do método ALTIS (negrito) em ambas tabelas foram superiores do que os do SOSM-S e do MALF. As Figuras 5.4 e 5.3 mostram dois gráficos apresentando de forma visual os resultados dos métodos para cada métrica.

Tabela 5.1: Comparação de similaridade com métrica DICE para Traqueia (T), Pulmão Direito (PD) e Pulmão Esquerdo (PE).

VIA/ELCAP Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	0.71 ± 0.12	0.78 ± 0.10	0.91 ± 0.03
PD	0.94 ± 0.03	0.95 ± 0.03	0.99 ± 0.00
PE	0.96 ± 0.02	0.96 ± 0.02	0.98 ± 0.03
ASBESTO Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	0.68 ± 0.23	0.75 ± 0.15	0.93 ± 0.02
PD	0.94 ± 0.09	0.93 ± 0.09	0.99 ± 0.01
PE	0.95 ± 0.08	0.95 ± 0.08	0.99 ± 0.00
EXACT09 Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	0.71 ± 0.12	0.78 ± 0.10	0.92 ± 0.02
PD	0.94 ± 0.03	0.95 ± 0.03	0.99 ± 0.01
PE	0.96 ± 0.02	0.96 ± 0.02	0.99 ± 0.01
LOLA11 Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	0.68 ± 0.16	0.71 ± 0.12	0.92 ± 0.01
PD	0.91 ± 0.07	0.92 ± 0.08	0.98 ± 0.01
PE	0.94 ± 0.05	0.94 ± 0.07	0.99 ± 0.01

Apesar dos resultados indicarem que o método ALTIS está na frente dos outros dois, é importante realizar o teste ANOVA & Tukey para verificar se existe de fato uma diferença estatisticamente significativa entre eles. A tabela 5.3 apresenta os resultados da aplicação do teste ANOVA & Tukey. A declaração “ $A < B$ ” implica que o método B é superior ao método A com importância estatística. O símbolo \simeq indica equivalência estatística entre os métodos, e a declaração “ $A \leq B$ ” indica que o método B é superior ao método A na maioria dos casos, mas não foi o suficiente para garantir uma importância estatística. Note que o ALTIS é superior estatisticamente ao SOSM-S e ao MALF para a maioria dos **órgãos** e métricas, com exceção da traqueia na métrica ASSD (primeira linha da tabela 5.3). Nesse caso, não é possível garantir alguma diferença estatística entre os métodos ALTIS e MALF. Esse fato ocorre mesmo com os resultados superiores do ALTIS mostrados na tabela 5.2, indicando a importância de se aplicar diferentes métricas para comparação quantitativa entre segmentações e o rigor da métrica ASSD, uma vez que o DICE aponta que o ALTIS é estritamente superior, revelando ser uma métrica mais superficial.

Tabela 5.2: Comparação de similaridade com métrica ASSD (mm).

VIA/ELCAP Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	4.81 ± 4.11	1.85 ± 1.02	0.92 ± 0.69
PD	1.90 ± 1.12	2.09 ± 1.31	0.55 ± 0.15
PE	1.53 ± 0.79	1.88 ± 1.23	0.73 ± 1.07
ASBESTO Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	5.52 ± 6.06	2.41 ± 3.16	0.64 ± 0.27
PD	2.25 ± 3.45	2.97 ± 3.87	0.40 ± 0.18
PE	1.98 ± 3.28	2.41 ± 3.63	0.39 ± 0.07
EXACT09 Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	4.12 ± 3.28	2.62 ± 2.43	0.70 ± 0.29
PD	2.54 ± 1.86	2.97 ± 2.39	0.56 ± 0.22
PE	2.04 ± 1.61	2.85 ± 2.26	0.59 ± 0.23
LOLA11 Data Set			
Orgão	SOSM-S	MALF	ALTIS
T	5.07 ± 3.88	2.60 ± 1.73	0.71 ± 0.22
PD	3.38 ± 2.55	3.33 ± 2.70	0.61 ± 0.17
PE	2.50 ± 1.83	3.09 ± 2.74	0.61 ± 0.17

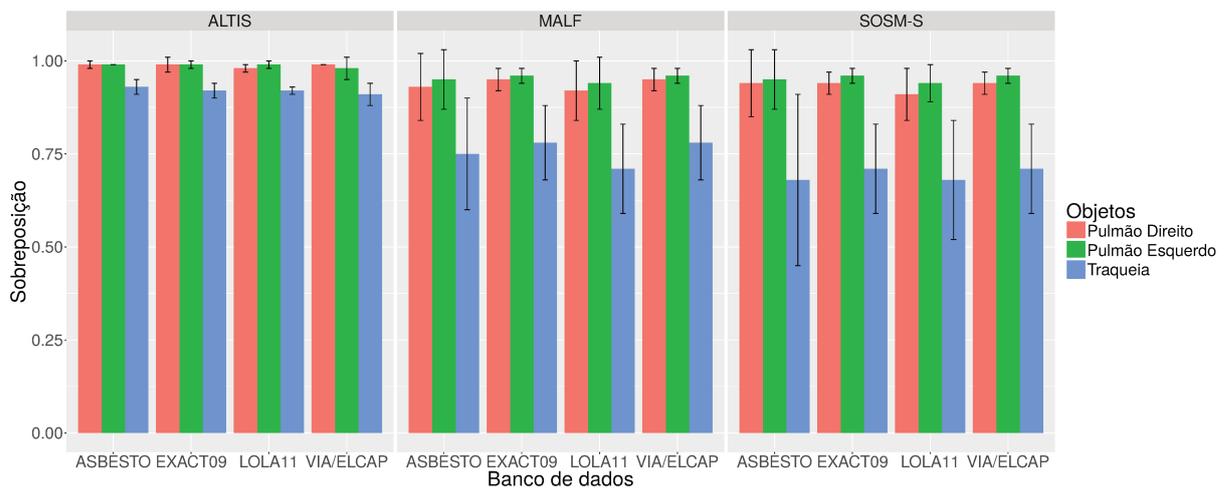


Figura 5.3: Gráfico com os resultados de similaridade entre os métodos ALTIS, SOSM-S e MALF na métrica DICE. Note que quanto maior o valor de sobreposição, mais similares são as superfícies.

