



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA

Alyson Bezerra Nogueira Ribeiro

SEGMENTAÇÃO DOS VASOS SANGUÍNEOS
PULMONARES EM IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA DO TÓRAX

FORTALEZA - CEARÁ
MARÇO - 2013

Alyson Bezerra Nogueira Ribeiro

SEGMENTAÇÃO DOS VASOS SANGUÍNEOS
PULMONARES EM IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA DO TÓRAX

DISSERTAÇÃO

Dissertação submetida ao corpo docente da Coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática da **Universidade Federal do Ceará** como parte dos requisitos necessários para obtenção do grau de MESTRE EM ENGENHARIA DE TELEINFORMÁTICA, Área de concentração: Sinais e Sistemas.

Orientador: Prof. Dr. Paulo César Cortez

FORTALEZA - CEARÁ

2013

Segmentação dos Vasos Sanguíneos Pulmonares em Imagens de Tomografia Computadorizada do Tórax

Alyson Bezerra Nogueira Ribeiro

Dissertação de Mestrado aprovada em 04/03/2013.

Prof. Dr. Paulo César Cortez
(Orientador)

Prof. Dr. Auzuir Ripardo de Alexandria

Prof. Dr. Danielo Gonçalves Gomes

Prof. Dr. Wagner Coelho de Albuquerque Pereira

Sumário

Lista de Figuras	vi
Lista de Tabelas	x
Lista de Siglas	xi
Resumo	xii
Abstract	xiii
Agradecimentos	xiv
1 Introdução	1
1.1 Objetivos	3
1.2 Organização da Dissertação	4
2 Fundamentação Teórica e Estado da Arte	5
2.1 Imagens de Tomografia Computadorizada do Tórax	5
2.2 Vasos Sanguíneos Pulmonares	8
2.3 Cardiopatias Pulmonares	10
2.4 Segmentação de Imagens	12
2.4.1 Segmentação do Pulmão	12
2.4.1.1 Método Contorno Ativo Tradicional	12
2.4.1.2 Método de Contorno Ativo Crisp	13
2.4.2 Segmentação dos Vasos Sanguíneos	14
2.4.2.1 Limiarização	14
2.4.2.2 Lógica <i>Fuzzy</i>	16
2.4.2.3 Conectividade <i>Fuzzy</i>	17
2.4.2.4 Função de Pertinência	18
2.4.2.5 Crescimento de Regiões 3D	18
2.4.2.6 Reconhecimento de Padrões	21
2.4.2.7 Algoritmo K-médias	23
2.4.2.8 Análise de Densidade Pulmonar (ADP)	24
2.5 Estado da Arte	25
3 Metodologia	27
3.1 Segmentação do Pulmão	27
3.2 Segmentação dos Vasos Sanguíneos	28
3.2.1 Limiarização	28

3.2.2	Crescimento de Regiões 3D	28
3.2.3	K-médias e ADP	30
3.2.4	Conectividade <i>Fuzzy</i>	30
3.3	Avaliação dos Métodos	32
4	Resultados	39
4.1	Aquisição de Imagens	39
4.2	Limiarização	41
4.3	Crescimento de Regiões 3D (CR3D)	42
4.4	Conectividade Fuzzy	45
4.5	K-Média	48
4.6	Comparação entre o desempenho dos três métodos	51
5	Conclusões, Contribuições e Trabalhos Futuros	71
	Referências Bibliográficas	74
	Apêndices	79

Lista de Figuras

2.1	imagens de seções do pulmão adaptada de (SLUIMER; PROKOP; GINNEKEN, 2005), a) planos de corte em relação ao corpo humano; b) seção sagital; c) seção axial; e d) seção coronal.	6
2.2	ilustração representativa do <i>pixel</i> e do <i>voxel</i> , adaptada de (BONTRAGER, 2000).	7
2.3	escala em Unidades Hounsfield, adaptada de (SIEMENS, 2004).	8
2.4	imagem de TC multidetectores, (a) imagem original; (b) representação em faixa de densidade UH.	9
2.5	ilustração da circulação pulmonar , adaptada de (FAUCI et al., 2003).	10
2.6	imagem de TC do tórax com destaque em alguns vasos sanguíneos.	10
2.7	aplicação do MCA crisp (a) visualização em duas dimensões da segmentação do pulmão utilizando o MCA Crisp (b) renderização da segmentação por MCA Crisp do pulmão.	14
2.8	representação gráfica da função de pertinência gaussiana.	19
2.9	ilustração da aplicação do Crescimento de Regiões 3D. a) determinação do <i>voxel</i> semente em destaque vermelho b) primeira iteração do Crescimento de Regiões 3D analisando-se a vizinhança do <i>voxel</i> semente c) resultado final da segmentação	20
2.10	estrutura clássica de um reconhecimento de padrões adaptada de (MARTQUES, 2005).	21
2.11	exemplo de regiões de decisão de um classificador.	22
2.12	regiões de decisão do classificador K-médias	24
3.1	definição do padrão-ouro da segmentação de vasos; (a), (c) e (e) imagens originais do ápice, hilo e base respectivamente; (b), (d) e (f) respectivos padrões-ouro das regiões do ápice, hilo e base.	36

3.2	exemplo de segmentações de vasos sanguíneos pulmonares em outros trabalhos; (a)segmentação de vasos desenvolvida por Kaftan et al. (2008); (b) segmentação de vasos no trabalho desenvolvido por Zhu et al. (2009); (c) segmentação de vasos no trabalho desenvolvido por Korfiatis, Karahaliou e Costaridou (2009).	37
3.3	modelos de padrão ouro da segmentação dos vasos; (a)visualização de uma segmentação manual padrão com vasos de pequeno calibre incluídos; (b) padrão ouro com exclusão de vasos de pequeno calibre;	38
4.1	imagem de TC; (a) multidetectores adquirida pelo tomógrafo modelo <i>Philips Gemini</i> ; (b)TCAR adquirida pelo tomógrafo modelo <i>Toshiba Asteion</i> . . .	40
4.2	aplicação de somente limiarização no processo de segmentação do vasos pulmonares; (a) exame 1; (b) exame 2	41
4.19	sensibilidade e similaridade da segmentação por K-Médias pela segunda abordagem de avaliação	50
4.20	visualização da árvore de vasos sanguíneos pulmonares através da segmentação por K-Médias.	51
4.21	volume de segmentação dos três métodos por exame.	52
4.22	segmentação dos vasos sanguíneos na região do hilo por, (a) manualmente (padrão-ouro); (b)K-Médias; (c) CF; (d) CR3D.	52
4.23	número de vasos segmentados corretamente.	53
4.24	segmentação dos vasos sanguíneos na região do ápice por, (a) manualmente (padrão-ouro); (b)K-Médias; (c) CF; (d) CR3D.	53
4.25	percentual de falsos positivos.	54
4.26	segmentação de vasos sanguíneos com vias aéreas adjacentes; (a), (e), (i), (m) e (q) imagens originais com vias aéreas circuladas em vermelho; (b),(f),(j),(n) e (r) segmentações por CR3D; (c), (g), (k), (o) e (s) segmentação por CF; (d), (h), (l), (t) e (p) segmentação por K-Médias.	55
4.27	avaliação quantitativa dos métodos; (a) coeficiente de similaridade; (b) coeficiente de sensibilidade.	57
4.28	árvores de vasos sanguíneos, (a) segmentação por K-Médias;(b) segmentação por CF; (c) segmentação por CR3D.	58
4.29	árvores de vasos sanguíneos em exame com presença de doença intersticial, (a) segmentação por K-Médias;(b) segmentação por CF; (c) segmentação por CR3D.	59

4.30	imagem com destaque em tecido fibroso circulado em verde caracterizado por doença intersticial.	59
4.3	visualização da segmentação pulmonar e segmentação de vasos; (a) circulada em verde verifica-se uma região com vasos da região interna do pulmão que foi excluída erroneamente pela segmentação pulmonar; (b) circuladas em vermelho verifica-se algumas das regiões em que há presença de vasos não segmentados	60
4.4	segmentação dos vasos sanguíneos por CR3D, (a),(c) e (e) imagens originais; (b) segmentação em paciente sadio;(d)segmentação em paciente com doença intersticial;(f) segmentação em paciente com enfisema e doença intersticial.	61
4.5	visualização de limitações do CR3D; (a) imagem de vaso com via aérea justaposta circulada em vermelho; (b) segmentação do vaso com via aérea justaposta (c) região com vasos de pequeno calibre (d) segmentação de vasos em vermelho são as marcações do padrão-ouro e em verde a segmentações do CR3D	62
4.6	visualização da segmentação vasos por CR3D com vias aéreas justapostas; (a) imagem original com a via aérea circulada em vermelho; (b) segmentação dos vasos	62
4.7	sensibilidade e similaridade da segmentação por CR3D considerando a primeira abordagem de avaliação	63
4.8	sensibilidade e similaridade da segmentação por CR3D pela segunda abordagem de avaliação	63
4.9	visualização da árvore de vasos sanguíneos pulmonares através da segmentação por CR3D.	64
4.10	segmentação dos vasos sanguíneos por CF,(a),(c) e (e) imagens originais; (b) segmentação em paciente sadio;(d)segmentação em paciente com doença intersticial;(f) segmentação em paciente com enfisema e doença intersticial.	65
4.11	avaliação da segmentação dos vasos sanguíneos por CF; (a),(c) e (e) imagens originais com vias aéreas circuladas em vermelho; (b),(d) e (f) respectivas segmentações dos vasos vizinhos as vias aéreas.	66
4.12	sensibilidade e similaridade da segmentação por CF por meio da primeira abordagem de avaliação	66

4.13	sensibilidade e similaridade da segmentação por CF considerando a segunda abordagem de avaliação	67
4.14	visualização da árvore de vasos sanguíneos por meio da segmentação por CF	67
4.15	taxas de acerto do classificador K-médias aplicado ao banco de dados de treino; (a)Histograma das taxas de acerto; (b) Box plot das taxas de acerto.	68
4.16	segmentação dos vasos sanguíneos por K-médias em imagens distintas; (a),(c) e (e) imagens originais; (b)e(d)segmentação em paciente normal; (f) segmentação em paciente com enfisema e doença intersticial;	69
4.17	avaliação da segmentação por K-médias dos vasos sanguíneos; (a),(c) e (e) imagens originais com vias aéreas circuladas em vermelho; (b),(d) e (f) respectivas segmentações dos vasos vizinhos as vias aéreas;	70
4.18	sensibilidade e similaridade da segmentação por K-médias pela primeira abordagem de avaliação	70
5.1	utilização da árvore de vasos sanguíneos para distinguir os lóbulos pulmonares.	73

Lista de Tabelas

2.1	classificação das regiões pulmonares segundo a aeração presente.	8
4.1	descrição das imagens utilizadas para avaliação dos algoritmos.	40
4.2	descrição das imagens utilizadas para avaliação dos algoritmos.	40
4.3	volume de segmentação do algoritmo CR3D	42
4.4	resultado da primeira abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CR3D	43
4.5	resultado da segunda abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CR3D	44
4.6	volume de segmentação por CF.	45
4.7	resultado da primeira abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CF	46
4.8	resultado da segunda abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CF	47
4.9	volume de segmentação por K-médias.	49
4.10	resultado da primeira abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por K-Médias	50
4.11	resultado da segunda abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por K-Médias	51

Lista de Siglas

3D	Tridimensional
ADP	Análise de Densidade Pulmonar
CR3D	Crescimento de Regiões 3D
CF	Conectividade <i>Fuzzy</i>
EP	<i>Embolia Pulmonar</i>
EM	<i>Expectation Maximization</i>
HP	<i>Hipertensão Pulmonar</i>
MCA	Método de Contornos Ativos
TC	Tomografia Computadorizada
TCAR	Tomografia Computadorizada de Alta Resolução

Resumo

A análise de imagens médicas por meio de técnicas de visão computacional tornou-se bastante promissora, principalmente pelo fato de aperfeiçoar a acurácia diagnóstica de diversas patologias. Por essas razões, a Pneumologia é considerada atualmente uma área de concentração de projetos que envolvem métodos de Processamento Digital de Imagens. A segmentação de vasos sanguíneos pulmonares é de bastante auxílio na detecção de cardiopatias pulmonares. Esse processo é realizado através da análise dos resultados obtidos por exame de diagnóstico por imagem, os quais se destacam as radiografias torácicas, tomografia computadorizada (TC) do tórax, ressonância magnética, cintilografia pulmonar e angiografia. A hipertensão pulmonar e o câncer são exemplos de doenças que podem ser diagnosticadas com menor subjetividade ao realizar a segmentação de vasos, visualização em três dimensões e extração de seus atributos. Devido a essa importância, diversos algoritmos são desenvolvidos com intuito de obter uma segmentação ótima destas estruturas. Dentre estes, encontram-se os métodos por contornos ativos, Lógica *Fuzzy*, Crescimento de Regiões, Filtragem Multi-escalar 3D e algoritmo *Expectation Maximization* (EM). Nesta dissertação, são segmentados os vasos sanguíneos pulmonares de imagens de tomografia computadorizada do tórax utilizando-se três métodos: uma combinação de Crescimento de Regiões 3D controlado por uma função de pertinência gaussiana e limiarização; um método híbrido de segmentação por Conectividade *Fuzzy* e limiarização; por fim, a segmentação utilizando o classificador K-médias. Os resultados obtidos pelas segmentações são analisados e comparados por meio de uma análise dos coeficientes de similaridade e sensibilidade. Os resultados da aplicação dos três métodos são caracterizados aceitáveis e compatíveis com os observados na literatura.

Palavras-chave: Crescimento de Regiões 3D, Conectividade *Fuzzy*, Análise de Densidade Pulmonar, Vasos Sanguíneos.

Abstract

Medical image analysis using computer vision techniques has become quite promising because of its improvement on the diagnostic accuracy of various pathologies. For this reason, pulmonology became an area of high concentration of projects involving methods of Digital Image Processing. The blood vessels segmentation in the lung is an important aid in the detection of pulmonary heart diseases. This process is performed by analyzing the results obtained with known diagnostic imaging exams, like chest X-rays, computed tomography (CT) scan, magnetic resonance imaging, scintigraphy and angiography. Pulmonary hypertension and cancer are examples of diseases that can be diagnosed with less subjectivity if performing vessels segmentation, three-dimensional visualization and attribute extraction of these images. Thus, several algorithms are developed with the objective of obtaining an optimal segmentation of these structures. Among those algorithms are active contours, fuzzy logic, 3D Region Growing, 3D multi-scale filtering algorithm and Expectation Maximization (EM). In this study, the blood vessels were extracted from lung CT scans of the chest using three methods. The first is a combination of 3D Region Growing controlled by a Gaussian membership function and thresholding, the second is a hybrid segmentation by thresholding and Fuzzy Connectedness. Finally, the third refers to segmentation using the K-means classifier. The results and evaluation of applying these algorithms are presented.

Keywords:3D Region Growing , Fuzzy Connectedness, Lung Density Analysis, Blood Vessels.

Agradecimentos

Dedico esta dissertação a minha mãe Fabíola Bezerra, alicerce de minha personalidade. Agradeço a Universidade Federal do Ceará por toda a estrutura de pesquisa disponível. Agradeço ao CNPq pelo financiamento deste estudo. Agradeço aos professores Dr. Paulo Cortez e Dr. Marcelo Alcântara pela orientação e ensino. Agradeço aos meus companheiros de laboratório Tarique Cavalcante, Thomaz Maia, Pedro Pedrosa e Valberto Enoc pelo auxílio inquestionável neste estudo. Agradeço aos meus irmãos Everton Bezerra e Ítalo Bezerra pela paciência e apoio. Agradeço a minha noiva Isabelly Silva, minha companheira, por sempre estar ao meu lado.

*“Tudo virá no seu tempo, eu disse tudo. Tudo no seu dia virá.
Então jogue suas mágoas ao vento e deixe essa água rolar.”*

Fauzi Beydoun

Capítulo 1

Introdução

Várias técnicas de Processamento Digital de Imagem são utilizadas com a finalidade de segmentar, reconhecer e identificar detalhes da região de interesse, de modo automático ou semi-automático (JAN, 2006). Em Pneumologia, diversos projetos de visão computacional são desenvolvidos com intuito de prover um auxílio ao diagnóstico de patologias pulmonares, tal como podem ser observados nos trabalhos de Félix (2007), Rebouças Filho (2010), Cavalcante (2010) e Kaftan et al. (2008).

A importância do estudo de patologias pulmonares é evidente, visto a ocorrência em grande parte da população mundial (ROBBINS; COTRAN, 2005). Dentre as doenças que atingem os vasos sanguíneos pulmonares destaca-se a hipertensão pulmonar, observada de forma frequente sendo efeito de uma série de patologias que afetam o ventrículo esquerdo, a drenagem venosa pulmonar, a circulação arterial pulmonar, sendo consequência também de doenças pulmonares que afetam o interstício e parênquima pulmonar (MORAES; LOSCALZO, 1997).

Outra patologia a ser destacada é a embolia pulmonar (EP). Essa ocorre como consequência de um trombo, formado no sistema venoso profundo, que se desprende e, atravessando as cavidades direitas do coração, obstrui a artéria pulmonar ou um de seus ramos (CARAMELLI et al., 2004). Somente nos EUA são relatados mais de 100 casos para 100.000 pessoas por ano (WHITE., 2003). No Brasil e nos demais países da América Latina, são escassos os trabalhos publicados sobre a epidemiologia do tromboembolismo pulmonar (KLEINFELDER et al., 2009).

A circulação pulmonar tem início no ventrículo direito, de onde o sangue é bombeado para a rede capilar dos pulmões. Após a hematose, o sangue oxigenado retorna ao átrio esquerdo. Devido ao fato de ser uma circulação coração-pulmão-corção é comum denominá-la de pequena circulação (DÂNGELO; FATTINI, 2002).

O vasos sanguíneos pulmonares são importantes objetos de estudo, visto que sua segmentação, visualização em três dimensões e extração de atributos tornou mais evidente a detecção de doenças, como por exemplo, o câncer pulmonar (TOZAKI et al., 1996), hipertensão pulmonar (LINGURARU et al., 2008) e embolismo (MASUTANI; MACMAHON; DOI, 2002). Estas patologias são verificadas pela análise dos resultados obtidos por exames de diagnóstico por imagem, entre os quais destacam-se as radiografias torácicas, tomografia computadorizada (TC) do tórax, ressonância magnética, cintilografia pulmonar e angiografia (HOVNANIAN et al., 2011).

Neste contexto, é fundamental a necessidade de um diagnóstico exato dessas patologias de forma precoce e, assim, detectar os reais estágios das doenças pulmonares, nas quais por muitos casos a identificação dos vasos sanguíneos é um fator determinante. Dada esta importância, diversos algoritmos de visão computacional são desenvolvidos com intuito de obter uma segmentação precisa dessas estruturas.

O desenvolvimento de projetos que envolvem Visão Computacional deve seguir basicamente 5 etapas: aquisição, pré-processamento, segmentação, extração de características e reconhecimento e interpretação (GONZALEZ; WOODS, 2008).

Aquisição da imagem, trata-se de adquirir uma imagem digital por meio de máquinas fotográficas, câmera de vídeo ou outros dispositivos com tecnologia CCD por exemplo. Uma imagem digital é uma imagem discretizada tanto em coordenadas espaciais quanto em brilho, sendo considerada uma matriz cujos índices de linhas e de colunas identificam um ponto (*pixel*) na imagem, e o valor do elemento da matriz identifica o nível de cinza naquele ponto (GONZALEZ; WOODS, 2008).

A etapa de pré-processamento consiste em alterar a imagem, de modo que o resultado seja mais apropriado do que a imagem original para uma aplicação específica. Nesse processo são utilizadas técnicas de remoção de ruído, realce de contraste dentre outros. O estágio posterior é a segmentação que, em termos gerais, extrai os objetos de interesse da imagem.

Após segmentada a imagem, é preciso realizar o processo de descrição, também chamado de extração de características. Esse processo extrai peculiaridades que resultem em alguma informação quantitativa de interesse ou que sejam básicas para discriminação entre classes de objetos.

O último passo é o reconhecimento e interpretação. Reconhecimento é processo que atribui um rótulo a um objeto, baseado em suas informações. Interpretação é a atribuição de um significado a um conjunto de objetos reconhecidos. Para a realização de todas as

etapas é necessária uma base de conhecimento, pois a comunicação entre os estágios baseia-se em conhecimento prévio da natureza esperada do resultado. No trabalho de Kaftan et al. (2008) foi utilizada Lógica *Fuzzy* combinada com Limiarização e Transformada da Distância para realizar a segmentação semi-automática dos vasos sanguíneos pulmonares em imagens de TC. Através de Filtragem Multi-Escalar 3D, Sato et al. (1998) também segmentaram estas estruturas em imagens de TC. No trabalho de Zhu et al. (2009) os vasos sanguíneos são segmentados utilizando Contorno Ativo com algoritmo *level set*. Outro trabalho a ser destacado é o de Zhou et al. (2007) que realiza essa segmentação com do algoritmo *Expectation Maximization*(EM). Já Félix (2007), com morfologia matemática e Crescimento de Regiões, segmentou os vasos sanguíneos.

Neste sentido, este trabalho centraliza seus esforços na extração dos vasos sanguíneos pulmonares de imagens de tomografia computadorizada do tórax através de três métodos. O primeiro trata-se de um novo método de segmentação dos vasos que visa eliminar a necessidade de uma segmentação inicial, no qual se baseia na análise de densidade pulmonar (ADP) combinada com o classificador K-médias. A segunda, aplicada com intuito de obter um modelo flexível de segmentação, trata-se de uma combinação de Crescimento de Regiões 3D controlado por uma função de pertinência gaussiana e limiarização. Por fim, a terceira é um híbrido de segmentação por Conectividade *Fuzzy* e limiarização, a qual também é um modelo flexível de segmentação.

1.1 Objetivos

O objetivo geral desse trabalho consiste em desenvolver e aplicar algoritmos para segmentar os vasos sanguíneos pulmonares em imagens de TC do tórax. Durante o desenvolvimento desta dissertação outros objetivos específicos devem ser alcançados:

- i. obtenção de uma nova metodologia de segmentação de vasos sanguíneos;
- ii. implementação de algoritmos descritos na literatura para segmentação de vasos sanguíneos;
- iii. avaliação dos algoritmos pesquisados e desenvolvidos junto ao médico especialista;

1.2 Organização da Dissertação

Esta dissertação está organizada em 5 capítulos. No capítulo 2 são apresentados alguns conceitos importantes sobre imagens médicas, sobretudo imagens de tomografia computadorizada e cardiopatias pulmonares. Ainda no mesmo capítulo é feita a apresentação dos métodos de segmentação utilizados neste trabalho. Por fim, é realizada uma breve revisão bibliográfica sobre os trabalhos relacionados a esta dissertação.

No capítulo 3 é descrita a metodologia empregada para a implementação de cada algoritmo. Os resultados de cada método estudado é apresentado no capítulo 4 e, por fim, no capítulo 5 são apresentadas as conclusões e contribuições deste trabalho e os trabalhos futuros que podem ser desenvolvidos a partir do mesmo.

Capítulo 2

Fundamentação Teórica e Estado da Arte

Neste Capítulo inicialmente são discutidas as características das imagens adquiridas por TC do tórax. Também é realizado um breve estudo sobre circulação pulmonar, tal como uma revisão sobre as cardiopatias pulmonares hipertensão pulmonar e embolismo. Posteriormente, é realizada uma breve descrição do Método de Contorno Ativo crisp (MCA crisp) utilizado para segmentar o pulmão. Também são descritos os métodos Conectividade Fuzzy, Crescimento de Regiões 3D, Limiarização e o Classificador K-médias utilizados para segmentar os vasos sanguíneos. Por fim, é discutido o Estado da Arte em segmentação de vasos sanguíneos pulmonares em imagens de TC do tórax.

2.1 Imagens de Tomografia Computadorizada do Tórax

Há três tipos de aparelhos de Tomografia Computadorizada (TC): convencional, helicoidal *singleslice* e helicoidal *multislice* (WEBB W. E. BRANT, 2005). Para visualizar os vasos sanguíneos pulmonares, são utilizadas imagens de TC helicoidal *multislice* obtidas em plano axial. Após a sua obtenção, recursos computacionais permitem reconstruções em outros planos, tal como pode ser visualizado na Figura 2.1. Deste modo, esta possibilidade de analisar as seções transversais do corpo é um dos motivos que torna vantajosa a utilização de imagens de TC na análise de patologias que afetam o pulmão, dada a possibilidade de visualização de diversas estruturas, como vasos sanguíneos, vias aéreas, hilo, pleura e parênquima pulmonar em três dimensões (CAVALCANTE, 2010). Algumas imagens adquiridas por TC são caracterizadas pela presença de contraste intravenoso. Trata-se de uma substância, que ao ser inserida por meio de injeção intravenosa, realça os

vasos sanguíneos permitindo uma melhor visualização (SANTOS; GAIVÃO; TAVARES, 2009). Não obstante ao fato de prover uma melhor visualização dos vasos, essa substância pode causar reações adversas no organismo como insuficiência renal, manifestações cutâneo-mucosas (prurido), eritema, náuseas, vômitos, cefaleias, febre, dor abdominal, parotidite, dentre outras (SANTOS; GAIVÃO; TAVARES, 2009).

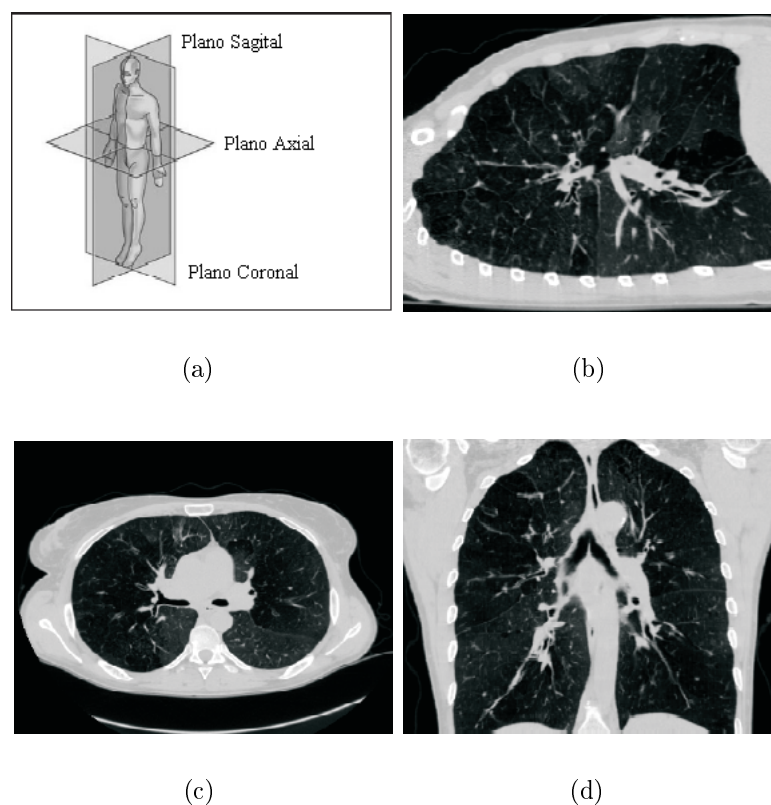


Figura 2.1: imagens de seções do pulmão adaptada de (SLUIMER; PROKOP; GINNEKEN, 2005), a) planos de corte em relação ao corpo humano; b) seção sagital; c) seção axial; e d) seção coronal.

A menor representação espacial de uma imagem 2D é o *pixel*. Todavia, como é considerada uma análise tridimensional das imagens de TC, o *voxel* é a definição da menor unidade dimensional da imagem (HOUNSFIELD, 1973). Na Figura 2.2 é ilustrada a representação dos componentes espaciais de uma de imagem de TC do tórax.

Para determinar o valor de densidade de cada *voxel* interior a região de interesse, o tomógrafo realiza a medição da atenuação de radiação que o corpo humano provoca quando atravessado por um feixe de raios X (BUSHONG, 2005). Atenuação radiológica é a propriedade que os materiais têm em absorver a radiação eletromagnética (FÉLIX, 2007). Uma medida de atenuação quantifica a fração de radiação removida, quando uma determinada quantidade de radiação atravessa um material com espessura específica.

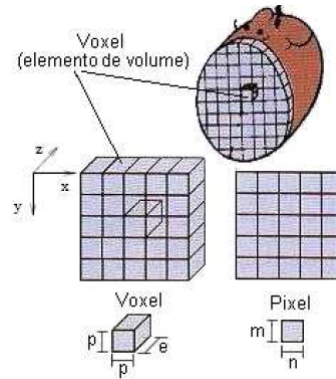


Figura 2.2: ilustração representativa do *pixel* e do *voxel*, adaptada de (BONTRAGER, 2000).

Esta atenuação é realizada por todo o corpo. Assim, se obtém uma grande quantidade de dados para definir em cada ponto da imagem o valor de atenuação, ou de densidade.

Para cada elemento de volume é dado um valor numérico que corresponde à quantidade média de absorção de radiação (EPSTEIN, 2001). A densidade na tomografia computadorizada é diretamente proporcional com o coeficiente de atenuação, uma constante do tecido influenciado por alguns fatores. A determinação do coeficiente de atenuação UH_{tecido} é dada por (EPSTEIN, 2001).

$$UH_{tecido} = 1000 \times \frac{(\mu_{tecido} - \mu_{agua})}{\mu_{agua}} \quad (2.1)$$

em que o parâmetro μ_{tecido} é a medida do coeficiente de absorção do tecido de um *voxel* e μ_{agua} é a medida do coeficiente de absorção da água.

Em imagens de TC, os valores de atenuação são medidos em unidades Hounsfield (UH). O valor de atenuação do ar e da água definidos como -1000 UH e 0 UH, respectivamente representam pontos fixos na escala de densidade do TC e mantêm-se inalterados mesmo com a variação da tensão do tubo (BUSHONG, 2005).

Através da comparação com os tecidos circundantes, a estrutura pode ser descrita como isodensa, hipodensa ou hiperdensa. Em órgãos parenquimatosos como o cérebro, fígado, rins e pâncreas, o valor de atenuação dos tecidos circundantes sadios é normalmente usado para comparação. Os valores de densidade na faixa da água são descritos como *água-densos*, aqueles na faixa da gordura como *gordura-densos*, e aqueles na faixa dos músculos, como *músculo-densos* (BUSHONG, 2005). Os valores em UH para determinados tipos de tecidos e órgãos do corpo humano são apresentados na Figura 2.3. Para o pulmão juntamente com todas as suas estruturas, a faixa de densidade está compreendida entre -1000 UH e 100 UH (SLUIMER; PROKOP; GINNEKEN, 2005).

Vieira et al. (1998), Cavalcante (2010) e Gevenois e Yernault (1995) por meio de

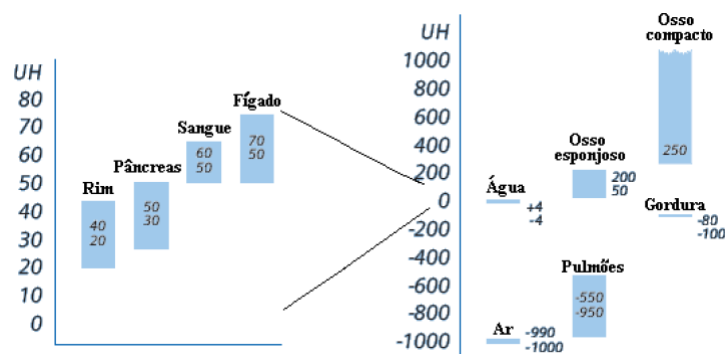


Figura 2.3: escala em Unidades Hounsfield, adaptada de (SIEMENS, 2004).

análise da densidade pulmonar, classificaram as regiões pulmonares considerando somente a aeração presente na região específica. Foram atribuídas quatro classes: região hiper-aerada, normalmente aerada, pouco aerada e não aerada.

Na região normalmente aerada, em alguns casos, há presença de vasos no seu mais baixo grau de aeração. Neste sentido, são observados melhores resultados na segmentação ao se subdividir a classe normalmente aerada em duas subclasses: Normalmente aerada α e normalmente aerada γ . Deste modo, a classificação das regiões pulmonares para esta dissertação segundo a aeração é mostrada na tabela 2.1.

Tabela 2.1: classificação das regiões pulmonares segundo a aeração presente.

Hiper aerada	-1000 a -900
Normalmente aerada α	-900 a -750
Normalmente aerada γ	-750 a -500
Pouco aerada	-500 a -100
Não aerada	-100 a 100

É visualizada na Figura 2.4, uma imagem de TC do Tórax, em que são classificadas as regiões quanto a aeração atribuindo-se tonalidades distintas para cada classe de aeração de acordo como a Tabela 2.1. A classificação da região quanto a densidade em UH está representada pelas cores na Figura 4.1(b). A Cor vermelha representa regiões Hiper aeradas, o verde claro regiões normalmente aeradas α , o verde escuro normalmente aeradas γ , a cor amarela representa regiões de pouca aeração e, por fim, a cor azul trata-se de regiões não aeradas. As áreas não classificadas estão representadas pela cor preta.

2.2 Vasos Sanguíneos Pulmonares

A circulação pulmonar tem início no ventrículo direito, de onde o sangue é bombeado para a rede capilar dos pulmões. Após a hematose, o sangue oxigenado retorna ao




Figura 2.4: imagem de TC multidetectores, (a) imagem original; (b) representação em faixa de densidade UH.

átrio esquerdo. Devido ao fato de ser uma circulação coração-pulmão-corção é comum denominá-la de pequena circulação (DÂNGELO; FATTINI, 2002).

A artéria pulmonar após passar além do ápice do ventrículo direito divide-se em dois ramos principais: direito e esquerdo. A função desses ramos é levar sangue para os pulmões. Os vasos pulmonares são curtos e possuem paredes muito finas e distensíveis, o que confere à árvore arterial pulmonar grande compliância (CARVALHO, 1983).

Por isso, explica-se o fato das artérias pulmonares acomodarem cerca de dois terços do débito sistólico do ventrículo direito. A artéria pulmonar contém sangue escuro, sobrecarregado de anidrido carbônico (sangue venoso) (GUYTON, 1997).

As veias pulmonares possuem características de distensibilidade similares às das veias da circulação sistêmica e, contrariamente as artérias, transportam sangue que abandonou o anidrido carbônico e se carregou de oxigênio, tomando a cor vermelha (sangue arterial) (FERRON, 2007). Na Figura 2.5 são ilustrados os componentes da circulação pulmonar.

Em imagens de TC do tórax, os vasos são visualizados a priori no plano axial, tal como alguns podem ser observados em destaque na Figura 2.6. Desta forma, por meio de recursos computacionais é possível realizar uma reconstrução em três dimensões dessas estruturas. Nota-se na Figura 2.6 uma diversidade de formas e tamanhos de vasos, além de pouca clareza quanto a determinação dos limites e formas dessas estruturas, o que se revela nada trivial a tarefa de segmentação. Entretanto, existe um ganho verificado ao realizar a segmentação e reconstrução 3D dos vasos, em que consiste no auxílio significativo ao

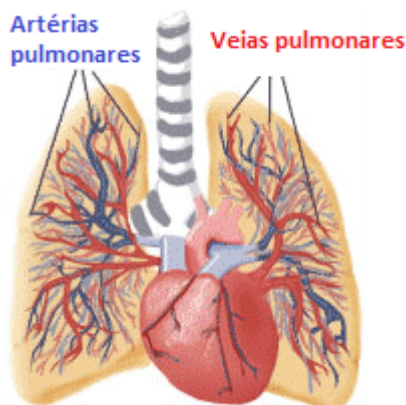


Figura 2.5: ilustração da circulação pulmonar , adaptada de (FAUCI et al., 2003).

diagnóstico de diversas patologias, por exemplo, o embolismo (MASUTANI; MACMAHON; DOI, 2002) e hipertensão pulmonar (LINGURARU et al., 2008).



Figura 2.6: imagem de TC do tórax com destaque em alguns vasos sanguíneos.

2.3 Cardiopatias Pulmonares

A OMS define a ocorrência de cardiopatia pulmonar quando o fluxo de sangue para os pulmões é retardado, bloqueado ou aumentado, ou seja, ocorre falha no ventrículo direito devido a algum problema pulmonar. As principais doenças cardiopulmonares são a hipertensão pulmonar e o embolismo.

Define-se como hipertensão pulmonar (HP) a presença de pressão média de artéria pulmonar maior que 25 mmHg, em repouso, ou maior que 30 mmHg ao exercício, com pressão de oclusão da artéria pulmonar menor que 15 mmHg (BARRETO; GAZZANA, 2000). Desse modo, os níveis de pressão da artéria pulmonar são desproporcionalmente elevados

para um dado nível de fluxo sanguíneo pulmonar. A HP é classificada como hipertensão arterial pulmonar idiopática (HAPI) quando nenhum fator causal pode ser identificado (CHANNICK, 2004).