De acordo com os resultados das tabelas 5.1, 5.2 e 5.3 pode-se concluir que, de acordo com as duas métricas usadas, ALTIS é mais eficaz do que os métodos SOSM-S e MALF com importância estatística para a grande maioria dos casos. Isto se deve pela dificuldade

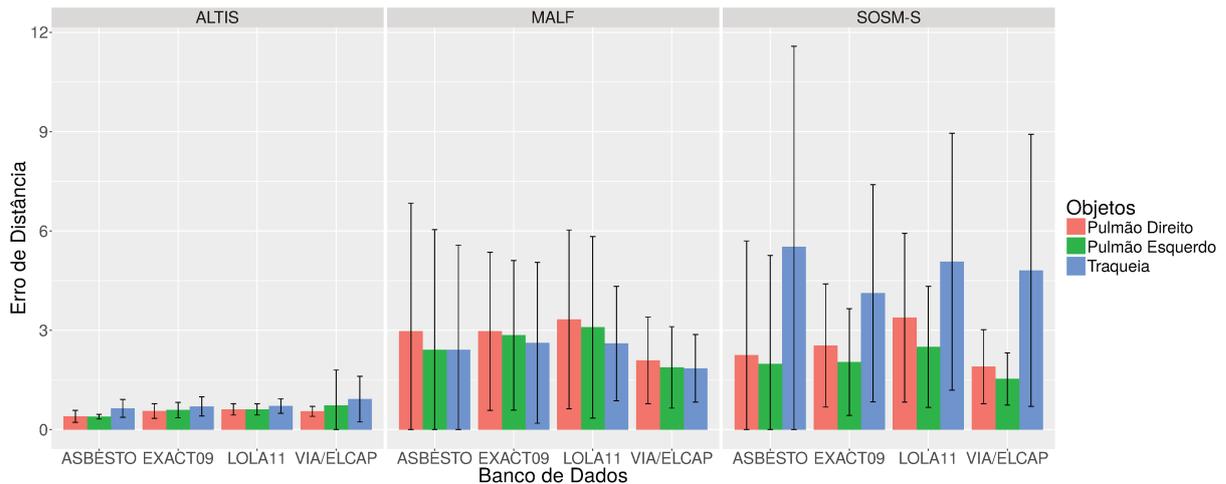


Figura 5.4: Gráfico com os resultados de similaridade entre os métodos ALTIS, SOSM-S e MALF na métrica ASSD. Note que quanto menor o valor de distância, mais próximas estão as superfícies.

Tabela 5.3: Análise de variância (ANOVA) com teste de Tukey

		Anova & Tukey		
Órgão		ASSD	DICE	
T	SOSM-S < MALF ≤ ALTIS	SOSM-S ≤ MALF < ALTIS		
PD	SOSM-S ≈ MALF < ALTIS	SOSM-S ≈ MALF < ALTIS		
PE	SOSM-S ≈ MALF < ALTIS	SOSM-S ≈ MALF < ALTIS		

de geração de um modelo de forma que capte todas e qualquer variação de forma dos pulmões e traqueia. Para ilustrar os resultados das segmentações de cada método, a Figura 5.5 apresenta o corte coronal das segmentações de uma série de imagens retiradas do grupo A.

Neste trabalho, é considerada uma segmentação correta quando são delineados três objetos, que se referem aos pulmões direito e esquerdo, delimitados pela pleura visceral, e a traqueia com os brônquios principais. Assim, pelas segmentações da Figura 5.5, conclui-se que na grande maioria dos casos o resultado do método ALTIS retorna exatamente isso. Entretanto, ALTIS assume que não haverá nenhum outro objeto escuro conectado aos pulmões na imagem de CT, e durante os experimentos foram encontrados casos em que o paciente possuía uma bolha de ar no intestino conexa à eles (Figura 4.6a), mesmo com o diafragma separando esses órgãos. Isso pode ocorrer quando a resolução da imagem de CT é muito baixa. Desta forma, a bolha seria delineada juntamente com os pulmões e a traqueia (Figura 4.6a). Métodos baseados em modelo de forma têm melhor resultado nesse tipo de problema pois o modelo não conteria a região da bolha, e conseqüentemente ela não faria parte da segmentação. A primeira linha da Figura 5.7 mostra as segmentações pelos métodos MALF, SOSM-S e ALTIS desse tipo de problema.

Outra situação que pode ocorrer é a redução do volume de ar dos pulmões devido a alguma doença respiratória. Quando a redução é muito significativa, a segmentação do método ALTIS pode falhar, geralmente retornando apenas dois objetos (Figura 4.6b).