Dados norte-americanos e europeus descrevem a hipertensão arterial pulmonar idiopática com incidência de 1 a 2 casos por milhão por ano e prevalência de 15 casos por milhão de habitantes, com predominância do sexo feminino, na razão aproximada de 2:1 e início dos sintomas predominantemente após a segunda ou terceira década de vida (MCGOON et al., 2004). Neste sentido, para diagnosticar a HP o exame de TC do tórax mostra-se uma importante ferramenta, pois proporciona uma excelente visualização da vasculatura pulmonar, parênquima pulmonar e estruturas mediastinais.

Outra patologia a ser destacada é a embolia pulmonar (EP). A EP ocorre como consequência de um trombo, formado no sistema venoso profundo, que se desprende e, atravessando as cavidades direitas do coração, obstrui a artéria pulmonar ou um de seus ramos (CARAMELLI et al., 2004). Somente nos Estados Unidos são relatados mais de 100 casos para 100.000 pessoas por ano (WHITE., 2003). No Brasil e nos demais países da América Latina, são escassos os trabalhos publicados sobre a epidemiologia da embolia pulmonar (KLEINFELDER et al., 2009). O aumento do risco de EP, de acordo com a elevação da faixa etária, foi descrito em alguns estudos (ANDERSON et al., 1991) (GOLDHABER et al., 1983) (COON P.W. WILLIS, 1973). Evidentes correlações entre idade e risco foram confirmadas no estudo realizado em Worcester, que identificou 89% dos pacientes com EP com idade maior que 40 anos (ANDERSON et al., 1991). No estudo de Framingham, foi observada maior incidência de EP maciça nos pacientes de faixa etária mais alta (GOLDHABER et al., 1983). A insuficiência cardíaca congestiva (ICC) e a doença pulmonar obstrutiva crônica (DPOC) são situações clínicas também predisponentes ao tromboembolismo venoso pulmonar (KASPER et al., 1997).

A apresentação clínica da EP é geralmente inespecífica, dificultando o diagnóstico. Os sinais e sintomas dependem, fundamentalmente, da localização e tamanho do trombo e do estado cardiorrespiratório prévio do paciente (RENSHAW S.R. BRENNAN, 1999).

A TC do tórax vem sendo amplamente utilizada na investigação de pacientes com suspeita clínica de EP. A boa acurácia, o custo relativamente baixo, se comparado à arteriografia convencional, a possibilidade de investigação de outros diagnósticos diferenciais estão entre as vantagens da TC, frente a outras estratégias (CARAMELLI et al., 2004).

2.4 Segmentação de Imagens

A segmentação subdivide uma imagem em suas partes ou objetos constituintes (GONZALEZ; WOODS, 2008). Quando forem isolados todos os objetos de interesse da imagem, o objetivo da aplicação dessa técnica é concluído. As estratégias de segmentação são basicamente firmadas em verificação de descontinuidade ou similaridade (CAVALCANTE, 2010). O método que avalia a descontinuidade considera a mudança abrupta dos valores de cinza por exemplo, descontinuidade da normal das superfícies, descontinuidade em profundidade, descontinuidade na reflectância da superfície e descontinuidade de iluminação, já o método por similaridade fundamenta-se na agregação de pixels em função da sua semelhança com os pixels vizinhos por exemplo, texturas ou cores (GONZALEZ; WOODS, 2008).

2.4.1 Segmentação do Pulmão

A primeira etapa para identificação dos vasos sanguíneos é a segmentação do pulmão. Trata-se de uma importante etapa de pré-processamento, em que reduz-se consideravelmente o custo computacional e simplifica a identificação dos vasos ao eliminar as estruturas externa do pulmão. Utilizou-se o método de contorno ativo para efetuar essa segmentação.

2.4.1.1 Método Contorno Ativo Tradicional

Segmentar determinado objeto da imagem através de um contorno é em que consiste basicamente o método de contornos ativos. O contorno inicial é deformado devido à minimização das energias que atuam sobre o mesmo. Este método foi introduzido por Kass, Witkin e Terzopoulos (1988), e permite segmentar imagens por detecção de contornos. O MCA é baseado em métodos variacionais, cujo objetivo é minimizar uma função que representa a energia do contorno. O modelo Tradicional é chamado de deformável porque está descrito por uma energia E que varia de acordo com a equação (KASS; WITKIN; TERZOPOULOS, 1988)

$$E = \int_0^1 f_1 |c'(s)|^2 + f_2 |c''(s)|^2 + E_{ext}(c(s)) |ds. \quad (2.2)$$

Os termos $c'(s)$ e $c''(s)$ são denominados componentes da energia interna e representam, respectivamente a primeira e a segunda derivada da curva $c(s)$ (KASS; WITKIN; TERZOPOULOS, 1988). A energia interna depende somente de sua geometria e da localização dos pontos da curva (SILVA, 2005). A primeira derivada $c'(s)$ é a força de continuidade,

a qual é ligada à elasticidade da curva. O termo $c''(s)$ é a força de curvatura baseada na análise nos ângulos internos da curva, tendendo a deixá-la contínua e, deste modo, mantê-la suave. As variáveis f_1 e f_2 são coeficientes que especificam a relevância das forças. O termo E_{ext} é associado às forças externas, designadas por informações da imagem (KASS; WITKIN; TERZOPOULOS, 1988). Esse parâmetro é definido por (SONKA; HLAVAC; BOYLE, 2008)

$$E_{ext}(s) = w_l E_l(s) + w_g E_g(s) + w_t E_t(s), \quad (2.3)$$

em que E_l representa a energia proveniente das linhas da imagem, E_g representa o gradiente da borda e E_t é a energia relativa às terminações. Os termos w_l, w_g, w_t são pesos que definem a relevância de cada energia na composição da energia total. Normalmente, utiliza-se o operador gradiente para calcular essa energia, visto que este possui informações de linhas, pontos e bordas (Rebouças Filho, 2010). Existem vários Métodos de Contorno Ativos, cada um com suas devidas particularidades. Para efetuar a segmentação do pulmão, neste trabalho é utilizado um Método de Contorno Ativo Paramétrico, especificamente o método Crisp proposto por Rebouças Filho (2010), desenvolvido exclusivamente para segmentação pulmonar.

2.4.1.2 Método de Contorno Ativo Crisp

O MCA Crisp foi desenvolvido com o objetivo de otimizar a segmentação do pulmão em imagens de TC do tórax, visto as limitações do MCA tradicional em realizar essa tarefa (Rebouças Filho, 2010). O MCA Crisp propõe uma inicialização automática do contorno no interior do pulmão e uma força externa a ser incorporada ao MCA Balão desenvolvido por Cohen (1991). O MCA Crisp é descrito de acordo com a equação (Rebouças Filho, 2010)

$$E_{Crisp}[c(s)] = w_{cont} F_{cont}[c(s)] + w_{bal} F_{bal}[c(s)] + w_{crisp} F_{crisp}[c(s)], \quad (2.4)$$

em que $F_{cont}[c(s)]$ é a força de continuidade, a mesma que caracteriza o MCA tradicional, $F_{bal}[c(s)]$ é a força Balão. O termo $F_{crisp}[c(s)]$ trata-se da força Crisp baseada no conhecimento específico das densidades pulmonares obtidas em imagens de TC e identifica quais estruturas encontradas através do operador Sobel são as bordas do pulmão (Rebouças Filho, 2010). Os termos w_{cont} , w_{bal} e w_{crisp} são referentes aos pesos de cada força na composição da energia do MCA Crisp. Na Figura 2.7 é possível verificar um exemplo de segmentação e renderização por meio do método descrito.




Figura 2.7: aplicação do MCA crisp (a) visualização em duas dimensões da segmentação do pulmão utilizando o MCA Crisp (b) renderização da segmentação por MCA Crisp do pulmão.

2.4.2 Segmentação dos Vasos Sanguíneos

Existem diversas metodologias para segmentação de vasos sanguíneos. Dentre estas, três metodologias que se destacam com bons resultados observados na literatura foram utilizadas nesta dissertação: Fuzzy, orientada a regiões e reconhecimento de padrões.

O método Conectividade Fuzzy é também utilizado Kaftan et al. (2008) para segmentar os vasos sanguíneos. A aplicação do Crescimento de Regiões 3D para segmentação de vasos sanguíneos pulmonares pode ser observada nos trabalhos de Masutani, MacMahon e Doi (2002) e Raghupathi e Lakare (2009), entretanto foi utilizada neste trabalho uma metodologia segmentação de vasos utilizando Crescimento de Regiões 3D controlado por uma função de pertinência gaussiana. A aplicação do classificador K-médias combinado com análise de densidades pulmonares (ADP) é uma metodologia inédita para segmentação de vasos. O método de Limiarização é basicamente utilizado como etapa inicial de segmentação por Crescimento de Regiões e Conectividade Fuzzy. A seguir, é realizada uma breve revisão sobre os métodos utilizados para segmentar os vasos sanguíneos.

2.4.2.1 Limiarização

O princípio da limiarização consiste em separar as regiões de uma imagem em duas classes: o fundo e o objeto (GONZALEZ; WOODS, 2008). Quando a aplicação da limiarização produzir uma imagem binária, o processo também é denominado, muitas vezes,

binarização. A forma mais simples de limiarização consiste na bipartição do histograma, convertendo os pixels cujo tom de cinza é maior ou igual a um certo valor de limiar T em brancos e os demais em pretos.

Matematicamente, a operação de limiarização pode ser descrita como uma técnica de processamento de imagens na qual uma imagem de entrada $f(x, y)$ de N níveis de cinza produz à saída uma imagem $g(x, y)$, chamada de imagem limiarizada, cujo número de níveis de cinza é menor que N (GONZALEZ; WOODS, 2008). Normalmente, $g(x, y)$ apresenta 2 níveis de cinza, sendo

$$g(x, y) = \begin{cases} 1, & f(x) \geq T \\ 0, & f(x) < T \end{cases} \quad (2.5)$$

em que os pixels rotulados com 1 correspondem aos objetos, com valor 0 correspondem ao fundo e T é um valor de tom de cinza pré-definido, ao qual denomina-se limiar.

A limiarização pode ser vista como uma operação que envolve um teste com relação a uma função T do tipo (Marques Filho, 1999)

$$T = T[x, y, p(x, y), f(x, y)], \quad (2.6)$$

em que $f(x, y)$ é o tom de cinza original no ponto (x, y) e $p(x, y)$ indica alguma propriedade local deste ponto, por exemplo a média de seus vizinhos. Quando T depende apenas de $f(x, y)$, o limiar é chamado global, já quando T depende de $f(x, y)$ e de $p(x, y)$, o limiar é chamado local. Se, além disso, T depende das coordenadas espaciais (x, y) , o limiar é chamado dinâmico ou adaptativo (Marques Filho, 1999).

O histograma é uma representação gráfica da distribuição de probabilidade de ocorrência dos níveis de cinza em uma imagem (GONZALEZ; WOODS, 2008). Deste modo, é comum a utilização de técnicas de cálculo do valor ótimo de limiar com base nas propriedades estatísticas da imagem. Uma destas técnicas, denominada limiarização ótima, parte de uma imagem da qual se conhecem as principais propriedades estatísticas. Considerando que sua distribuição de probabilidade é normal ou gaussiana mostra-se que existe um valor ótimo de limiar, T , dado por uma das raízes da equação (GONZALEZ; WOODS, 2008)

$$AT^2 + BT + C = 0, \quad (2.7)$$

onde:

$$A = \sigma_1^2 - \sigma_2^2 \quad (2.8)$$

$$B = 2(\mu_1\sigma_2^2 - \mu_2\sigma_1^2) \quad (2.9)$$

$$C = \mu_2^2 \sigma_1^2 - \mu_1^2 \sigma_2^2 + 2\sigma_1^2 \sigma_2^2 \ln\left(\frac{\sigma_2 P_1}{\sigma_1 P_2}\right) \quad (2.10)$$

O termo μ_1 representa a média dos tons de cinza da região de interesse e μ_2 trata-se média dos tons de cinza da região de fundo. O desvios padrão são representados pelas variáveis σ_1 e σ_2 . Os parâmetros P_1 e P_2 correspondem a probabilidade de ocorrência dos pixels a região de interesse ou ao fundo, respectivamente. Duas raízes reais e positivas indicam que a imagem pode requerer dois valores de limiar para obter uma solução ótima (GONZALEZ; WOODS, 2008). Se as variâncias forem iguais $\sigma^2 = \sigma_1^2 = \sigma_2^2$ um único valor T é necessário (Marques Filho, 1999)

$$T = \frac{\mu_1 + \mu_2}{2} + \frac{\sigma^2}{\mu_1 - \mu_2} \ln\left(\frac{P_2}{P_1}\right) \quad (2.11)$$

Se, além disso, as duas classes forem equiprováveis,

$$T = \frac{\mu_1 + \mu_2}{2} \quad (2.12)$$

Neste sentido, verifica-se o conceito intuitivo de que o valor ótimo de limiar quando as classes apresentam a mesma distribuição de probabilidade é o ponto médio entre as médias das classes.

2.4.2.2 Lógica *Fuzzy*

Segmentação de imagens utilizando Lógica Nebulosa tem sido extensivamente aplicada em diversas áreas (ACHARYA; RAY, 2005). A teoria de Lógica *Fuzzy* parte do princípio que tudo pode ser tratado como um problema de grau de associação entre objetos (ACHARYA; RAY, 2005). Assumindo Z como o conjunto dos números inteiros, portanto Z^n trata-se de uma representação espacial n -dimensional cujos elementos básicos são definidos como *spels* (*spatial elements*) (LAGE, 2010). Neste trabalho, como é utilizado o espaço tridimensional, representa-se o *spel* por *voxel*. Um subconjunto A , definido em Z^n é um conjunto de pares ordenados descritos por (SHAW; SIMÕES, 2010)

$$A = \{(x, \mu_A(x)) | x \in Z^n\}, \quad (2.13)$$

em que, $\mu_A(x) : Z^n \rightarrow [0, 1]$ representa uma função, cujo valor indica o grau de pertinência do elemento x a A . Uma relação *fuzzy* ρ é um subconjunto de Z^n definido por (UDUPA; SAMARASEKERA, 1996)

$$\rho = \{((x, y), \mu_\rho(x, y)) | x, y \in Z^n\}, \quad (2.14)$$

em que, $\mu_\rho(x, y) : Z^n \rightarrow [0, 1]$. A relação *Fuzzy* ρ entre os elementos x e y é considerada reflexiva se $\forall x \in Z^n$,

$$\mu_\rho(x, x) = 1, \quad (2.15)$$

simétrica, se $\forall x, y \in Z^n$,

$$\mu_\rho(x, y) = \mu_\rho(y, x), \quad (2.16)$$

e passa a ser considerada transitiva se $\forall x, z \in Z^n$, (UDUPA; SAMARASEKERA, 1996)

$$\mu_\rho(x, z) = \max_{y \in Z^n} [\min[\mu_\rho(x, y), \mu_\rho(y, z)]]. \quad (2.17)$$

Uma relação ρ a qual observa-se simultaneamente simetria e transitividade e reflexibilidade é definida como relação de semelhança (UDUPA; SAHA, 2003).

A relação de adjacência *fuzzy* associa a cada par de *voxels* (x, y) um valor entre zero e um, definidos no domínio do espaço digital. Esse valor indica a proximidade espacial entre os elementos comparados. A definição de adjacência *fuzzy* é verificada quando uma relação ρ definida em Z^n é simétrica e reflexiva. Portanto, o par (Z^n, ρ) é caracterizado como espaço digital *fuzzy* (UDUPA; SAMARASEKERA, 1996).

Uma cena *fuzzy* é definida no espaço digital (Z^n, ρ) como um par $P = (C, f)$ em que

$$C = \{c \mid -b_j \leq c_j \leq b_j \forall b \in Z_+^n\} \quad (2.18)$$

O parâmetro f , trata-se de uma função caracterizada por ser a intensidade da cena e definida no domínio C (LAGE, 2010). Uma relação ρ que seja simultaneamente simétrica e reflexiva definida no domínio de uma cena é dita afinidade *fuzzy* representada por j (LAGE, 2010). O grau de pertinência dessa relação é definido por $\mu_j(x, y)$, cujo valor indica o quão similar é a intensidade dos *voxels* x e y .

Neste sentido, baseando-se nesses conceitos de adjacência e afinidade *fuzzy* utiliza-se a teoria de conectividade fuzzy para segmentar os vasos sanguíneos.

2.4.2.3 Conectividade *Fuzzy*

A partir da combinação dos conceitos de afinidade e vizinhança *fuzzy*, deduz-se que é possível encontrar uma conectividade global entre dois *voxels* v_1 e v_2 no domínio de uma cena *fuzzy*, a partir de uma sequência de afinidades locais (UDUPA; SAMARASEKERA, 1996). Essa sequência pode ser interpretada como caminho e existem inúmeros caminhos passando somente por adjacências unitárias e que unam esses dois *voxels*. Essa conectividade global é definida como Conectividade *Fuzzy* (*Fuzzy Connectedness*), representada por k e sua função de pertinência entre v_1 e v_2 por $\mu_k(v_1, v_2)$ (LAGE, 2010).

Considerando o caminho $c_{v_1 v_2} = \{s_1, s_2, s_3 \dots s_N\}$ entre $s_1 = v_1$ e $s_N = v_2$, em que s_i são N *voxels* adjacentes em pares entre si, a afinidade local entre dois *voxels* s_1 e s_2

pode ser definida por $\mu_{kl}(s_1, s_2)$. Portanto a afinidade $\mu_k(v_1, v_2)$ deste caminho é dada por (KAFTAN et al., 2008)

$$\mu_k(c_{v_1v_2}) = \min[\mu_{kl}(s_1, s_2), \mu_{kl}(s_2, s_3), \dots, \mu_{kl}(s_N - 1, s_N)], \quad (2.19)$$

isto é, a afinidade mais fraca é a que representa a melhor afinidade para este caminho. Contudo existem vários possíveis caminhos entre dois *voxels* e para calcular a conectividade global deve-se considerá-los. Faz-se necessária então, uma seleção da maior afinidade de caminho como melhor representação da afinidade global. Portanto, assumindo que C_j seja o conjunto de todos os caminhos c , a conectividade global entre x e y pode ser definida como (KAFTAN et al., 2008)

$$\mu_k(x, y) = \max[\mu_k(C_j)] \forall j. \quad (2.20)$$

Dessa forma, a definição de uma função de pertinência é dependente da definição de afinidade local entre os elementos que a compõe.

2.4.2.4 Função de Pertinência

A afinidade local definida na seção 2.4.2.3 é determinada a partir de uma função de densidade de probabilidade gaussiana tal como pode ser observado na Figura 2.8. Esta indica o grau de similaridade entre o *voxel* v_1 e a semente v_2 . Neste trabalho, utilizou-se a definição de componente de intensidade determinada por (UDUPA; SAMARASEKERA, 1996):

$$g(v_1, v_2) = e^{\frac{-1}{2\sigma^2}(\frac{x+y}{2}-\mu)}, \quad (2.21)$$

em que μ e σ representam a média e desvio padrão das densidades do objeto respectivamente. O valor esperado da densidade μ é estimado calculando-se o valor médio das densidades das sementes. O desvio padrão foi definido $\sigma = 200$, porem não é um valor crucial, visto possíveis alterações em decorrência de ruídos na imagem que possam ser confundidos com os objetos de interesse.

2.4.2.5 Crescimento de Regiões 3D

As características elementares do Crescimento de Regiões 3D não diferem das definições de Gonzalez e Woods (2008). Trata-se de uma técnica que agrupa *voxels* ou sub-regiões em regiões maiores baseando-se em algum critério predefinido de agregação (GONZALEZ; WOODS, 2008). Nesta dissertação, são utilizadas múltiplas sementes por meio de aplicação da limiarização. Em seguida, os *voxels* vizinhos às sementes são adicionados à




Figura 2.8: representação gráfica da função de pertinência gaussiana.

região caso as propriedades consideradas sejam semelhantes. Para aplicação do algoritmo Crescimento de Regiões, inicialmente é fixada uma região de interesse R podendo esta ser subdividida em n regiões $R_1, R_2, R_3, \dots, R_n$ com as seguintes características (GONZALEZ; WOODS, 2008):

$$\bigcup_{i=1}^n R_i = R, \quad (2.22)$$

$$R_i \text{ é uma região conectada, } i = 1, 2, 3, \dots, n, \quad (2.23)$$

$$R_i \cap R_j = \phi, \text{ para todo } i \text{ e } j, i \neq j, \quad (2.24)$$

$$P(R_i) = \text{VERDADEIRO para } i = 1, 2, \dots, n, \quad (2.25)$$

$$P(R_i \cup R_j) = \text{FALSO para } i \neq j, \quad (2.26)$$

A propriedade $P(R_i)$ é uma definição lógica sobre um conjunto de pontos R_i . A equação 2.22 indica que a segmentação deve ser completa, isto é, todos os *voxels* da imagem devem pertencer a uma região. A equação 2.23 informa que os pontos de uma região devem ser obrigatoriamente conectados. A equação 2.24 indica que as regiões devem ser disjuntas. Percebe-se na equação 2.25 que as propriedades dos *voxels* de uma mesma região devem ser semelhantes. Finalmente, a equação 2.26 informa que não existe regiões com propriedades idênticas.

É ilustrada na Figura 2.9 a aplicação básica do algoritmo Crescimento de Regiões 3D. Considerando uma máscara volumétrica $3 \times 5 \times 5$, em que as propriedades de cada *voxel* foram distinguidas por meio de atribuição de cores. Dessa forma, os *voxels* de cor branca possuem propriedade *A* e os de cor cinza, propriedade *B*. É atribuída cor vermelha a semente. Nesse exemplo, deseja-se segmentar os *voxels* com propriedade *A*.

Este método de segmentação baseia-se primordialmente em análise de similaridade na vizinhança da semente. Dessa forma, ela deve ser localizada em posição estratégica para melhor desempenho do algoritmo. Na Figura 2.9(a) é visualizada a determinação da semente.

A próxima etapa é analisar a vizinhança da semente. Os *voxels* vizinhos com propriedade *A* passam a possuir o mesmo rótulo da semente e, por conseguinte, obtêm-se uma região volumétrica inicial constituída agora por diversas sementes. Na Figura 2.9(b) é ilustrado o resultado da análise da vizinhança da semente. Observa-se que se a semente for posicionada na extremidade superior direita da máscara, somente três *voxels* são agrupados em todo o processo de segmentação.

Esse processo é iterativo. A verificação é realizada na vizinhança dos *voxels* que na iteração anterior foram inseridos a região de interesse. Na Figura 2.9(c) é mostrado o resultado da segmentação. Nesse exemplo ocorreu o caso de *voxels* com propriedade *A* que não foram segmentados. Isto acontece devido ao fato de o *voxels* não serem conectados a região e sejam caracterizados como vizinhos.




Figura 2.9: ilustração da aplicação do Crescimento de Regiões 3D. a) determinação do *voxel* semente em destaque vermelho b) primeira iteração do Crescimento de Regiões 3D analisando-se a vizinhança do *voxel* semente c) resultado final da segmentação

2.4.2.6 Reconhecimento de Padrões

A estrutura clássica de um sistema de reconhecimento de padrões mostrada Figura 2.10) é constituída em sua forma elementar por dois blocos: um de extração de característica e um de classificação (MARQUES, 2005). O primeiro bloco seleciona dados relevantes para a tomada de decisão, ou seja, ocorre uma transformação dos dados medidos pelos sensores em um conjunto menor de valores designado por características. Essas características são utilizadas pelo classificador para escolher a classe que melhor descreve a situação real.




Figura 2.10: estrutura clássica de um reconhecimento de padrões adaptada de (MARQUES, 2005).

As características extraídas pertencem a um conjunto finito, $S \subset \mathbb{R}^n$. Dessa forma, o padrão é um vetor

$$x = [x_1 \quad x_2 \quad \dots \quad x_n], \quad (2.27)$$

constituído por n componentes reais. O conjunto S é definido como espaço de características (MARQUES, 2005).

O objetivo do segundo bloco da Figura 2.10 é atribuir a cada padrão observado uma classe $\hat{\omega} \in \Omega$ em que

$$\Omega = \{\omega_1, \omega_2, \omega_3, \dots, \omega_n\}, \quad (2.28)$$

trata-se do conjunto das classes admissíveis. Um classificador fica definido se, para cada padrão de entrada, for conhecida a classe que lhe está associada (JHONSON, 1988). Deste modo, é realizada uma partição do conjunto S em c subconjuntos disjuntos R_1, \dots, R_c em que R_c é o conjunto dos padrões de S classificados na classe ω_c . Os conjuntos R_k são definidos como regiões de decisão do classificador (MARQUES, 2005). O projeto do classificador é equivalente à escolha das suas regiões de decisão (BANKS, 1990). Na Figura 2.11 observam-se as regiões de decisão de um classificador baseando-se em duas características x e y . Na zona com presença de círculos, o vetor de características é classificado na classe ω_1 , a zona com triângulos na classe ω_2 e a zona com estrelas na classe ω_3 .

O projeto de um sistema de reconhecimento de padrões envolve pelo menos quatro fases: caracterização do problema, escolha das características, projeto do classificador e avaliação (FUKUNAGA, 1990).




Figura 2.11: exemplo de regiões de decisão de um classificador.

A caracterização do problema é uma fase em que envolve a identificação das fontes de informação (dados de câmeras, sensores, entre outros), dos objetivos que se pretendem atingir, bem como do nível de desempenho pretendido.

A escolha das características é um aspecto fundamental no projeto. Se os parâmetros relevantes para a decisão forem conhecidos ou em número reduzido o bastante para que todos possam ser utilizados na classificação, o problema de escolha de características pode ser evitado incluindo simplesmente toda informação disponível no vetor de característica (MARQUES, 2005). Entretanto, se a quantidade de medidas disponíveis for muito elevada, a escolha de um pequeno conjunto de características que contenha a maior parte da informação relevante para a classificação é um fator decisivo.

A concepção do classificador é feita com base em propriedades estatísticas das características e no critério de desempenho adotado. No projeto do classificador, raramente estão disponíveis as propriedades dos dados produzidos por cada uma das classes. Neste sentido, é necessário deduzir os parâmetros do classificador a partir dos dados. Esta fase é denominada treinamento ou aprendizagem do classificador (MARQUES, 2005). No treino de um classificador é necessário utilizar um conjunto de características,

$$X = \{x(1), x(2), \dots, x(N)\}, \quad x(i) \in S, i = 1, \dots, N, \quad (2.29)$$

que seja representativo dos dados produzidos por todas as classes. O parâmetro X é designado por conjunto de treino, e seus elementos, por padrões de treino.

Para avaliar um classificador é necessário definir um critério de desempenho. Uma grandeza usada para avaliação é a matriz de confusão, $P = (P_{ij})$, a qual é uma matriz quadrada, de dimensão igual ao número de classes, em que P_{ij} é a probabilidade de um padrão ser classificado na classe j , sabendo-se que foi gerado pela classe i (MARQUES,

2005)

$$P_{ij} = P\{\hat{\omega} = \omega_j / \omega = \omega_i\} \quad (2.30)$$

em que ω é a classe que gerou a observação x , e $\hat{\omega}$ é a decisão do classificador. Se x for uma variável aleatória discreta (MARQUES, 2005),

$$P_{ij} = \sum_{x \in R_j} P(x / \omega_i) \quad (2.31)$$

em que P_{ij} é a função de probabilidade das observações geradas pela classe ω_i . A matriz P é uma matriz estocástica, pois (MARQUES, 2005)

$$P_{ij} \geq 0, \quad i, j = 1, \dots, c \quad (2.32)$$

e

$$\sum_{j=1}^c P_{ij} = 1, \quad i = 1, \dots, c \quad (2.33)$$

No caso ideal não há erros de classificação, a matriz de confusão é a matriz identidade. A análise da matriz de confusão permite identificar os tipos de erros mais frequentes.

2.4.2.7 Algoritmo K-médias

O algoritmo K-médias é uma técnica bastante divulgada. A função custo que pretende minimizar é o critério de mínimos quadrados entre cada padrão e o centroide mais próximo (MARQUES, 2005)

$$D = \frac{1}{N} \sum_{x \in X} \sum_{i=1}^c P(x) \|x - \hat{x}_i\|^2, \quad (2.34)$$

em que N é o número de padrões de treino, P_i é a função característica da i -ésima região. Dessa forma, $P(x) = 1$ se x for classificado na i -ésima classe e $P(x) = 0$, caso contrário. A minimização da equação 2.34 é feita recursivamente, em que cada iteração é constituída por duas etapas (MARQUES, 2005). A primeira trata-se da classificação dos padrões de treino,

$$x \in X^k : k = \arg \min_i \|x - x_i\|, \quad (2.35)$$

em que $\arg \min$ designa um valor do argumento que minimiza a expressão, ou seja, um valor de i que minimiza a norma euclidiana. Neste sentido, cada padrão é classificado na classe do centroide mais próximo. A segunda etapa consiste em atualizar o centroide, passando a ocupar o ponto médio dos padrões da sua classe

$$\hat{x}_i = \frac{1}{N_i} \sum_{x \in X^i} x, \quad (2.36)$$

As regiões de decisão do método k-médias são formadas pela união de células de Voronoi associadas aos padrões de treino de cada uma das classes. É mostrado na figura 2.12 um conjunto de padrões de decisão do método considerando as características x e y , gerados por três classes. Nesse exemplo, as superfícies de decisão são segmentos de reta. Os centroides de cada classe é destacado em vermelho.




Figura 2.12: regiões de decisão do classificador K-médias

2.4.2.8 Análise de Densidade Pulmonar (ADP)

É possível classificar as regiões pulmonares segundo a aeração, baseando-se nos valores específicos das densidades em UH dos tecidos pulmonares em imagens de TC (CAVALCANTE, 2010). Esse processo denominado Análise de Densidade Pulmonar consiste em determinar os percentuais de cada região especificada na Tabela 2.1 da Seção 2.1. Para esta dissertação, assume-se a existência de 5 classes c_i , em que $i = 1, 2, 3, 4, 5$ na seguinte ordem: hiper-aerada, normalmente aerada α , normalmente aerada γ , pouco aerada, não aerada.

Portanto, considerando $D(x, y, z)$ uma matriz 3D de densidades pulmonares, tem-se a função $f_i(x, y, z)$ que determina a quantidade de pontos com densidades presentes em cada classe c_i dada por (Rebouças Filho, 2010)

$$f_i(x, y, z) = \sum_{l=-k}^k \sum_{m=-k}^k \sum_{n=-k}^k R(x-l, y-m, z-n) \quad (2.37)$$

em que k

$$k = \frac{\text{ordem} - 1}{2} \quad (2.38)$$

e R dado por

$$R(x, y, z) = \begin{cases} 1, & l_{inf}(c_i) < D(x, y, z) < l_{sup}(c_i) \\ 0, & \text{caso contrário} \end{cases} \quad (2.39)$$

em que l_{inf} e l_{sup} representam os limites inferior e superior da faixa de densidade de cada classe c_i . A partir do valor de $f_i(x, y, z)$ calcula-se o percentual P_i de cada classe i por

(CAVALCANTE, 2010)

$$P_i = \frac{f_i(x, y, z)}{\sum_{i=0}^5 f_i(x, y, z)} \quad (2.40)$$

2.5 Estado da Arte

A segmentação dos vasos sanguíneos pulmonares é objeto de estudo de diversos trabalhos. São propostos métodos de segmentação por pesquisadores de todo o mundo para auxiliar o diagnóstico de patologias que afetam essas estruturas específicas.

O trabalho de Flores e Schmitt (2005) mostra a aplicação do Crescimento de Regiões 3D combinado com morfologia matemática e limiarização para segmentar os vasos sanguíneos pulmonares. Nesse trabalho foram utilizadas imagens coloridas do banco de imagens digitais *Visible Human Project*. É feita uma análise por histograma e limiarização para determinar as sementes do CR e após essa etapa, é aplicado o algoritmo seguindo o critério de similaridade específico. O algoritmo foi capaz somente de segmentar vasos de grosso calibre. Observa-se que não é realizada avaliação quantitativa e não são utilizadas imagens de TC do tórax.

Outra aplicação do Crescimento de Regiões combinado com morfologia matemática foi no trabalho de Felix et al. (2007). Contudo nesse trabalho não ocorre boa distinção entre vias aéreas e vasos sanguíneos.

A proposta de Zhu et al. (2009) foi desenvolver um contorno ativo com algoritmo *level set* (VOLES: *Vascularity-Oriented Level Set algorithm*). Primeiramente, segmenta-se o pulmão por meio de Crescimento de Regiões 3D para, deste modo, utilizar o VOLES na segmentação dos vasos, na qual há uma análise dos autovalores da matriz de Hessian como fator determinante na configuração do contorno ativo. Há no entanto, dependência de injeção de contraste intravenoso para obtenção de uma segmentação adequada por este algoritmo. Não foi também analisada a qualidade da segmentação em regiões em que há vasos justapostos à vias aéreas.

A utilização do classificador *Support Vector Machine* (SVM) junto com filtragem linear 3D foi mostrada no trabalho de Korfiatis, Karahaliou e Costaridou (2009). Neste trabalho é utilizado o cálculo do autovalor da matriz de Hessian para realizar a aplicação do algoritmo Expectation Maximization (EM), em que os vasos sanguíneos são segmentados. O resultado do trabalho foi avaliado por médicos especialista com auxílio de uma ferramenta que permite analisar a sobreposição de volumes. Deste modo foram apresentados alguns resultados numéricos que refletem aceitação da aplicação. A dependência de

injeção de contraste, bem como ausência de avaliação da segmentação de vaso vizinhos as vias aéreas também são fatos verificados neste trabalho. Sato et al. (1998) também utilizou filtragem linear 3D com análise do autovalores da matriz de Hessian para segmentar os vasos sanguíneos. Somente vasos de grosso e médio calibre são segmentados e não há avaliação quantitativa da segmentação.

O algoritmo *Expectation Maximization* foi também utilizado no trabalho de Zhou et al. (2007) para segmentar os vasos. A determinação do autovalor da matriz de Hessian também é um fator preponderante para identificação dos vasos sanguíneos. São segmentados somente vasos de grosso e médio calibre. Neste trabalho é utilizado somente um exame para avaliar o desempenho do algoritmo. Salienta-se que o exame é de paciente sadio.

No trabalho de Kaftan et al. (2008) segmentaram-se os vasos utilizando Conectividade Fuzzy. A aplicação do algoritmo inicia após efetuada a segmentação do pulmão. Uma limiarização é aplicada em conjunto com a Transformada da Distância para classificar alguns *voxels* como sementes, em que suas características irão servir de fator de análise de similaridade. Deste modo, ocorre a classificação dos *voxels* em vaso ou não vaso. Neste trabalho, somente vasos de grosso e médio calibre são segmentados. Os resultados desse trabalho foram satisfatórios, no entanto mostrou-se resultados somente de exames de pacientes que ingeriram contraste intravenoso. Dessa forma, concluiu-se a imposição dessa exigência para aplicação do algoritmo.

Nos trabalhos que foram utilizadas metodologias *fuzzy* ou orientada a regiões foi observada a exigência de uma segmentação inicial dos vasos com intuito de determinar as sementes de inicialização do algoritmo. Já nos métodos que utilizam o autovalor da matriz de hessian como parâmetro determinante de segmentação, não há necessidade de segmentação inicial. Em todos os trabalhos pesquisados, há necessidade de segmentação pulmonar antes de efetuar a segmentação dos vasos sanguíneos.

Capítulo 3

Metodologia

O processo de segmentação dos vasos é constituído por três fases: aquisição das imagens, segmentação do pulmão e, por fim, segmentação dos vasos. Neste sentido, de posse das técnicas descritas no capítulo anterior, é realizado neste momento a descrição do processo de aquisição das imagens de TC, bem como a descrição das metodologias para segmentação. Também é apresentado neste capítulo a forma de avaliação utilizada para verificar a exatidão das segmentações.