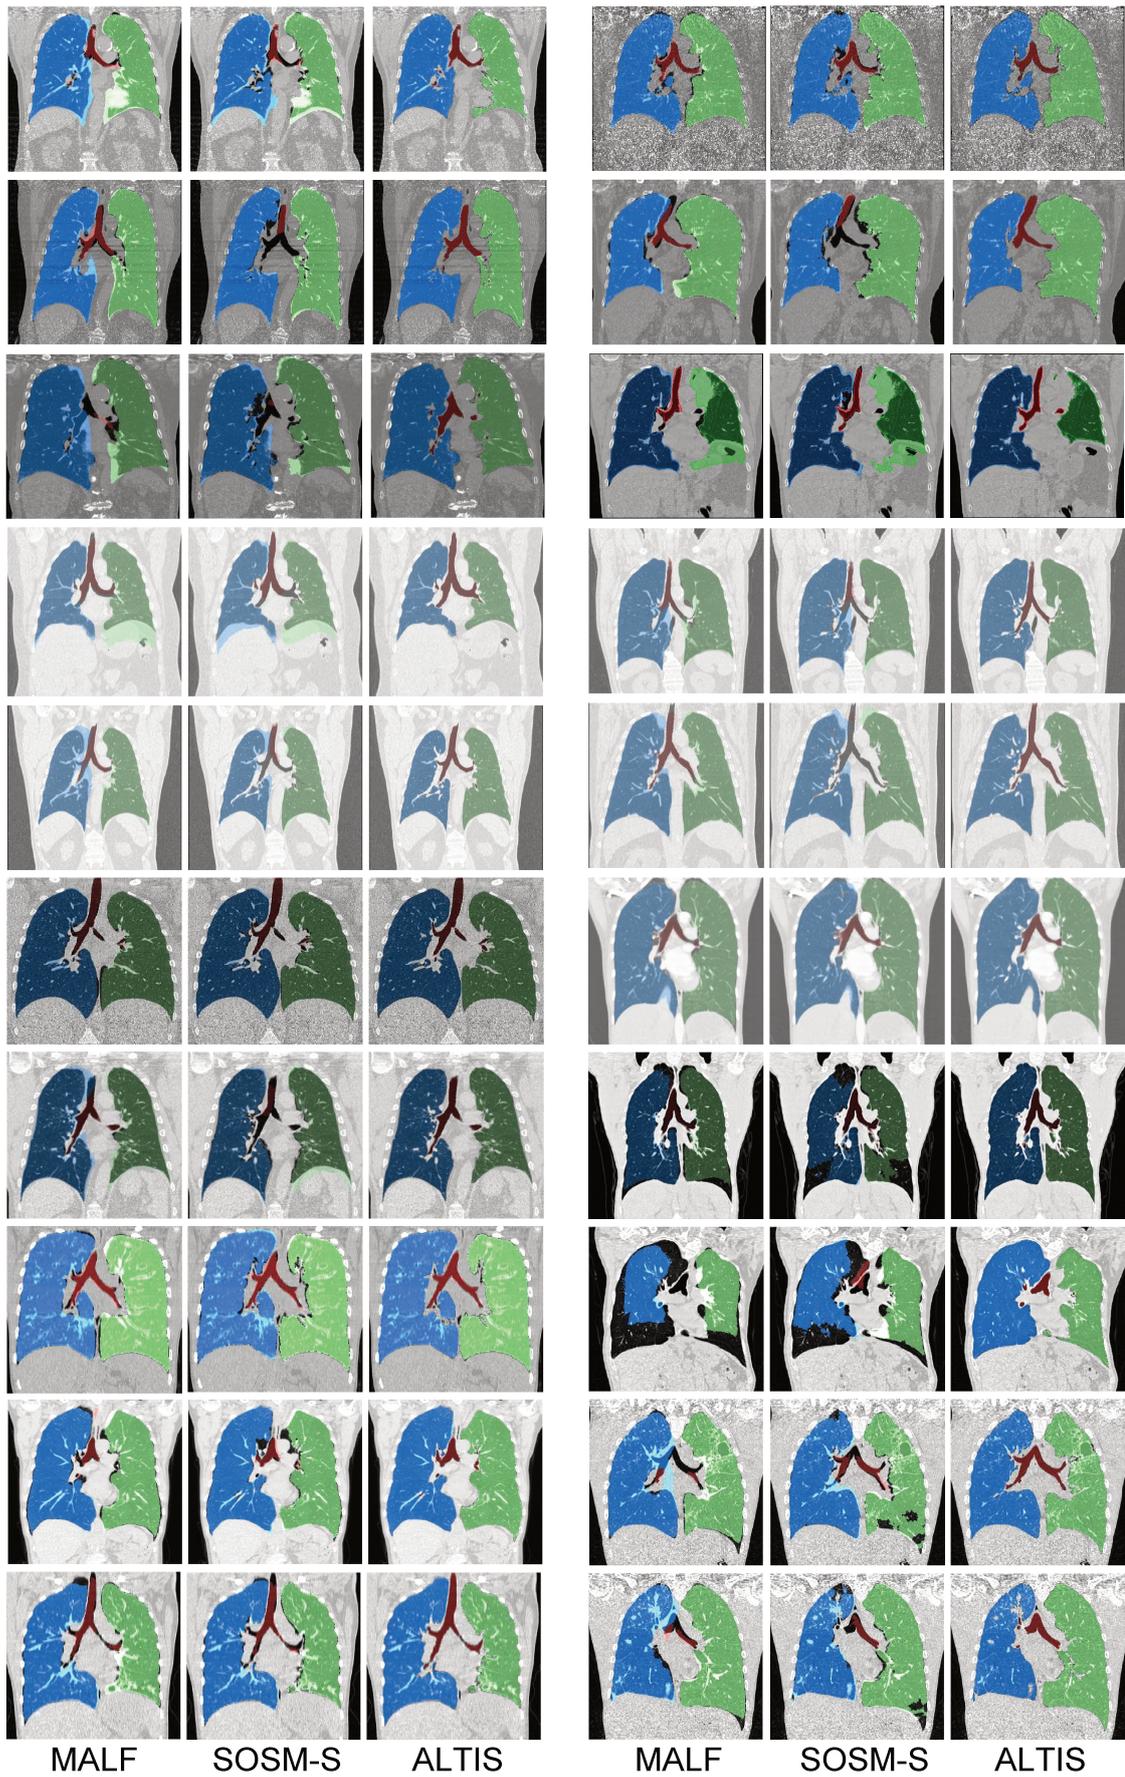


Figura 5.5: Exemplos de segmentação dos métodos MALF, SOSM-S e ALTIS.