3.1 Segmentação do Pulmão

A segmentação pulmonar é realizada por meio da utilização do MCA Crisp. A etapa inicial para a aplicação deste método é a inicialização automática do contorno, ou seja, determinar as coordenadas iniciais. O primeiro passo para a inicialização é a identificação das densidades radiológicas da região interna do pulmão, em que consistem nas áreas hiper-aeradas, com densidades entre -1000 e -950 UH, e nas áreas normalmente aeradas, com densidades entre -950 e -500 UH. A força crisp F_{crisp} descrita na equação 2.4, é calculada através da análise de densidade pulmonar da vizinhança 9×9 do pixel. Deste modo, verifica-se em todas as máscaras definidas na imagem o cálculo de uma função para determinar os percentuais de aeração de cada umas das regiões presentes na imagem. Esse percentual é definido por meio de uma classificação segundo a aeração presente na região. Assume-se que existe um conjunto de 6 classes s_i , em que i varia de 0 a 5, na seguinte ordem: hiper-aerada, normalmente aerada, pouco aeradas, não aerada, osso e áreas não classificadas. A Combinação do operador Sobel com essa determinação da força crisp identifica quais estruturas pertencem a borda pulmonar, permitindo a segmentação exata do pulmão.

A inclusão e exclusão de pontos também são elementos importantes na dinâmica do *snake* crisp. A inclusão permite um maior refinamento do *snake* e, portanto, maior acurácia na segmentação dos contornos de objetos. A exclusão elimina pontos do contorno que estavam em discrepância com os seus vizinhos e elimina pontos vizinhos que possuem as mesmas coordenadas. A adição de pontos se baseia na distância Euclidiana entre dois pontos consecutivos do contorno. Quando esta distância é maior do que uma distância máxima entre pontos, um novo ponto é adicionado entre estes, aumentando a sensibilidade do contorno. Já a remoção de pontos baseia-se em dois critérios: apagar o ponto quando suas coordenadas são iguais às coordenadas de um ponto consecutivo e remoção de pontos que possuem variação brusca de coordenadas em relação aos seus vizinhos.

3.2 Segmentação dos Vasos Sanguíneos

Após efetuada a segmentação do pulmão a próxima etapa é efetuar a extração dos vasos sanguíneos. A descrição das metodologias empregadas serão descritas a seguir.

3.2.1 Limiarização

O passo inicial para aplicação dos métodos *fuzzy* e orientado a regiões é a aplicação da Limiarização para determinar as sementes e, deste modo, utilizá-las como parâmetro referencial de início da segmentação. Neste sentido, considerando uma imagem 3D I em que a intensidade em UH de cada *voxel* com coordenadas espaciais (x, y, z) é representada por $I(x, y, z)$, aplica-se a seguinte equação para segmentação inicial dos vasos sanguíneos.

$$G(x, y, z) = \begin{cases} 0, & I(x, y, z) \geq T \\ 1, & \text{caso contrário} \end{cases} \quad (3.1)$$

A imagem $G(x, y, z)$ é a imagem saída do processo. O limiar T é definido igual a $-300UH$ após realização de exaustivos testes com utilização de diversos limiares. Quando $G(x, y, z) = 1$ classifica-se esse *voxel* como semente.

3.2.2 Crescimento de Regiões 3D

Antes de iniciar o algoritmo Crescimento de Regiões 3D é necessário extrair alguns dados do processo de segmentação inicial. Concluída a Limiarização, é armazenada em um vetor $X = [x_1 \ x_2 \ \dots \ x_n]$ a densidade de todos os *voxels* rotulados como sementes.

Deste modo, calcula-se a média μ_s dos componentes desse vetor dada por,

$$\mu_s = \frac{1}{N} \sum_{k=0}^N x_k, \quad (3.2)$$

em que N representa a quantidade de componentes do vetor X . A classificação do *voxel* $v(x, y, z)$ em *vaso sanguíneo* ou *não* é concluída após a realização de duas etapas: análise de vizinhança e análise de similaridade. Para isso, considera-se a imagem binária G calculada no processo de Limiarização definido na seção 3.2.1.

$$Vizinho(x, y, z) = \begin{cases} \text{verdadeiro,} & \text{se } \sum_{i=-1}^1 \sum_{j=-1}^1 \sum_{k=-1}^1 G(x+i, y+j, z+k) > 0 \\ \text{falso,} & \text{caso contrário} \end{cases} \quad (3.3)$$

Na equação 3.3 é mostrado o processo de análise de vizinhança, em que é verificado se na vizinhança $3 \times 3 \times 3$ do *voxel* a ser classificado existe semente. Se no resultado da análise da vizinhança do *voxel* ocorre a presença de semente, inicia-se o processo de análise de similaridade. O processo de análise de similaridade consiste na utilização da função de pertinência descrita na seção 2.4.2.5. Deste modo, a equação 2.21 passa a ser redefinida por,

$$g(I(x, y, z), \mu_s) = e^{\frac{-1}{2\sigma^2} (I(x, y, z) + \mu_s - \mu_s)}, \quad (3.4)$$

O parâmetro σ corresponde ao desvio padrão e foi definido $\sigma = 200$ após a realização de exaustivos testes. O termo $I(x, y, z)$ corresponde a densidade em UH do *voxel* v_1 a ser classificado. Basicamente, para determinar se o *voxel* pertence a classe vaso sanguíneo calcula-se a similaridade entre o *voxel* e a média da densidade das sementes. Deste modo, a média μ_s do vetor que contém as densidades das sementes é utilizada como parâmetro correspondente ao termo v_2 definido na equação 2.21. O valor $g(I(x, y, z), \mu_s)$ obtido é, portanto, o fator final de análise para determinar se o *voxel* v_1 é um vaso sanguíneo ou não. O processo final da segmentação é dado por

$$I_r(x, y, z) = \begin{cases} 1, & g(I(x, y, z), \mu_s) \geq T_s \\ 0, & \text{caso contrário.} \end{cases} \quad (3.5)$$

O parâmetro I_r é a imagem 3D resultante, em que se $I_r(x, y, z) = 1$ conclui-se que o *voxel* $i(x, y, z)$ pertence a classe vaso sanguíneo. Entretanto se $I_r(x, y, z) = 0$, o *voxel* não foi classificado como vaso. O limiar de similaridade T_s deve ser definido de acordo com a necessidade da aplicação. Neste trabalho, após a realização de testes, foi decidido analisar o desempenho do algoritmo aplicando o limiar $T_s = 0,5$.

3.2.3 K-médias e ADP

Na aplicação do algoritmo K-médias não há necessidade de segmentação inicial por meio de Limiarização. O primeiro passo é a obtenção da base de dados de treinamento do classificador. Os dados de treino são compostos por 5 atributos, sendo estes os percentuais de regiões hiper-aeradas, normalmente aeradas α , normalmente aeradas γ , pouco aeradas e não aeradas. A classificação foi definida atribuindo 1 a objetos rotulados como vaso sanguíneo e 0 a objetos rotulados como não vaso sanguíneo.

A Seleção desta base de dados é realizada manualmente selecionando-se 1134 padrões de estruturas a classificar, compreendendo em regiões do tecido pulmonar, vias aéreas, bordas da vias aéreas e vasos sanguíneos. A máscara definida para calcular o ADP foi $5 \times 5 \times 5$. Esta definição concretiza-se após a realização de vários testes com diferentes máscaras.

Definida a base de dados de treinamento, na próxima etapa aplica-se a equação 2.36 para determinar os vetores centróides $C_i = [c_1 \ c_2 \ c_3 \ c_4 \ c_5]$, em que $i = 1$ para o vetor centroide da classe *vaso sanguíneo* e $i = 0$ para o vetor da classe *não vaso sanguíneo*.

Para classificar o *voxel* $v(x, y, z)$ em vaso sanguíneo ou não, calcula-se, primeiramente, por meio da equação 2.40 o ADP do *voxel* a ser classificado utilizando a mesma máscara definida para determinar o ADP dos padrões de treino. Dessa forma, gera-se um vetor $Y = [y_1 \ y_2 \ y_3 \ y_4 \ y_5]$ de dados a classificar. Neste sentido, aplicando a equação 2.34 classifica-se o *voxel* representado pelo vetor Y na classe do centroide C_i mais próximo. Após a realização classificação, atualiza-se o centroide C_i utilizando a equação 2.36.

3.2.4 Conectividade *Fuzzy*

Analogamente a metodologia de Crescimento de Regiões 3D, a segmentação por Conectividade *Fuzzy* (CF) necessita extrair alguns parâmetros da limiarização antes de sua execução. Em uma matriz

$$S = \begin{bmatrix} s_1(x_1, y_1, z_1) & x_1 & y_1 & z_1 \\ s_2(x_2, y_2, z_2) & x_2 & y_2 & z_2 \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ s_{n-1}(x_{n-1}, y_{n-1}, z_{n-1}) & x_{n-1} & y_{n-1} & z_{n-1} \\ s_n(x_n, y_n, z_n) & x_n & y_n & z_n \end{bmatrix} \quad (3.6)$$

armazenam-se as densidades dos *voxels* definidos sementes $S_n(x_n, y_n, z_n)$ e suas coordenadas espaciais x_n, y_n, z_n . Assim, calcula-se a média μ_s das densidades.

$$\mu_s = \frac{1}{N} \sum_{i=0}^N s_i(x_i, y_i, z_i) \quad (3.7)$$

Com intuito de diminuir o custo computacional, a matriz S não contém a posição e a densidade de todos *voxels* sementes. Foi estabelecida após realização de testes uma quantidade de 1000 sementes aleatórias com distribuição uniforme para segmentar os vasos sanguíneos por Conectividade *Fuzzy*. Finalizada a definição da matriz S e do parâmetros μ_s inicia-se a aplicação do algoritmo Conectividade *Fuzzy*. O primeiro passo da aplicação deste método é a definição dos caminhos, em que calcula-se a distância euclidiana entre o *voxel* $v(x, y, z)$ e as sementes $s_n(x_n, y_n, z_n)$ definidas na matriz S dada por

$$Caminho = \begin{cases} verdadeiro, & \sqrt{(x - x_n)^2 + (y - y_n)^2 + (z - z_n)^2} \leq T_s \\ falso, & \text{caso contrário} \end{cases} \quad (3.8)$$

O valor de T foi definido igual a 50, após a realização de testes experimentais. Deste modo haverá um caminho para cada par P_{v,s_n} determinado pela equação 3.8. Definidos os caminhos possíveis de $v(x, y, z)$, o próximo passo é calcular a conectividade $\mu_k(C_{v,s_n})$ de cada caminho C_{v,s_n} e a conectividade global $\mu_k(C_j)$ do conjunto de todos os caminhos C_j .

Para definir C_{v,s_n} determina-se os *voxels* que pertencem a reta 3D que conecta $v(x, y, z)$ e $s_n(x_n, y_n, z_n)$. Um vetor diretor $V = [v_x, v_y, v_z]$ é primeiramente definido.

$$V = [x_n - x, y_n - y, z_n - z] \quad (3.9)$$

Deste modo, para determinar os pontos (x_r, y_r, z_r) da reta utiliza-se as equações

$$y_r = \frac{x_r - x}{v_x} \cdot v_y + y \quad (3.10)$$

$$z_r = \frac{y_r - y}{v_y} \cdot v_z + z. \quad (3.11)$$

O valor de x_r é o parâmetro de referência para a construção da reta e varia de x a x_n . Portanto, C_{v,s_n} é representado por

$$C_{i,s_n} = [i_1(x_{r_1}, y_{r_1}, z_{r_1}), i_2(x_{r_2}, y_{r_2}, z_{r_2}), \dots, i_n(x_{r_n}, y_{r_n}, z_{r_n})] \quad (3.12)$$

Após a definição dos *voxels* pertencentes a C_{v,s_n} calcula-se a afinidade local utilizando a função de pertinência descrita na seção 2.4.2.5. Os parâmetros de entrada da equação 2.21 são definidos a seguir:

- $\mu = \mu_s$,
- $v_1 = v_n(x_{r_n}, y_{r_n}, z_{r_n})$,
- $v_2 = v_{n+1}(x_{r_{n+1}}, y_{r_{n+1}}, z_{r_{n+1}})$,
- $\sigma = 120$.

É calculado, portanto, a afinidade local $\mu_k(x, y)$. O desvio-padrão σ foi definido após realização de testes de desempenho e a média μ da função gaussiana é o valor de μ_s calculado na equação 3.7. Após calculada todas as afinidades locais, utiliza-se a equação 2.19 para definir a afinidade do caminho. O processo é repetido para todos os caminhos e a maior afinidade de caminho representa afinidade global $\mu_k(C_j)$. Assim,

$$I_r(x, y, z) = \begin{cases} 1, & \mu_k(C_j) \geq T\mu_k \\ 0, & \text{caso contrário} \end{cases} \quad (3.13)$$

O parâmetro I_r é a imagem resultante. A determinação do limiar T_{μ_k} é definida após a realização de testes. Portanto, para analisar o desempenho do algoritmo utilizou-se o limiar de afinidade global $T_{\mu_k} = 0,7$.

3.3 Avaliação dos Métodos

A validação de um algoritmo computacional é uma etapa importantes e, no caso de imagens médicas, a importância dessa avaliação é ressaltada por se tratar de uma imagem que caracteriza o estado de saúde. Para analisar os resultados de segmentação de imagens médicas, alguns autores consideram uma segmentação padrão-ouro realizada manualmente por médicos especialistas (CAVALCANTE, 2010),(ZHOU et al., 2007).Esse padrão-ouro serve de referência para verificar a exatidão da segmentação pelo algoritmo específico.

Os trabalhos que tratam da segmentação dos vasos sanguíneos pulmonares seguem padrões singulares de avaliação. No trabalho de Korfiatis, Karahaliou e Costaridou (2009) o processo de avaliação consiste em utilizar uma interface gráfica para analisar o volume total de vasos segmentados e sobrepor no volume padrão ouro definido por médicos radiologistas. Deste modo, obtém-se um valor numérico que corresponde a exatidão da segmentação. Foi utilizado somente um exame para avaliar o resultado da segmentação. Salienta-se que não há padrão-ouro para a visualização da reconstrução tridimensional da árvore de vasos sanguíneos no trabalho de Korfiatis, Karahaliou e Costaridou (2009).

Alem da análise qualitativa, o processo de avaliação adotado por Kaftan et al. (2008) utiliza 58 imagens de todas as regiões pulmonares de 10 exames. É definida uma taxa de

acerto baseada na análise estatística de segmentação desenvolvida por Zou et al. (2004). Não há definição de padrão-ouro por médicos especialistas.

O padrão-ouro da visualização tridimensional foi definido no trabalho de Zhou et al. (2007), no qual radiologistas segmentaram manualmente os vasos sanguíneos em imagens de TC. Foi possível efetuar a visualização tridimensional da segmentação manual. Deste modo, foi realizada uma avaliação quantitativa comparando o volume de vasos segmentados pelo método proposto com o volume de vasos segmentados manualmente.

No trabalho de Shang et al. (2011), a definição do padrão ouro da segmentação dos vasos é realizada aplicando o método proposto para segmentar os vasos para, posteriormente, o médico especialista efetuar a correção manual da segmentação, incluindo vasos não segmentados e retirando as falsas detecções. A validação foi realizada utilizando seis exames. Portanto, utilizando a análise de sobreposição de volume, foi determinado um valor correspondente à exatidão da segmentação. Ressalta-se que o padrão-ouro foi determinado para cada exame.

A avaliação da segmentação no trabalho de Zhu et al. (2009) foi realizada por meio de verificação de exatidão da segmentação em 100 pontos correspondentes aos vasos e 100 pontos em regiões próximas aos vasos. Deste modo, calculou-se a sensibilidade e a especificidade do algoritmo.

Todas as imagens presentes nestes trabalhos citados possuem duas características em comum: são de exames de pacientes sadios com injeção de contraste intravenoso. Neste sentido, devido às características das imagens avaliadas nos métodos citados diferirem das dispostas nesta dissertação, o método de avaliação nesta dissertação utiliza alguns padrões de avaliação dos métodos citados, mas segue um procedimento geral de análise próprio.

Uma das medidas que pode ser utilizada como critério de avaliação da segmentação de vasos sanguíneos pulmonares é o volume. Aproximadamente, o volume de sangue presente na circulação pulmonar em um indivíduo adulto normal é de 450 ml E.Hall e Guyton (2011). Essa medida é uma referência de exatidão das segmentações presentes nesta dissertação, entretanto considerando as particularidades das aquisições, bem como as características fisiológicas e patológicas de alguns exames adquiridos, não é possível fazer desta estimativa de volume um fator que quantifique o acerto da segmentação de cada método. O volume de vasos segmentados serviu como mais um parâmetro para comparar o desempenho dos algoritmos entre si.

Nesta dissertação, a definição do padrão ouro foi realizada por dois médicos especialista. Foram escolhidas 6 imagens por exame para segmentar manualmente todos os vasos sanguíneos pulmonares presentes. As regiões pulmonares escolhidas foram:

- ápice, logo a cima da artéria aorta,
- hilo, precisamente na região da carina da traqueia,
- base, na região das veias pulmonares,

São ilustradas na Figura 3.1 exemplos das definições do padrão ouro de cada região pulmonar escolhida.

Com base na definição do padrão ouro por médicos especialistas, a avaliação quantitativa foi definida calculando o coeficiente de similaridade CS baseada na análise estatística de segmentação desenvolvida por (ZOU et al., 2004) e determinando a sensibilidade S dos algoritmos, de acordo Zhu et al. (2009)

$$CS = \frac{2.VP}{2.VP + FP + FN} \quad (3.14)$$

$$S = \frac{VP}{VP + FN}. \quad (3.15)$$

Os parâmetros VP , FP e FN correspondem respectivamente aos resultados das segmentações considerados segmentados corretamente (verdadeiros positivos), falsas segmentações (falsos positivos) e vasos não detectados (falsos negativos). Ao verificar os valores de similaridade e sensibilidade obtidos nos trabalhos pesquisados e observar as segmentação obtidas, deduz-se que a avaliação da segmentação limitou-se a considerar a detecção de vasos de médio e grande calibre somente. Nesta dissertação há inclusão de vasos de pequeno calibre na definição do padrão ouro.

Portanto, a definição do padrão ouro nesta dissertação difere das definições observadas na literatura pelo motivo de incluir vasos de pequeno calibre. Em nenhum dos trabalhos pesquisados há segmentação em imagens com largura de corte menor que $1mm$. Como pode ser observado na Figura 3.2, somente vasos de área considerável são segmentados. Com o conhecimento desse padrão de segmentação observado nesses trabalhos citados, bem como de outros brevemente descritos na seção 2.5, foram realizadas duas abordagens para avaliação do coeficiente de similaridade e sensibilidade dos algoritmos. Na primeira abordagem, todos os vasos segmentados manualmente no padrão ouro servem de parâmetro para a determinação dos coeficientes. Já na segunda abordagem, desconsideram-se os vasos de pequeno calibre segmentados no padrão ouro para realização dos cálculos dos

coeficientes. Deste modo, obtém-se dois modelos de padrão ouro para cada imagem, tal como pode ser observado na Figura 3.3.