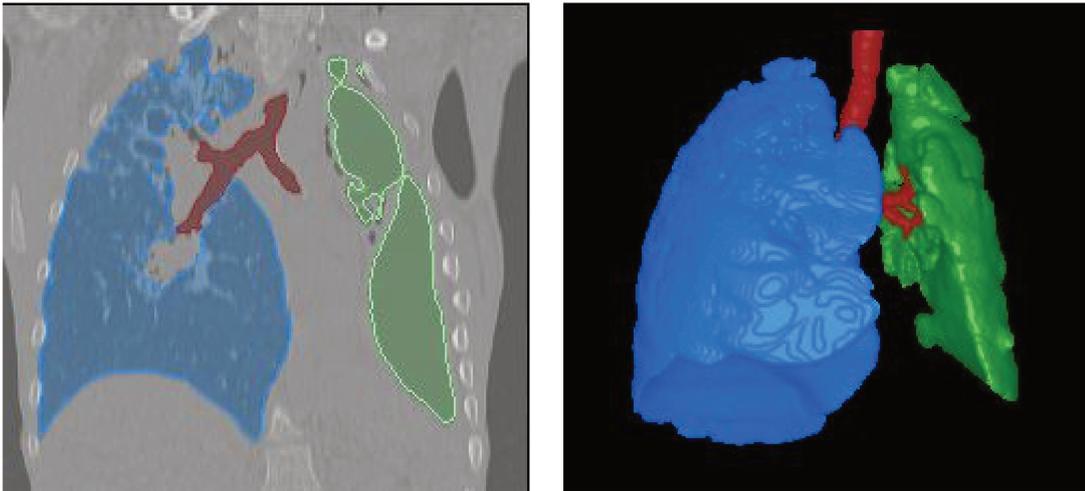


Figura 5.6: Método ALTIS aplicado em uma imagem com pulmão direito reduzido.

Isto se deve pelo fato de que os voxels dentro do volume reduzido estarem muito próximos das bordas, impossibilitando o computo de sementes internas dentro dele. Por outro lado, caso a redução não seja radical, o método ALTIS retornará a segmentação com o volume reduzido. Contudo, como um dos objetos de interesse deste trabalho é o pulmão limitado na pleura visceral, a segmentação do ALTIS não está incorreta, como visto na Figura 5.6. Doenças que afetam a cavidade pleural, como por exemplo o derrame pleural que é o acúmulo anormal de líquidos nessa cavidade, tendem a diminuir o volume de ar nas imagens de CT. A segunda linha da Figura 5.7 mostra as segmentações desse tipo de problema pelos métodos MALF, SOSM-S e ALTIS.

A segmentação do ALTIS é considerada incorreta quando doenças que afetam o interior dos pulmões não são segmentadas. Um exemplo dessa situação é em imagens de pacientes com quadros severos de pneumonia. Em imagens de CT, a pneumonia possui um brilho semelhante ao brilho dos tecidos do corpo do paciente. Assim, quando a pneumonia está conexas com a borda dos pulmões, ou quando compromete uma grande região dos pulmões, o método ALTIS pode falhar durante o filtro de fechamento de bacias ou na estimativa de sementes internas dos pulmões.

É importante notar que todos os três métodos possuem suas limitações. Os métodos SOSM-S e MALF são muito dependentes da criação do modelo e do conjunto de treinamento, e durante os experimentos notou-se que em várias imagens a máscara de segmentação continha regiões do abdômen como parte dos pulmões (primeira linha da Figura 5.5, por exemplo), enquanto que em outras imagens a traqueia e partes dos pulmões não eram segmentadas (como nas sétima e oitava linhas da Figura 5.5). Por outro lado, o ALTIS pode falhar em casos já mencionados anteriormente, isto é, quando anomalias dentro dos pulmões estão conectadas com suas bordas ou quando estruturas externas com brilho similar ao dos pulmões estão conectadas a eles na imagem. Em casos de erros de segmentação pelo ALTIS, uma segmentação interativa com o algoritmo IFT diferencial [10] é sugerido como uma solução simples e fácil, a qual requer a seleção manual de um marcador em cada objeto e um marcador no fundo.

A Tabela 5.4 mostra o tempo de execução médio e desvio padrão para cada um dos

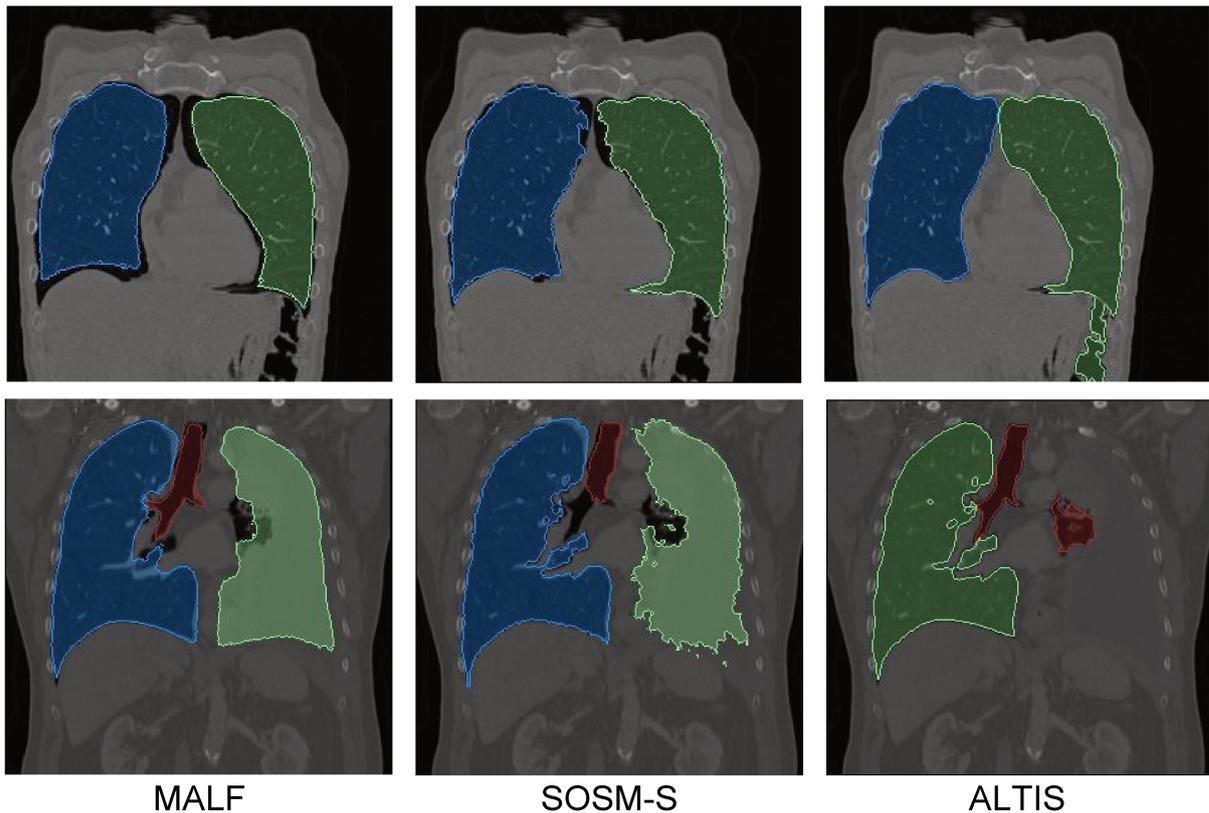


Figura 5.7: Aplicação dos métodos de segmentação MALF, SOSM-S e ALTIS nas imagens de CT de um paciente com gases intestinais e com o pulmão direito reduzido.