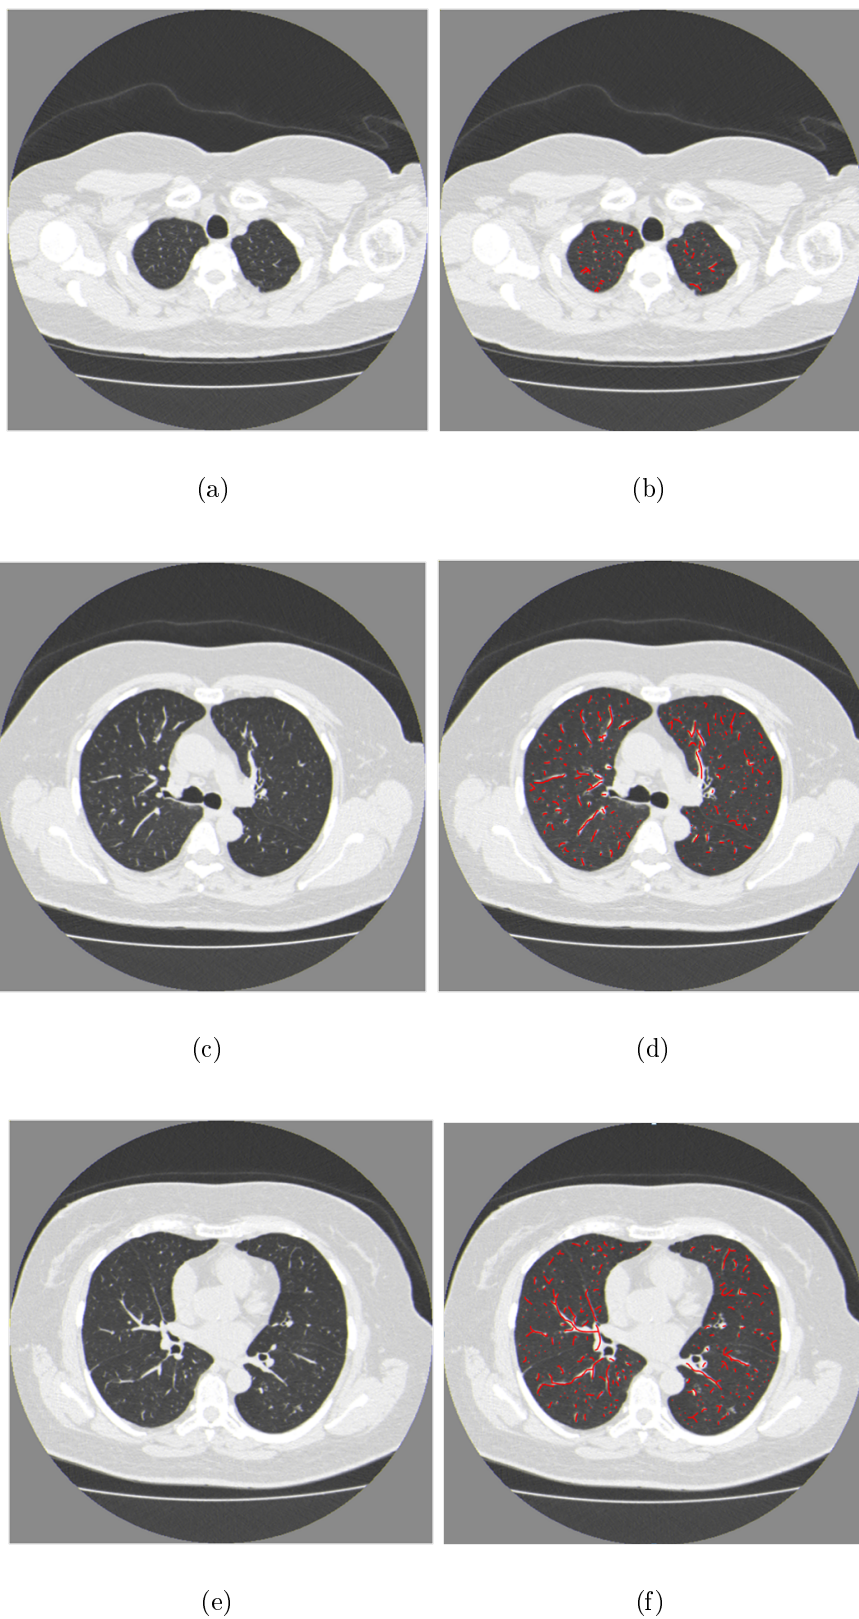


Figura 3.1: definição do padrão-ouro da segmentação de vasos; (a), (c) e (e) imagens originais do ápice, hilo e base respectivamente; (b), (d) e (f) respectivos padrões-ouro das regiões do ápice, hilo e base.





Figura 3.2: exemplo de segmentações de vasos sanguíneos pulmonares em outros trabalhos; (a) segmentação de vasos desenvolvida por Kaftan et al. (2008); (b) segmentação de vasos no trabalho desenvolvido por Zhu et al. (2009); (c) segmentação de vasos no trabalho desenvolvido por Korfiatis, Karahaliou e Costaridou (2009).



(a)



(b)

Figura 3.3: modelos de padrão ouro da segmentação dos vasos; (a) visualização de uma segmentação manual padrão com vasos de pequeno calibre incluídos; (b) padrão ouro com exclusão de vasos de pequeno calibre;

Capítulo 4

Resultados

Neste Capítulo é apresentada a descrição do processo de aquisição das imagens de TC, bem como os resultados obtidos das segmentações dos algoritmos. É realizada uma avaliação individual de cada algoritmo e posteriormente uma análise comparativa dos três métodos. Os cálculos dos coeficientes de similaridade e sensibilidade consideram duas abordagens. Na primeira contabiliza-se também a segmentação de vasos de pequeno calibre, já na segunda considera-se somente a contabilização de vasos de médio e grosso calibre segmentados.

4.1 Aquisição de Imagens

O processo de aquisição das imagens utiliza tomógrafo do tipo multidetectores e de alta resolução. As imagens utilizadas para avaliar os algoritmos foram adquiridas em datas diferentes e em tomógrafos distintos. Os modelos utilizados para adquirir essas imagens foram: *Toshiba Aquilion* (TA), *Toshiba Asteion* (TAs), *GE Medical System LightSpeed16* (GEMSL), *GE Medical System BrightSpeed* (GEMSB), *Philips Brilliance 10* (PB) e *Philips Gemini* (PG). As imagens de TC são convertidas para padrão DICOM (*Digital Image Communication in Medicine*), criado pela *National Electrical Manufacturers Association* (NEMA)(SILVA, 2005). Nesse formato, o cabeçalho de cada imagem fornece informações específicas, por exemplo, dados do paciente nome, sexo, número de identificação, modalidade e informações sobre a forma de obtenção da imagem, calibração, parâmetros do dispositivo, dosagem de radiação, contraste do meio; e informações da imagem, resolução e janelamento (ZAFFARI, 2006).

Todas as imagens são 512×512 e com 16 bits. Quando a largura de corte é inferior a $2mm$ caracteriza-se por uma aquisição por TC de alta resolução (TCAR). Nas tabelas 4.1




Figura 4.1: imagem de TC; (a) multidetectores adquirida pelo tomógrafo modelo *Philips Gemini*; (b)TCAR adquirida pelo tomógrafo modelo *Toshiba Asteion*.

e 4.2 estão dispostas as características das imagens adquiridas. São mostradas na Figura 4.1 dois exemplos de imagens adquiridas po TC.

Todas as imagens foram adquiridas de exames em que não há presença de injeção de contraste. Na aquisição das imagens, os cortes são realizados na posição supina, considerando três regiões: ao nível de ápice, hilo e base. Obtenção destas imagens foi possível devido a parceria entre o Departamento de Teleinformática (DETI) Universidade Federal do Ceará (UFC) e o Hospital Walter Cantídio da UFC.

Tabela 4.1: descrição das imagens utilizadas para avaliação dos algoritmos.

Dados das imagens	Exame 1	Exame 2	Exame 3	Exame 4
Data de aquisição	15/06/2009	04/04/2012	26/04/2008	26/05/2010
Número de fatias	910	281	269	762
Largura do corte	0,5	1,25	1,25	0,5
Modelo do tomógrafo	TA	GEMSB	GEMSL	TA
Diagnóstico	Normal	Normal	Normal	Normal

Tabela 4.2: descrição das imagens utilizadas para avaliação dos algoritmos.

Dados das imagens	Exame 5	Exame 6	Exame 7	Exame 8
Data de aquisição	26/04/2008	21/03/2011	26/07/2011	04/06/2012
Número de fatias	241	231	298	599
Largura do corte	1,25	3	2	1
Modelo do tomógrafo	GEMSL	TAs	PB	PG
Diagnóstico	D. Intersticial	Normal	Normal	Efisema

Todas as imagens foram adquiridas de exames em que não há presença de injeção de

contraste. Na aquisição das imagens os cortes são realizados na posição supina considerando três regiões: ao nível de ápice, hilo e base. Obtenção destas imagens foi possível devido a parceria existente entre o Departamento de Teleinformática (DETI) Universidade Federal do Ceará (UFC) com Hospital Walter Cantídio da UFC.

4.2 Limiarização

A primeira etapa de segmentação é a aplicação da limiarização. Esta consiste em determinar as sementes para inicialização dos algoritmos Crescimento de Regiões 3D e Conectividade *Fuzzy*. A aplicação de uma limiarização, em que o Limiar $L = -300UH$ garante a priori que os objetos segmentados são vasos, todavia não permite a segmentação de todos. Após realização de exaustivos testes verifica-se que ao aumentar o valor de L outras estruturas além dos vasos podem ser rotuladas como sementes. Nessa etapa, é segmentada uma parte dos vasos, mas com descontinuidades que são corrigidas por meio da aplicação de Crescimento de Regiões 3D e Conectividade Fuzzy. Os vasos que não são identificados por meio da limiarização também são segmentados através dos métodos em questão. Na Figura 4.2 visualiza-se dois exemplos de reconstrução 3D dos vasos sanguíneos considerando apenas a limiarização como fator de segmentação.




Figura 4.2: aplicação de somente limiarização no processo de segmentação do vasos pulmonares; (a) exame 1; (b) exame 2

4.3 Crescimento de Regiões 3D (CR3D)

Utilizando o CR3D, a classificação do *voxel* como pertencente a classe vasos sanguíneo é menos exigente, em relação aos critérios de análise dos outros algoritmos desenvolvidos nesta dissertação. Conseqüentemente, verifica-se que a aplicação deste método proporciona o maior volume de vasos segmentados. Na Tabela 4.3 observa-se o volume de vasos segmentados por CR3D em todos os exames.

Tabela 4.3: volume de segmentação do algoritmo CR3D

Exames	Volume(ml)
1	267,9
2	211,7
3	126,8
4	224,6
5	305,2
6	294,7
7	351,5
8	265,5

O volume calculado corresponde a todos os voxels classificados como vasos sanguíneos pelo algoritmo. Em exames de pacientes saudáveis, o valor de referência 450 ml não foi atingido. As justificativas, além das particularidades citadas, são o fato de o algoritmo CR3D não ser capaz de segmentar alguns vasos de pequeno e médio calibre sem o custo de um significativo vazamento e a segmentação pulmonar não permitir a inclusão de alguns dos vasos de grande calibre na região do hilo e na base próximo à região das veias pulmonares. A Figura 4.3 ilustra essas situações.

Na Figura 4.4 são observados exemplos de segmentações, em que cada uma corresponde a uma visualização em duas dimensões da aplicação do método em exames distintos.

De acordo com as marcações observadas no padrão-ouro, verificou-se que as segmentações em imagens de exames de pacientes saudáveis obtêm um melhor desempenho qualitativo. Na Figura 4.4(b) é mostrada segmentação em exame de paciente que não possui nenhuma doença pulmonar. A segmentação dos vasos é bem definida neste tipo de exame. Assim, as limitações do método para este tipo de exame são os vasos de pequeno calibre e algumas bordas de vias aéreas justapostas aos vasos sanguíneos. Na Figura 4.5 é possível observar alguns erros de segmentação devido a estas limitações.

A densidade de algumas bordas das vias aéreas são relativamente similares a dos vasos sanguíneos, por esse motivo a análise da vizinhança das sementes não é suficientemente efetiva para evitar que alguns erros dessa característica ocorra. Salienta-se que existem

regiões de bordas de vias aéreas vizinhas aos vasos sanguíneos que são classificadas corretamente, tal como pode ser observado na Figura 4.6.

Para imagens de exames de pacientes que apresentam patologias, as quais apresentam inclusão de estruturas com alta densidade, não foi possível distingui-las dos vasos sanguíneos. Na Figura 4.4(e) é mostrado um exame de paciente com enfisema pulmonar e doença intersticial. Neste caso, é possível observar circulado em vermelho na Figura 4.4(f) uma das falhas da segmentação ao incluir estruturas classificadas equivocadamente como vasos sanguíneos. Na Figura 4.4(d) verifica-se a segmentação em paciente com doença intersticial. Neste corte do exame há menos presença de tecido fibroso o qual apresenta alta densidade, portanto é possível ainda uma boa distinção dos vasos.

Considerando a primeira abordagem de avaliação, no conjunto dos 8 exames os médicos especialistas selecionaram 7249 vasos sanguíneos. Após efetuada a devida comparação com o padrão ouro, foi constatado um total de 3124 detecções corretas, 4125 detecções caracterizadas como falso negativo e 155 classificadas como falso positivo. Em média, constataram-se 390 detecções corretas por exame, 515 detecções incluídas como falso negativo e 19 consideradas como falso positivo. Logo, de acordo com as equações 3.14 e 3.15 é possível obter um coeficiente de similaridade geral de 0,59 e sensibilidade geral de 0,43. Na Figura 4.7 é possível observar as discrepâncias entre o coeficiente de similaridade e sensibilidade por exame e na Tabela 4.4 visualizam-se seus valores exatos.

Tabela 4.4: resultado da primeira abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CR3D

Exames	Similaridade	Sensibilidade
1	0,48	0,32
2	0,58	0,26
3	0,56	0,40
4	0,60	0,43
5	0,84	0,78
6	0,55	0,39
7	0,59	0,43
8	0,94	0,97

O algoritmo não foi capaz de segmentar os vasos de pequeno calibre. Como o padrão ouro inclui absolutamente todos os vasos visíveis, as taxas de similaridade e sensibilidade estão abaixo do padrão encontrado na literatura. Os valores de similaridade possuem valores mais altos do que os de sensibilidade pelo fato de o primeiro atribuir maior significância as detecções corretas, enquanto o segundo atribui pesos iguais aos índices de falsos negativos e detecções corretas. Salienta-se que o coeficiente de sensibilidade desconsidera

as falsas detecções.

Os exames 5 e 8 são de pacientes que apresentam doenças. No entanto, apresentaram um alto valor dos coeficientes de similaridade e sensibilidade. O exame 8 contém imagens com presença de enfisema pulmonar e doença intersticial. Quando se caracteriza um enfisema pulmonar, ocorre uma diminuição da quantidade de vasos sanguíneos pulmonares. Para exemplificar essa situação, o número de vasos marcados no padrão ouro para o exame 2 (paciente sadio) é 1525, enquanto para o exame 8 foi 242 excluindo-se da contagem os vasos de pequeno calibre. Por esse motivo, o algoritmo foi capaz de segmentar a maior parte dos vasos marcados no padrão ouro do exame 8, ocasionando apenas 7 falsos-negativo. Essas imagens do exame 8 também possuem características de doença intersticial que ocasionam presença de tecido fibroso dificultando a visualização dos vasos, além de aumentar o índice de falsas detecções.

O exame 5 trata-se de imagens com presença de doença intersticial. O índices de similaridade e sensibilidade são maiores que a média devido ao fato de também haver menos marcações de vasos de pequeno calibre. Observa-se que o tecido fibroso dificulta a visualização dos vasos sanguíneos. Desta forma, no padrão ouro são marcadas 811 estruturas classificadas como vasos sanguíneos, proporcionando o algoritmo identificar 626 estruturas corretamente e 47 falsas detecções. Esta quantidade falsos-positivos é bastante elevada, considerando a média por exame 19 e o fato de este estudo considerar seis imagens por exame

Considerando a segunda abordagem de avaliação, reduziu-se as marcações do padrão ouro para 3765 estruturas classificadas como vasos sanguíneos. Desta forma, mantendo-se os valores de detecções corretas e falsas detecções atingiu-se um coeficiente de similaridade geral de 0,88 e sensibilidade geral de 0,83. Na Figura 4.8 é possível observar as discrepâncias entre o coeficiente de similaridade e sensibilidade por exame e na Tabela 4.5 visualiza-se seus valores.

Tabela 4.5: resultado da segunda abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CR3D

Exames	Similaridade	Sensibilidade
1	0,92	0,88
2	0,82	0,72
3	0,89	0,84
4	0,90	0,85
5	0,91	0,90
6	0,84	0,76
7	0,84	0,75
8	0,94	0,97

Utilizando a segunda abordagem de avaliação, o índice de falso negativo diminui significativamente. O índice geral muda de 4218 para 634 não detecções e a média de 527 para 79 falsos negativos por exame. Consequentemente, essa alteração resulta a elevação dos coeficientes de similaridade e sensibilidade. Nas imagens do padrão ouro, as falsas detecções consistem em segmentação de vias aéreas e, no caso de exames que apresentam doença intersticial, tecido fibroso também.

Reduzindo os falsos negativos, o índice de similaridade ainda continua superior ao de sensibilidade, equiparando-se aos coeficientes observados na literatura. Assim, o peso dado as detecções verdadeiras mostra-se um fator determinante na discrepâncias entre essas taxas. A visualização tridimensional da segmentação de todas as imagens de um exame segmentado por CR3D de paciente normal pode ser verificada na Figura 4.9.

4.4 Conectividade Fuzzy

Apesar de semelhante ao método CR3D em relação a análise de similaridade entre voxels, a análise dos caminhos torna a segmentação por conectividade Fuzzy mais criteriosa. Desta forma, o algoritmo proporcionou êxitos como diminuição dos falsos-positivos, mas diminuiu o volume de vasos segmentados. Com base nas marcações do padrão-ouro, foram realizados testes exaustivos para definir o mais apropriado limiar de afinidade global T_{μ_k} . Na tabela 4.6, verifica-se o volume de vasos segmentados por CF.