métodos em cada base de imagens. A velocidade de execução do método ALTIS aumenta com a redução de espaços desnecessários na imagem ao redor dos pulmões e traqueia. Portanto, é importante evitar regiões na imagem que são irrelevantes para o estudo de doenças pulmonares, como o fígado do paciente, por exemplo. Note que o ALTIS executa a segmentação de 17 a 25 vezes mais rápido do que o SOSM-S, que por sua vez executa de 6 a 13 vezes mais rápido que o MALF. Logo, o ALTIS apresenta um ganho de eficiência considerável sobre o SOSM e o MALF, além de ser mais preciso do que ambos.

Tabela 5.4: Comparação no tempo de execução

Base de Dados	Tempo de Execução		
	SOSM-S	MALF	ALTIS
VIA/ELCAP	$6 \pm 1min$	$57 \pm 7min$	$16 \pm 4sec$
ASBESTO	$6 \pm 1min$	$45 \pm 6min$	$21 \pm 6sec$
EXACT09	$7 \pm 2min$	$46 \pm 6min$	$17 \pm 4sec$
LOLA11	$7 \pm 1min$	$93 \pm 15min$	$19 \pm 4sec$

O método ALTIS foi executado no grupo B contendo 1.500 imagens de CT e as segmentações geradas foram inspecionadas visualmente uma por uma. Foi considerado um erro de segmentação quando pelo menos uma das seguintes situações eram encontradas: parte do volume de ar não segmentado (Figuras 5.8a, 5.8d, 5.8f, 5.8g e 5.8h), vazamento

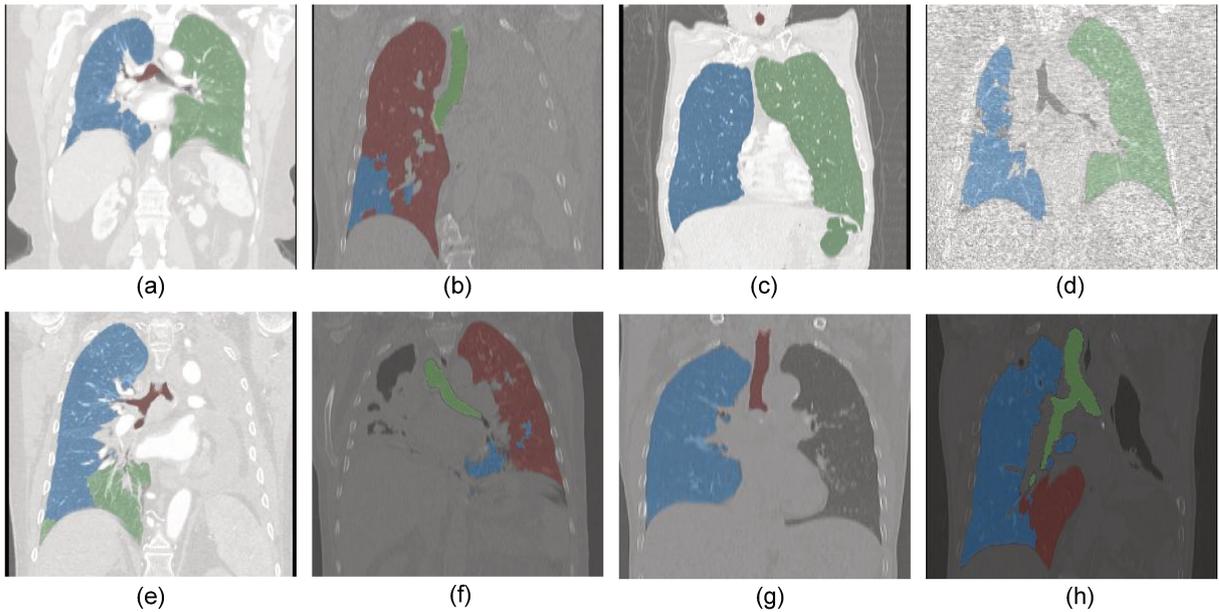


Figura 5.8: Exemplos de erros encontrados durante a análise visual do grupo B.

de algum objeto para outro ou para o fundo (Figura 5.8c), e algum objeto não segmentado devido a redução do volume de ar ou ruídos na imagem (Figura 5.8b, 5.8c, 5.8e e 5.8f). Inicialmente foram observados erros de segmentação em 90 imagens (6%) do grupo B. Apesar do fato do ALTIS não detectar anomalias na cavidade pleural, a maioria dos erros foram derivados de má aquisição de imagem. Como evidência desse fato, 66 das 90 imagens com erro de segmentação foram corrigidas alterando os parâmetros padrões do método ALTIS para compensar os problemas de aquisição.

5.6 Conclusão

Durante este capítulo foram discutidos os experimentos realizados com o método ALTIS, mostrando as bases de dados usadas, os métodos para comparação e a metodologia dos experimentos. O método ALTIS proposto foi comparado com outros dois métodos: SOSM-S e MALF, baseados em modelos de forma utilizando duas métricas diferentes: DICE e ASSD, em uma base de dados de 200 imagens. De acordo com os resultados obtidos, é possível concluir que o ALTIS foi superior aos outros em ambas as métricas e com uma diferença estatística significativa. O treinamento dos métodos foi realizado com 50 imagens normais que não participaram de nenhum teste, para que não haja problema de supertreinamento. Além disso, o método ALTIS foi extensamente avaliado em uma segunda base de dados com 1.500 imagens de CT para mostrar sua robustez. Em nenhum outro trabalho da literatura foi reportado o uso de uma base de dados desse tamanho.

A metodologia inicial para realização dos experimentos era comparar o ALTIS com alguns outros métodos específicos em segmentação de pulmões propostos na literatura. Contudo, a maioria dos métodos não estavam disponíveis para experimentação, e aqueles que estavam disponíveis possuíam funcionalidade reduzida do que era descrito no seu respectivo artigo. Isto é, métodos automáticos precisavam de interação do usuário, não

segmentavam os pulmões separadamente e/ou excluíaam a traqueia. Portanto, os experimentos foram realizados utilizando dois métodos baseados em modelos de forma treinados para segmentar os pulmões e a traqueia.

Capítulo 6

Conclusão

Essa dissertação apresenta o estudo e implementação de um método de segmentação dos pulmões e da traqueia baseado em crescimento de regiões com competição ótima de sementes. Neste capítulo são discutidas as principais contribuições do trabalho realizado, com uma breve descrição do método ALTIS proposto focando nas suas vantagens e limitações, e nos resultados dos experimentos. Por fim, é retratado como essas limitações podem ser tratadas e como o ALTIS pode ser usado para auxiliar na detecção de anomalias nos pulmões e na traqueia em trabalhos futuros.

6.1 Principais Contribuições

Este trabalho de mestrado apresentou uma solução rápida e eficaz, chamada de ALTIS, para segmentação automática dos pulmões e da traqueia em imagem de CT do tórax. O método ALTIS é baseado em competição ótima de sementes que utiliza uma sequência de operações morfológicas implementadas com a IFT que leva em consideração características anatômicas robustas das imagens de CT para segmentação. Isto é, a partir da premissa de que os pulmões e a traqueia são componentes escuros cercados por tecido mais claro, eles são ressaltados e extraídos da imagem de CT. Como os pulmões são mais largos do que a traqueia, sementes dentro de cada pulmão e no fundo são estimados por meio de uma erosão e dilatação morfológicas. Sementes dentro da traqueia são determinadas por meio da transformada de distância geodésica, partindo da premissa de que a traqueia é um objeto longo com região distante dos pulmões na parte superior da imagem. A segmentação é obtida pelo algoritmo da IFT adaptado para crescimento de regiões com competição ótima de sementes.

O método ALTIS é rápido, levando em média 18 segundos para executar em uma imagem de CT, e robusto, funcionando em uma grande variedade de imagens. O ALTIS foi comparado com os métodos SOSM-S e MALF, baseados em modelos de forma, em uma base de 200 imagens e em seguida foi executado em uma base de 1.500 imagens para validação de sua robustez. Experimentos indicaram que o método ALTIS é estatisticamente superior aos outros dois em tempo de execução, eficiência e acurácia no delineamento. O treinamento dos métodos foi feito utilizando 50 imagens normais, que por sua vez não participaram dos testes. O estudo completo envolveu 1.754 imagens de CT com casos de

anomalias severas, formado pela união de bases tanto públicas como privadas. Até onde pudemos constatar, não foi reportado em nenhum outro trabalho da literatura o uso de uma base com essa dimensão.

Durante os experimentos foi observado que o ALTIS é robusto para variações de intensidade e deformações de forma dos pulmões, entretanto, ainda possui algumas limitações. Em casos em que o paciente possui um bolha de ar no intestino e se a resolução da imagem for baixa, essa bolha pode estar conexa aos pulmões e, conseqüentemente, o ALTIS irá segmentá-la como parte do pulmão. Outro problema é na grande redução no volume do ar dos pulmões derivado de doenças pulmonares. Nesse caso, o ALTIS pode falhar na segmentação se não conseguir estimar sementes dentro do pulmão comprometido.

Apesar das limitações, o método ALTIS possui aplicações na comunidade médica para a detecção de doenças pulmonares ou análise do tórax por ser rápido e segmentar os pulmões e a traqueia com alta acurácia. A análise da superfície contendo o volume de ar segmentado dos pulmões pode indicar padrões anormais que correspondem a alguma doença ou complicação respiratória, sendo relevante em estudos médicos de imagens de CT.

6.2 Trabalhos Futuros

A segmentação dos pulmões e da traqueia é apenas um passo inicial para a posterior análise do tórax. Essa segmentação permite o estudo de anomalias localizadas no interior dos pulmões, traqueia, e na cavidade pleural. A segmentação em si pode ser usada na detecção de doenças que comprometem o interior dos pulmões, enquanto que a superfície 3D gerada por ela pode ser utilizada para investigar diversas doenças que afetam a pleura. Considerando a grande gama de doenças respiratórias, a criação de um método ou modelo para classificação automática de todas essas doenças é inviável. Desta forma, os escopos de trabalhos futuros serão na verificação da presença de anomalias para notificação e confirmação de especialistas, detecção e classificação de nódulos pulmonares, e segmentação de placas pleurais devido a asbesto para estimativa de características quantitativas.

Com a segmentação do volume de ar dos pulmões, a verificação da presença de alguma anomalia pode ser realizada extraíndo métricas que representam características de indivíduos saudáveis, treinadas a partir de um conjunto de treinamento com imagens normais. Assim, para toda nova imagem, um descritor com essas mesmas métricas será extraído e comparado com os padrões normais. Caso algo de diferente seja encontrado, o especialista será notificado. Eventualmente, as avaliações dos especialistas podem levar a classificação automática dos descritores, necessitando apenas de um viés de confirmação do especialista.

O câncer de pulmão é a maior causa de morte por câncer em todo o mundo. Logo a detecção e classificação de nódulos pulmonares é uma tarefa muito importante, já abordada por várias competições como: LUNA16¹, ANODE09², e Kraggle *Data Science Bowl* 2017³, que pode ser alcançada com a ajuda da segmentação dos pulmões. Assim, a de-

¹<https://luna16.grand-challenge.org/>, último acesso em 24 de Agosto, 2017

²<https://anode09.grand-challenge.org/>, último acesso em 24 de Agosto, 2017

³<https://www.kaggle.com/c/data-science-bowl-2017>, último acesso em 24 de Agosto, 2017

tecção de nódulos pulmonares será estudado em pesquisas futuras.