Tabela 4.6: volume de segmentação por CF.

Exames	Volume(ml)
1	221
2	199
3	97
4	199
5	171
6	182
7	211
8	187

O volume calculado corresponde a todos os voxels classificados como vasos sanguíneos pelo algoritmo. Assim como na aplicação do CR3D, o valor de referencia 450 ml não foi atingido devido as limitações da segmentação pulmonar e o fato de o algoritmo também não ser capaz de segmentar vasos de pequeno calibre.

Alguns exemplos de segmentações em diferentes exames podem se observados Na Figura 4.10.

As mesmas dificuldades foram igualmente verificadas na segmentação de exames de pacientes com doença intersticial e enfisema tal como podem ser visto na Figura 4.10(f). A Figura 4.10(a) trata-se de uma imagem sem presença de patologias e a Figura 4.10(c) apresenta doença intersticial. Na última, é possível observar, circulos em vermelho, alguns falsos positivos obtidos pela segmentação por CF. Estas estruturas confundidas com vasos pelo algoritmo são tecido fibroso oriundo de doença intersticial.

Em exames de pacientes sadios o grau de exatidão das segmentação foi considerado maior. Algumas bordas das vias aéreas justapostas aos vasos continuam ocasionando obstáculo à segmentação, entretanto verifica-se menor ocorrência de falhas quando comparada com a segmentação por CR3D. Na Figura 4.11 é possível observar o desempenho do algoritmo em segmentação de vasos com vias aéreas justapostas.

A análise de similaridade entre *voxels* baseia-se na observação da conectividade do caminho. Esta característica causa uma maior eficiência na segmentação por distinguir melhor as bordas das vias aéreas dos vasos sanguíneos. Contudo, algumas bordas de vias aéreas ainda não são diferenciadas.

Considerando a primeira abordagem de avaliação dos coeficientes de similaridade e sensibilidade, observa-se que no conjunto de 7249 vasos sanguíneos selecionados são verificadas 2362 segmentações consideradas corretas, 100 segmentações julgadas falsos-positivos e 4614 ocorrências de falsos-negativos. Deste modo, em média foram 329 detecções corretas por exame, 12 segmentações consideradas falsos-positivo e 576 vasos não detectados. De acordo com as equações 3.14 e 3.15 são calculados os coeficiente de similaridade e sensibilidade gerais, cujo valores são respectivamente 0,52 e 0,36. Os valores dos coeficientes de similaridade e sensibilidade de cada exame estão dispostos na Tabela 4.7 e, na Figura 4.12, é possível observar as diferenças entre os coeficientes calculados em cada segmentação.

Tabela 4.7: resultado da primeira abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CF

Exames	Similaridade	Sensibilidade
1	0,38	0,24
2	0,37	0,22
3	0,58	0,42
4	0,52	0,36
5	0,72	0,62
6	0,47	0,31
7	0,50	0,33
8	0,94	0,96

Os índices de falsos-negativos também são fatores determinantes que resultam em

coeficientes de similaridade e sensibilidade de baixo valor. A justificativa para os exames 5 e 8 produzirem coeficientes mais elevados é a mesma definida na descrição dos resultados da segmentação por CR3D. Salienta-se que no conjunto de 242 vasos selecionados no exame 8, foram detectados 16 falsos-positivos e 231 detecções corretas e no conjunto de 801 vasos selecionados no exame 5, foram detectados 27 falsos-positivos e 503 detecções corretas.

Tomando como referência de avaliação a segunda abordagem, no conjunto de 3765 estruturas classificadas como vasos sanguíneos pelos médicos especialistas foram detectados 1149 falsos-negativos com média de 142 não detecções por exame. Deste modo, os valores gerais dos índices de similaridade e sensibilidade foram respectivamente 0,80 e 0,69. Na Figura 4.13 é possível observar as diferenças entre os coeficiente e na Tabela 4.8, seus valores.

Tabela 4.8: resultado da segunda abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por CF

Exames	Similaridade	Sensibilidade
1	0,77	0,65
2	0,75	0,61
3	0,92	0,88
4	0,82	0,70
5	0,82	0,72
6	0,75	0,61
7	0,73	0,59
8	0,94	0,96

De modo geral, as segmentações em imagens que não apresentam doenças apresentaram resultados similares. O coeficiente de similaridade, neste caso, também caracterizou-se por ser superior ao coeficiente de sensibilidade. Como o valor do índice de falso-negativo diminui, os coeficientes de similaridade e sensibilidade aumentam também na mesma proporção. Todavia, a quantidade ainda elevada de falsos-negativos resultam em coeficientes inferiores aos observado na segmentação por CR3D.

O método CF utilizado nesta dissertação é semelhante ao utilizado por Kaftan et al. (2008). Contudo, salienta-se que no citado trabalho, além da utilização de contraste, observa-se que a segmentação foi realizada em uma janela que permite visualização somente de vasos de médio e grande calibre. A comparação entre os coeficientes de similaridade determinados nesta dissertação e do trabalho citado não é viável pelo fato de tratarem de exames diferente e em condições distintas.

Verifica-se na Figura 4.14 a visualização tridimensional do resultado da segmentação

de todas as imagens por CF de um exame sem presença de doença.

4.5 K-Média

Como a segmentação utilizando o K-Médias necessita de um banco de dados de treinamento é possível realizar uma avaliação preliminar do algoritmo utilizando somente estes dados. Deste modo, em vez de obter coeficiente de similaridade e sensibilidade por análise de detecção da estrutura, é possível obter uma taxa de acerto por *voxel*.

No conjunto de 1134 voxels escolhidos na base de dados, 700 pontos são escolhidos aleatoriamente para servirem como conjunto de treinamento do classificador e o restante, 434 pontos, selecionados para teste. Por conseguinte, são realizadas 100 repetições de classificação desta base de dados.

Na Figura 4.15 é possível observar o histograma e o box plot das taxas de acerto obtidas na aplicação do K-Médias na classificação da base de dados. O valor médio das taxas foi 90,34% com um desvio-padrão de 1,12%. A menor taxa de acerto é de 87,55% e a máxima taxa é de 93,31%. Das 100 repetições de classificação, a maior incidência de taxa de acerto é de 90,5%, correspondendo a 24 casos.

Ao se observar o histograma e o box plot verifica-se que a maior parte das taxas se concentra entre 89,5% e 91%. A taxa máxima de 93,31% é considerada um *outlier*. Deste modo, com o conhecimento do comportamento do algoritmo na classificação do banco de dados de treinamento, inicia-se o processo de avaliação da segmentação nas referidas imagens de TC.

A classificação do *voxel* em vaso sanguíneo utilizando o algoritmo K-média foi a mais rigorosa entre os três métodos analisados nesta dissertação. Observa-se que vasos de pequeno calibre são também ignorados por esse algoritmo, no entanto a qualidade da segmentação de vasos justapostos às bordas de vias aéreas é eleita a mais adequada. O volume de segmentação por exame pode ser observado na Tabela 4.9.

O volume calculado corresponde a todos os voxels classificados como vasos sanguíneos pelo algoritmo. Os atributos de entrada para classificação do *voxel* em vaso sanguíneo depende do ADP. Neste caso, como o ADP considera uma máscara volumétrica $5 \times 5 \times 5$, regiões com vasos de pequeno calibre ficam com o percentual de pouca aeração abaixo do verificado em regiões que contém vasos. O percentual de pouca aeração geralmente é um fator importante que caracteriza a presença de vasos sanguíneos. Alguns exemplos de segmentações em diferentes exames podem se observados Na Figura 4.16.

Tabela 4.9: volume de segmentação por K-médias.

Exames	Volume(ml)
1	165,6
2	156,5
3	93,9
4	186,8
5	133,1
6	194,4
7	137
8	168

Em imagens com ausência de doença, o desempenho do algoritmo também foi mais acurado. Estima-se que, devido a ausência da injeção de contraste, algumas bordas de vias aéreas vizinhas aos vasos não podem ser distinguidas, mas em geral o desempenho deste algoritmo na segmentação de vasos nessas regiões foi considerado satisfatório. Na Figura 4.17 é possível observar o desempenho do algoritmo nos casos em que há vias aéreas adjacente aos vasos. Em imagens com presença de doença intersticial o algoritmo K-Média também não distingue tecido fibroso de vasos sanguíneos em alguns casos. Na Figura 4.16(f) verifica-se circulada a detecção de falso-positivo na segmentação em imagens com presença de enfisema e doença intersticial.

Para determinar o banco de dados de treinamento, as medidas de ADP das regiões das bordas das vias aéreas são significativamente selecionadas para garantir que os vasos vizinhos às bordas das vias aéreas possam ser segmentados apropriadamente. Deste modo, pode-se observar, dentre os métodos testados, a melhor distinção entre as bordas das vias aérea e os vasos sanguíneos.

Considerando a primeira abordagem de avaliação, no conjunto total de 7249 vasos selecionados, são verificadas 2729 detecções corretas, 84 falsas detecções e 4520 vasos não segmentados. Desta forma, por meio das equações 3.14 e 3.15, são obtidos valores gerais dos coeficientes de similaridade e sensibilidade iguais a 0,54 e 0,37 respectivamente. Em média, são 341 detecções corretas, 10 falsas detecções e 565 falsos-negativos por exame. Os valores dos coeficientes de similaridade e sensibilidade por exame podem ser observados na Tabela 4.10. Na Figura 4.18 é possível observar as disparidades entre estes.

O alto índice de falso-negativo proporciona também na aplicação deste algoritmo baixas taxas de similaridade e sensibilidade. As imagens com presença de patologias também proporcionam maiores taxas por fatores já mencionados. No conjunto de 242 vasos selecionados no exame 8 há ocorrência de 18 falsos-positivos e 10 não detecções. No conjunto de 801 vasos selecionados no exame 5 são detectados 21 falsos-positivos e 270 não detecções.

Tabela 4.10: resultado da primeira abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por K-Médias

Exames	Similaridade	Sensibilidade
1	0,36	0,22
2	0,39	0,24
3	0,59	0,43
4	0,47	0,31
5	0,78	0,66
6	0,61	0,44
7	0,52	0,36
8	0,94	0,95

Tomando a segunda abordagem de avaliação como referência, observa-se que no conjunto de 3765 vasos selecionados, a quantidade total de falsos-positivos cai para 1036. Deste modo, os coeficientes de similaridade e sensibilidade geral assumem valores 0,82 e 0,72 respectivamente. A média de não detecções torna-se 129 falsos negativos por exame. Na Figura 4.19 mostram-se as disparidades entre os coeficientes e na Tabela 4.11 verificam-se seus valores exatos.




Figura 4.19: sensibilidade e similaridade da segmentação por K-Médias pela segunda abordagem de avaliação

Os valores de similaridade na aplicação do K-Médias também possuem, de forma geral, valores superiores aos da sensibilidade. Os índices de falsos-positivos encontrados neste método são os menores observados na aplicação dos três métodos de segmentação. No entanto, o índice de falso-negativo é elevado em relação ao método CR3D. Em imagens sem presença de patologias, os falsos-positivos correspondem a algumas vias aéreas adjacente

Tabela 4.11: resultado da segunda abordagem dos coeficiente de sensibilidade e similaridade por exame da segmentação por K-Médias

Exames	Similaridade	Sensibilidade
1	0,74	0,60
2	0,78	0,65
3	0,93	0,90
4	0,75	0,60
5	0,85	0,76
6	0,92	0,86
7	0,76	0,63
8	0,94	0,95

aos vasos, e em imagens com presença de doença intersticial, os falsos-positivos são os tecidos fibrosos, além de vias aéreas adjacentes. A segmentação de todas as imagens de um exame de paciente sadio pode ser visualizada na Figura 4.20. Por fim, salienta-se que a aplicação do método K-médias combinado com ADP é uma metodologia não encontrada na literatura consultada para segmentação de vasos sanguíneos.



Figura 4.20: visualização da árvore de vasos sanguíneos pulmonares através da segmentação por K-Médias.

4.6 Comparação entre o desempenho dos três métodos

Observam-se algumas características nas imagens que influenciam diretamente os algoritmos. A presença de doença intersticial é um fator preponderante na para inclusão de falsas detecções. A largura de corte também influencia significativamente, pois a visualização de vasos de pequeno calibre é menor quando a largura de corte é maior. Dos exames disponíveis, somente os exame 6 e 7 não são proveniente de imagens TCAR. Neste caso,

observa-se que, quanto maior o corte, menos vasos de pequeno calibre são segmentados. A Figura 4.21 contém o gráfico dos volumes de segmentação dos três métodos.




Figura 4.21: volume de segmentação dos três métodos por exame.

O volume de segmentação do CR3D, em geral, é bem superior ao volume das outras metodologias. Na Figura 4.22 verifica-se a aplicação dos três métodos em uma imagem de pulmão. Salienta-se que a segmentação padrão-ouro na Figura 4.22 é realizada excluindo-se vasos de pequeno calibre.




Figura 4.22: segmentação dos vasos sanguíneos na região do hilo por, (a) manualmente (padrão-ouro); (b) K-Médias; (c) CF; (d) CR3D.

Nota-se que além de mais vasos segmentados, a segmentação por CR3D também abrange uma maior área. Desta forma, quando calculado o volume total das segmentações de todas as imagens do exame, verifica-se uma diferença volumétrica significativa. Em geral, as diferenças de volume da segmentação entre CF e K-Médias são menos visíveis. No exame 1 e 7 é verificado que o método CF segmenta uma maior quantidade de vasos.

É possível comparar na Figura 4.23 que, no conjunto de todas as imagens do padrão-ouro, o método K-média obtém uma maior quantidade de vasos segmentados do que o método CF. Todavia, nestas imagens do padrão-ouro não estão presentes regiões extremas do ápice e da base que apresentam grande quantidade de vasos de pequeno calibre, ignorados significativamente pelo K-Médias e não na mesma intensidade pelo algoritmo CF. A área de segmentação por CF também é superior à área de segmentação por K-médias. Na Figura 4.24 mostra-se esta situação.




Figura 4.23: número de vasos segmentados corretamente.




Figura 4.24: segmentação dos vasos sanguíneos na região do ápice por, (a) manualmente (padrão-ouro); (b) K-Médias; (c) CF; (d) CR3D.

O custo de permitir uma maior quantidade de vasos segmentados no algoritmo CR3D é o alto índice de falsos-positivos. Na Figura 4.26(t) verifica-se outro exemplo de falsa detecção circunscrita em vermelho. Na Figura 4.25 nota-se a diferença significativa nestes índices. Salienta-se que os valores obtidos nos exames 5 e 8, os quais apresentam doenças, são maiores em relação aos valores obtidos nos exames de paciente sadio.




Figura 4.25: percentual de falsos positivos.

Em relação ao desempenho nas regiões em que há vasos adjacentes às vias aéreas, nota-se, na Figura 4.26, a superioridade do algoritmo K-Média. Observa-se que o algoritmo CR3D não distingue adequadamente as bordas das vias aéreas. O método CF distingue com mais exatidão do que o CR3D, contudo ainda inferior ao desempenho do classificador K-Médias.






Figura 4.26: segmentação de vasos sanguíneos com vias aéreas adjacentes; (a), (e), (i), (m) e (q) imagens originais com vias aéreas circuladas em vermelho; (b),(f),(j),(n) e (r) segmentações por CR3D; (c), (g), (k), (o) e (s) segmentação por CF; (d), (h), (l), (t) e (p) segmentação por K-Médias.

A comparação dos coeficientes de similaridade e sensibilidade nesta seção é restrita aos valores obtidos por meio da segunda abordagem de avaliação. Esta comparação pode ser vista na Figura 4.27 em que são visualizados os coeficientes de similaridade e sensibilidade por exame.



(a)



(b)

Figura 4.27: avaliação quantitativa dos métodos; (a) coeficiente de similaridade; (b) coeficiente de sensibilidade.

O valor da similaridade na segmentação por CR3D são superiores pelo fato de possuir maior número de vasos segmentados corretamente. Sabe-se que o CRD3 proporciona uma maior quantidade de falso-positivo, mas este índice não foi suficientemente alto para

reduzir de forma significativa o seu coeficiente de similaridade.

O valor da sensibilidade, em geral, também é superior na aplicação do CR3D. Todavia, no exame 6, a quantidade de falsos-negativos na segmentação por CR3D é maior do que as observadas na segmentação por K-médias. Nesse caso, o maior valor de sensibilidade pertence a segmentação por K-Médias que não proporciona uma quantidade tão elevada de falsos-negativos, devido a largura de corte mais espessa nesse exame.

Nota-se na Figura 4.28 o desempenho das três metodologias aplicada a um único exame sem presença de patologias. Neste caso, verifica-se a diferença volumétrica das segmentações de cada metodologia. A maior quantidade de vasos de menor calibre segmentados torna a aplicação CR3D detentora do maior volume de segmentação. Todavia, verifica-se uma sobreposição maior na visualização tridimensional. O algoritmo CF permitiu uma visualização com menos sobreposição. Por fim, o algoritmo K-Médias foi o algoritmo com menos sobreposição, mas com baixa segmentação de vaso de menor calibre.

A visualização da árvore de vasos com presença de doença intersticial pode ser vista na Figura 4.29. A região circulada em verde é a zona com mais concentração de tecido fibroso. A observação deste tecido fibroso em duas dimensões pode ser vista na Figura 4.30 circulada em verde.




Figura 4.28: árvores de vasos sanguíneos, (a) segmentação por K-Médias;(b) segmentação por CF; (c) segmentação por CR3D.

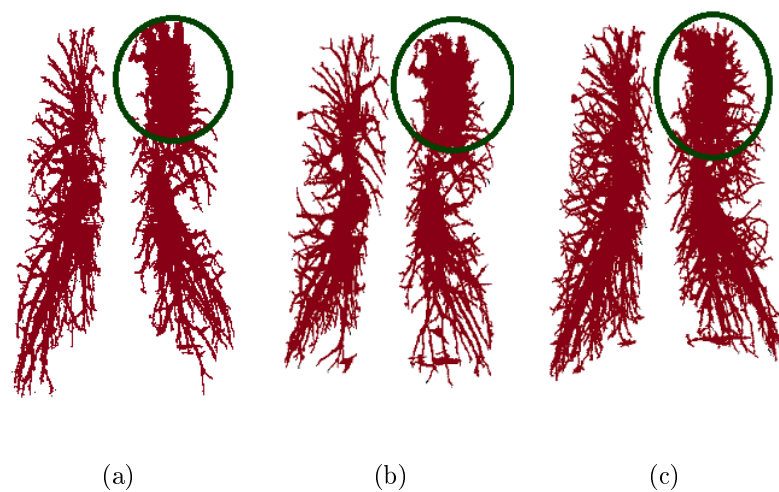


Figura 4.29: árvores de vasos sanguíneos em exame com presença de doença intersticial, (a) segmentação por K-Médias; (b) segmentação por CF; (c) segmentação por CR3D.