A exposição cumulativa de trabalhadores à fibras de asbestos pode resultar na formação de placas pleurais no paciente. Asbesto, também chamado de amianto, é um grupo de minerais amplamente usado em produtos comerciais e na construção civil, que também é altamente tóxico. Apesar disso, asbesto ainda é extraído na Rússia, China (uso local apenas) e no Canadá, onde é exportado para a Ásia e África. Atualmente, o Brasil ocupa a posição de terceiro maior produtor mundial, suprimindo todo o consumo interno, e ainda exporta 60% de sua produção para dezenas de países. As placas pleurais servem apenas como um marcador da exposição ao asbesto e, a não ser que sejam grandes e rígidas, não produzem sintomas ou resultam na diminuição das funções pulmonares. Portanto, a detecção e quantificação prévia de placas pleurais tem importância no ponto de vista médico-legal, dado que doenças relacionadas ao asbesto demandam compensação. Portanto, a segmentação das placas será abordada em pesquisas futuras.

Referências Bibliográficas

- [1] S. G. Armato, G. McLennan, M. F. McNitt-Gray, C. R. Meyer, D. Yankelevitz, D. R. Aberle, C. I. Henschke, E. A. Hoffman, E. A. Kazerooni, H. MacMahon, A. P. Reeves, B. Y. Croft, and L. P. Clarke. Lung image database consortium: developing a resource for the medical imaging research community. *Radiology*, 232(3):739–748, 2004.
- [2] S. G. Armato and W. F. Sensakovic. Automated lung segmentation for thoracic CT: Impact on computer-aided diagnosis. *Academic Radiology*, 11(9):1011–1021, 2004.
- [3] R. Audigier and R. A. Lotufo. Watershed by image foresting transform, tie-zone, and theoretical relationships with other watershed definitions. *Mathematical Morphology and its Applications to Signal and Image Processing*, pages 277–288, 2007.
- [4] H. C. Becker, W. J. Nettleton, P. H. Meyers, J. W. Sweeney, and C. M. Nice. Digital computer determination of a medical diagnostic index directly from chest X-ray images. *IEEE Trans. on Biomedical Engineering*, BME-11(3):67–72, 1964.
- [5] S. Beucher. The watershed transformation applied to image segmentation. *Scanning Microscopy. Supplement*, pages 299–299, 1992.
- [6] Y. Boykov and M-P. Jolly. Interactive organ segmentation using graph cuts. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 276–286. Springer, 2000.
- [7] Y. Boykov and M-P. Jolly. Interactive graph cuts for optimal boundary & region segmentation of objects in nd images. In *IEEE International Conference on Computer Vision*, volume 1, pages 105–112, 2001.
- [8] K. C. Ciesielski, A. X. Falcão, and P. A. V. Miranda. Path-value functions for which dijkstra’s algorithm returns optimal mapping. *Submitted*, 2016.
- [9] S. Dai, K. Lu, J. Dong, Y. Zhang, and Y. Chen. A novel approach of lung segmentation on chest CT images using graph cuts. *Neurocomputing*, 168:799–807, 2015.
- [10] A. X. Falcão and F. P. G. Bergo. Interactive volume segmentation with differential image foresting transforms. *IEEE Trans. on Medical Imaging*, 23(9):1100–1108, 2004.
- [11] A. X. Falcão, J. Stolfi, and R. A. Lotufo. The image foresting transform: Theory, algorithms, and applications. *IEEE Trans. on Pattern Analysis and Machine Int.*, 26(1):19–29, 2004.

- [12] S. Gerard, H. Johnson, J. Bayouth, G. Christensen, K. Du, J. Guo, and J. Reinhardt. Alpha shapes for lung segmentation in the presence of large tumors. In *Pulmonary Image Analysis*, 2016.
- [13] Rafael C. Gonzalez and Richard E. Woods. Digital image processing prentice hall. *Upper Saddle River, NJ*, 2002.
- [14] J. Guo, M. K. Fuld, S. K. Alford, J. M. Reinhardt, and E. A. Hoffman. Pulmonary analysis software suite 9.0: Integrating quantitative measures of function with structural analyses. In *First International Workshop on Pulmonary Image Analysis*, pages 283–292, 2008.
- [15] T. Heimann and H. Delingette. Model-based segmentation. In *Biomedical Image Processing*, pages 279–303. Springer, 2010.
- [16] S. Hu, E. A. Hoffman, and J. M. Reinhardt. Automatic lung segmentation for accurate quantitation of volumetric X-ray CT images. *IEEE Trans. on Medical Imaging*, 20(6):490–498, 2001.
- [17] P. Hua, Q. Song, M. Sonka, E. A. Hoffman, and J. M. Reinhardt. Segmentation of pathological and diseased lung tissue in CT images using a graph-search algorithm. In *IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, pages 2072–2075, 2011.
- [18] J. E. Iglesias and M. R. Sabuncu. Multi-atlas segmentation of biomedical images: a survey. *Medical Image Analysis*, 24(1):205–219, 2015.
- [19] K. Kanazawa, Y. Kawata, N. Niki, H. Satoh, H. Ohmatsu, R. Kakinuma, M. Kaneko, N. Moriyama, and K. Eguchi. Computer-aided diagnosis for pulmonary nodules based on helical CT images. *Computerized Medical Imaging and Graphics*, 22(2):157–167, 1998.
- [20] S. Klein, M. Staring, K. Murphy, M. A. Viergever, and J. P. W. Pluim. Elastix: a toolbox for intensity-based medical image registration. *IEEE Trans. on Medical Imaging*, 29(1):196–205, 2010.
- [21] R. Lamba, J. P. McGahan, M. T. Corwin, C-S. Li, T. Tran, J. A. Seibert, and J. M. Boone. CT hounsfield numbers of soft tissues on unenhanced abdominal CT scans: variability between two different manufacturers’ mdct scanners. *American Journal of Roentgenology*, 203(5):1013–1020, 2014.
- [22] T. R. Langerak, U. A. van der Heide, A. N. T. J. Kotte, F. F. Berendsen, and J. P. W. Pluim. Evaluating and improving label fusion in atlas-based segmentation using the surface distance. In *SPIE. Medical Imaging*, pages 796226–796226. International Society for Optics and Photonics, 2011.
- [23] P. Lo, J. Sporning, H. Ashraf, J. J. H. Pedersen, and M. de Bruijne. Vessel-guided airway tree segmentation: A voxel classification approach. *Medical Image Analysis*, 14(4):527–538, 2010.

- [24] P. C. P. Lo. *Segmentation of Lung Structures in CT*. PhD thesis, Faculty of Science, University of Copenhagen, 2010.
- [25] W. E. Lorensen and H. E. Cline. Marching cubes: A high resolution 3d surface construction algorithm. In *SIGGRAPH Computer Graphics*, volume 21, pages 163–169. ACM, 1987.
- [26] A. Mansoor, U. Bagci, B. Foster, Z. Xu, G. Z. Papadakis, L. R. Folio, J. K. Udupa, and D. J. Mollura. Segmentation and image analysis of abnormal lungs at CT: current approaches, challenges, and future trends. *RadioGraphics*, 35(4):1056–1076, 2015.
- [27] A. Mansoor, U. Bagci, Z. Xu, B. Foster, K. N. Olivier, J. M. Elinoff, A. F. Suffredini, J. K. Udupa, and D. J. Mollura. A generic approach to pathological lung segmentation. *IEEE Trans. on Medical Imaging*, 33(12):2293–2310, 2014.
- [28] Y. Masutani, K. Masamune, and T. Dohi. Region-growing based feature extraction algorithm for tree-like objects. In *Visualization in Biomedical Computing*, pages 159–171. Springer, 1996.
- [29] P. H. Meyers, C. M. Nice Jr, H. C. Becker, W. J. Nettleton Jr, J. W. Sweeney, and G. R. Meckstroth. Automated computer analysis of radiographic images. *Radiology*, 83(6):1029–1034, 1964.
- [30] I. Mingireanov Filho, T. V. Spina, A. X. Falcão, and A. C. Vidal. Segmentation of sandstone thin section images with separation of touching grains using optimum path forest operators. *Computers & Geosciences*, 57:146–157, 2013.
- [31] N. Otsu. A threshold selection method from gray-level histograms. *IEEE Trans. on Systems, Man, and Cybernetics*, 9(1):62–66, 1979.
- [32] R. Phellan, A. X. Falcão, and J. K. Udupa. Medical image segmentation via atlases and fuzzy object models: Improving efficacy through optimum object search and fewer models. *Medical Physics*, 43(1):401–410, 2016.
- [33] J. Pu, J. Roos, A. Y. Chin, S. Napel, G. D. Rubin, and D. S. Paik. Adaptive border marching algorithm: automatic lung segmentation on chest CT images. *Computerized Medical Imaging and Graphics*, 32(6):452–462, 2008.
- [34] R. Shojaii, J. Alirezaie, and P. Babyn. Automatic lung segmentation in CT images using watershed transform. In *IEEE International Conference on Image Processing*, volume 2, pages II–1270, 2005.
- [35] I. Sluimer, M. Prokop, and B. Van Ginneken. Toward automated segmentation of the pathological lung in CT. *IEEE Trans. on Medical Imaging*, 24(8):1025–1038, 2005.
- [36] M. Sofka, J. Wetzl, N. Birkbeck, J. Zhang, T. Kohlberger, J. Kaftan, J. Declerck, and S. K. Zhou. Multi-stage learning for robust lung segmentation in challenging CT volumes. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 667–674. Springer, 2011.

- [37] S. Sun, C. Bauer, and R. Beichel. Automated 3-D segmentation of lungs with lung cancer in CT data using a novel robust active shape model approach. *IEEE Trans. on Medical Imaging*, 31(2):449–460, 2012.
- [38] J. Tschirren, E. A. Hoffman, G. McLennan, and M. Sonka. Intrathoracic airway trees: segmentation and airway morphology analysis from low-dose CT scans. *IEEE Trans. on Medical Imaging*, 24(12):1529–1539, 2005.
- [39] J. K. Udupa and S. Samarasekera. Fuzzy connectedness and object definition: theory, algorithms, and applications in image segmentation. *Graphical Models and Image Processing*, 58(3):246–261, 1996.
- [40] E. M. van Rikxoort, B. de Hoop, M. A. Viergever, M. Prokop, and B. van Ginneken. Automatic lung segmentation from thoracic computed tomography scans using a hybrid approach with error detection. *Medical Physics*, 36(7):2934–2947, 2009.
- [41] H. Wang, J. W. Suh, S. R. Das, J. B. Pluta, C. Craige, and P. A. Yushkevich. Multi-atlas segmentation with joint label fusion. *IEEE Trans. on Pattern Analysis and Machine Int.*, 35(3):611–623, 2013.
- [42] D. M. Xu, H. Gietema, H. de Koning, R. Vernhout, K. Nackaerts, M. Prokop, C. Weenink, J-W. Lammers, H. Groen, M. Oudkerk, and R. van Klaveren. Nodule management protocol of the nelson randomised lung cancer screening trial. *Lung Cancer*, 54(2):177–184, 2006.
- [43] S. Yamamoto, H. Jiang, M. Matsumoto, Y. Tateno, T. Iinuma, and T. Matsumoto. Image processing for computer-aided diagnosis of lung cancer by CT (LSCT). In *IEEE Workshop on Applications of Computer Vision*, pages 236–241, 1996.
- [44] S. G. Yeary, G. E. Christensen, J. E. Bayouth, S. Bodduluri, Y. Pan, J. Guo, K. Du, J. H. Song, B. Zhao, I. Oguz, and J. M. Reinhardt. 4d lung CT segmentation for radiation therapy applications. In *Imaging and Computer Assistance in Radiation Therapy*, pages 50–57, 2015.
- [45] Y. R. Zhao, X. Xie, H. J. de Koning, W. P. Mali, R. Vliegenthart, and M. Oudkerk. Nelson lung cancer screening study. *Cancer Imaging*, 11(1A):S79, 2011.