Figura 4.30: imagem com destaque em tecido fibroso circulado em verde caracterizado por doença intersticial.



(a)



(b)

Figura 4.3: visualização da segmentação pulmonar e segmentação de vasos; (a) circulada em verde verifica-se uma região com vasos da região interna do pulmão que foi excluída erroneamente pela segmentação pulmonar; (b) circuladas em vermelho verifica-se algumas das regiões em que há presença de vasos não segmentados

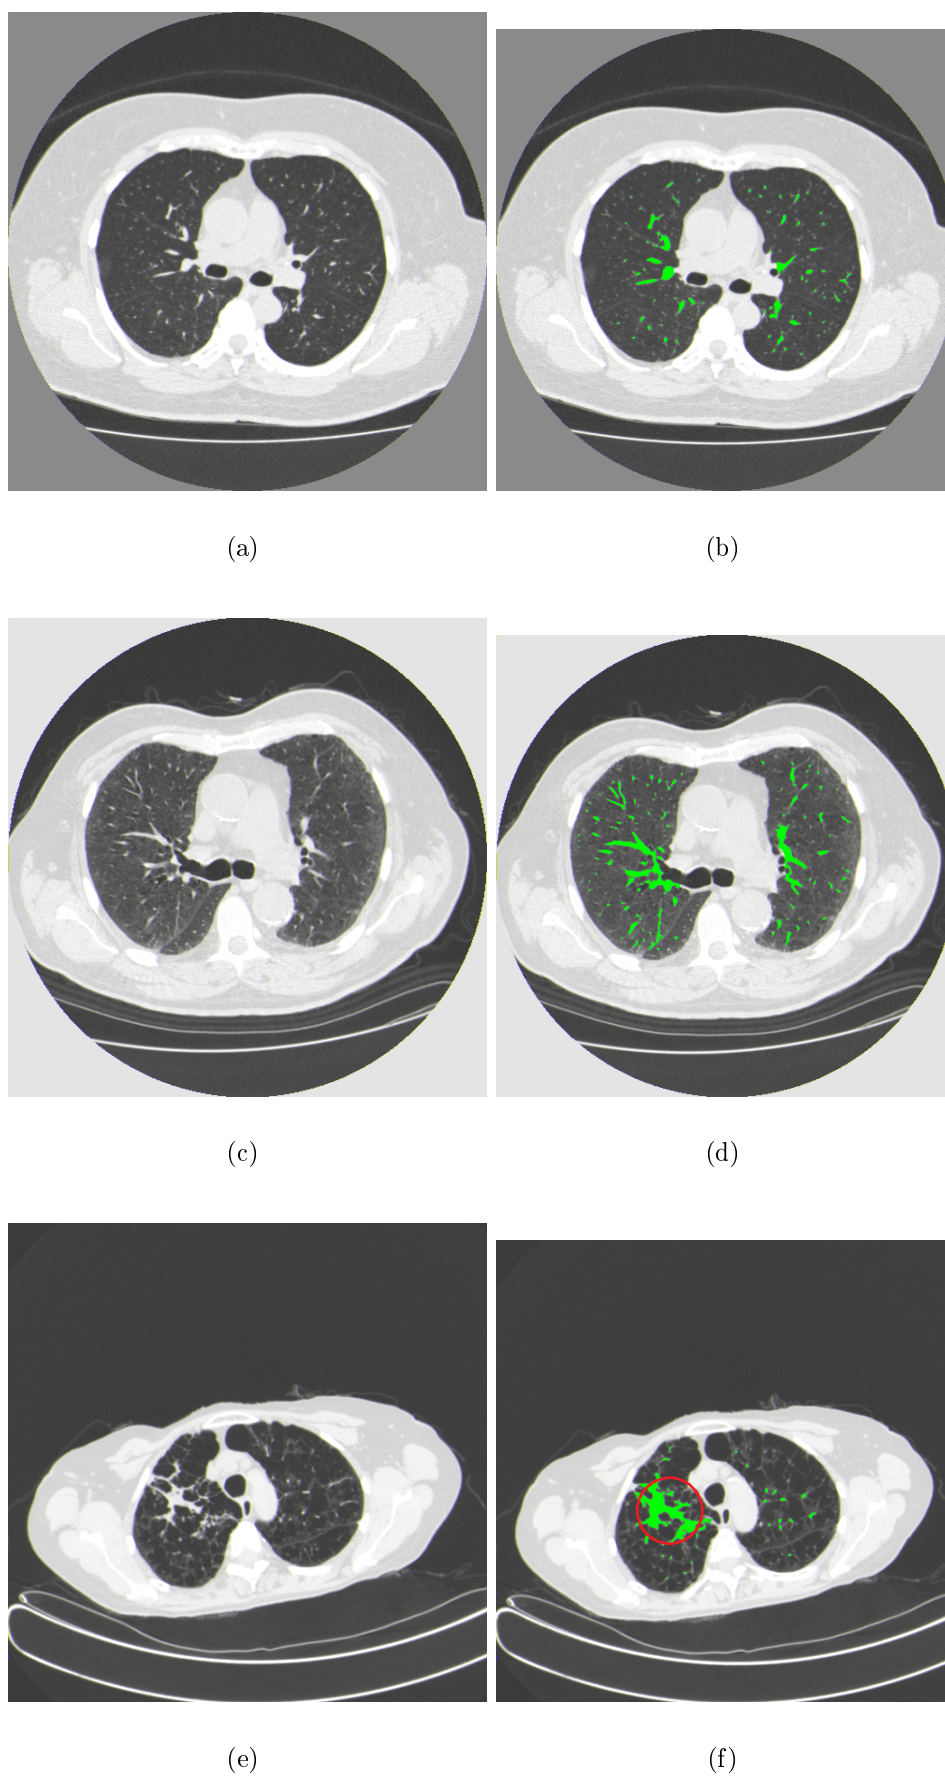


Figura 4.4: segmentação dos vasos sanguíneos por CR3D, (a),(c) e (e) imagens originais; (b) segmentação em paciente sadio;(d)segmentação em paciente com doença intersticial;(f) segmentação em paciente com enfisema e doença intersticial.




Figura 4.5: visualização de limitações do CR3D; (a) imagem de vaso com via aérea justaposta circulado em vermelho; (b) segmentação do vaso com via aérea justaposta (c) região com vasos de pequeno calibre (d) segmentação de vasos em vermelho são as marcações do padrão-ouro e em verde a segmentações do CR3D




Figura 4.6: visualização da segmentação vasos por CR3D com vias aéreas justapostas; (a) imagem original com a via aérea circulado em vermelho; (b) segmentação dos vasos




Figura 4.7: sensibilidade e similaridade da segmentação por CR3D considerando a primeira abordagem de avaliação




Figura 4.8: sensibilidade e similaridade da segmentação por CR3D pela segunda abordagem de avaliação




Figura 4.9: visualização da árvore de vasos sanguíneos pulmonares através da segmentação por CR3D.

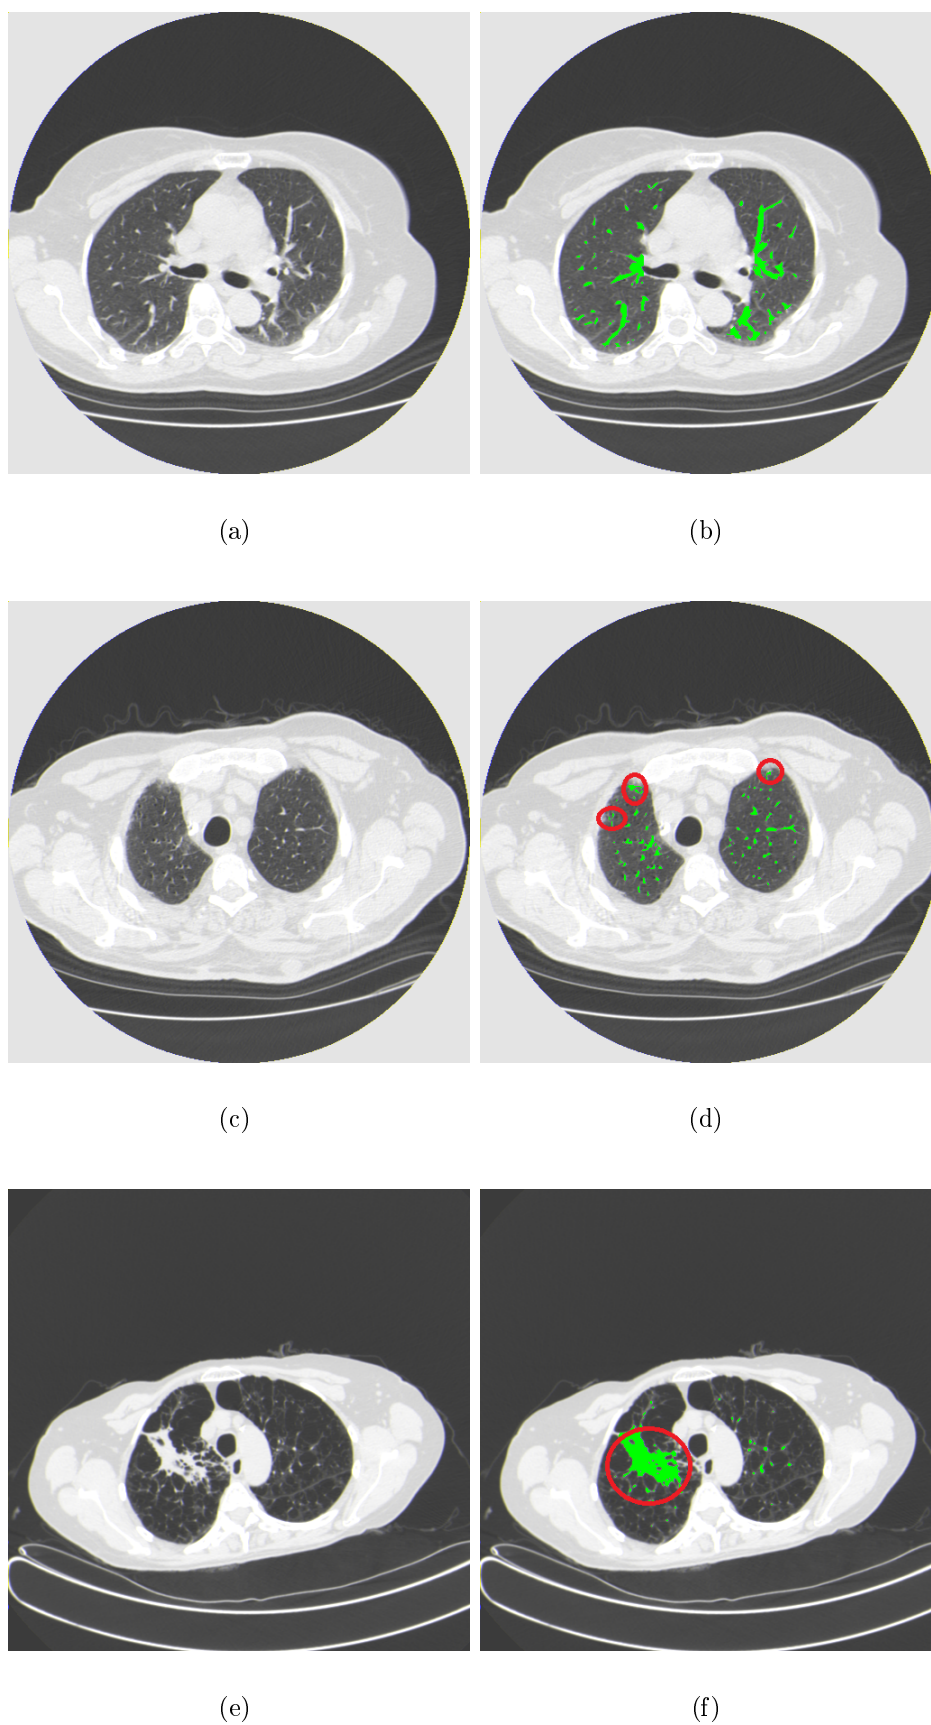


Figura 4.10: segmentação dos vasos sanguíneos por CF,(a),(c) e (e) imagens originais; (b) segmentação em paciente sadio;(d)segmentação em paciente com doença intersticial;(f) segmentação em paciente com enfisema e doença intersticial.




Figura 4.11: avaliação da segmentação dos vasos sanguíneos por CF; (a),(c) e (e) imagens originais com vias aéreas circulares em vermelho; (b),(d) e (f) respectivas segmentações dos vasos vizinhos as vias aéreas.




Figura 4.12: sensibilidade e similaridade da segmentação por CF por meio da primeira abordagem de avaliação




Figura 4.13: sensibilidade e similaridade da segmentação por CF considerando a segunda abordagem de avaliação


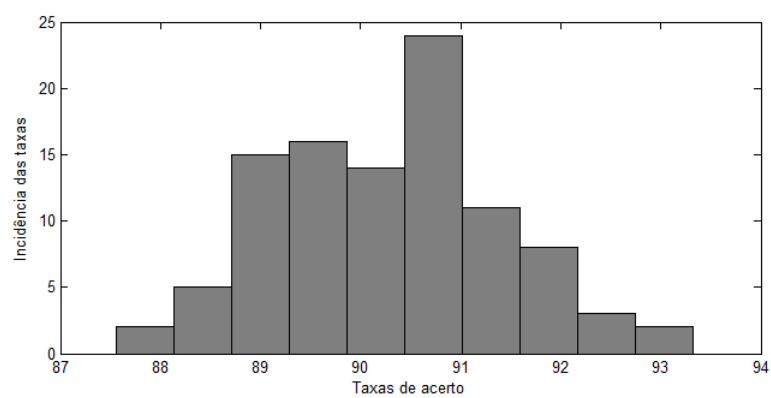



Figura 4.14: visualização da árvore de vasos sanguíneos por meio da segmentação por CF



(a)



(b)

Figura 4.15: taxas de acerto do classificador K-médias aplicado ao banco de dados de treino; (a) Histograma das taxas de acerto; (b) Box plot das taxas de acerto.




Figura 4.16: segmentação dos vasos sanguíneos por K-médias em imagens distintas; (a),(c) e (e) imagens originais; (b)e(d)segmentação em paciente normal; (f) segmentação em paciente com enfisema e doença intersticial;




Figura 4.17: avaliação da segmentação por K-médias dos vasos sanguíneos; (a),(c) e (e) imagens originais com vias aéreas circuladas em vermelho; (b),(d) e (f) respectivas segmentações dos vasos vizinhos as vias aéreas;




Figura 4.18: sensibilidade e similaridade da segmentação por K-médias pela primeira abordagem de avaliação

Capítulo 5

Conclusões, Contribuições e Trabalhos Futuros

Esta dissertação realiza uma análise comparativa entre os métodos Crescimento de Regiões 3D, Conectividade Fuzzy e classificador K-Médias, aplicados a segmentação de vasos sanguíneos pulmonares em imagens de Tomografia Computadorizada do Tórax. Para isto, são utilizadas imagens de TC multidetectores e TCAR, provenientes de voluntários sadios e pacientes com enfisema e doença intersticial.

Devido a menor quantidade de falsos-negativos, conclui-se que o desempenho do CR3D é o melhor, considerando-se somente o coeficiente de sensibilidade. Quando considera-se o coeficiente de similaridade, os desempenhos dos algoritmos tornam-se similares. Verifica-se também que, em imagens com presença de doença intersticial, somente a avaliação quantitativa da segmentação em 6 imagens por exame não define de forma efetiva a exatidão da segmentação. Faz-se necessário, portanto, uma avaliação também de caráter qualitativo. Em imagens com ausência de doenças, a avaliação de caráter quantitativo mostra-se efetiva.

Em imagens de TCAR, é possível segmentar regularmente os vasos, mas o desempenho dos algoritmos em imagens de TC multidetectores foi mais consistente. No conjunto dos métodos implementados, a definição do melhor algoritmo para segmentação dos vasos sanguíneos depende da aplicação. Se o objetivo da segmentação é detectar absolutamente todos os vasos, dentre os três métodos, a aplicação do CR3D é a mais adequada. Caso o objetivo seja uma visualização somente de vasos de grande calibre com menor incidência de falsos positivos, o método K-Médias é o mais adequado. Para uma visualização intermediária o algoritmo CF é suficiente. Em pacientes com doença intersticial, o alto índice de falso-positivo torna inviável a utilização destes algoritmos em imagens com essa

característica.

Diversas contribuições são resultantes deste trabalho, dentre as quais merece destaque a aplicação do classificador K-Médias combinado com ADP para segmentação de vasos sanguíneos. Além desta, podem-se citar outras contribuições:

- desenvolvimento do ADP em uma máscara volumétrica;
- classificação das regiões pulmonares segundo a aeração, é realizada uma divisão da classe normalmente aerada em normalmente aerada α e normalmente aerada γ ;
- análise do desempenho dos algoritmos CRD3, CF e K-médias em imagens de TC sem presença de contraste intravenoso;
- constatação de limitações das segmentações dos algoritmos em imagens com presença de doença intersticial;

A Partir deste trabalho, outros trabalhos podem ser desenvolvidos. As propostas para desenvolvimento de trabalhos futuros consistem em:

- aplicação de segmentação dos algoritmos em imagens com presenças de injeção de contraste e com largura de corte a cima de 2 mm;
- substituição do classificador K-Média por uma rede neural;
- realizar uma análise por textura, além de análise de densidade pulmonar;
- realizar a segmentação de um exame combinando as metodologias, aplicando em cada secção pulmonar uma metodologia distinta;
- desenvolver um sistema de visualização tridimensional dos vasos sanguíneos pulmonares;

Além de auxílio ao diagnóstico, outra aplicação para segmentação de vasos sanguíneos é proporcionar uma melhor distinção dos Lóbulos pulmonares. Rotacionando a árvore de vasos é possível observar claramente essa distinção. Portanto esta segmentação de vasos pode servir como parâmetro para segmentação da cisura pulmonar, estrutura fronteira entre os lóbulos pulmonares. Na Figura 5.1 verifica-se circulado em verde uma das regiões de cisura pulmonar.




Figura 5.1: utilização da árvore de vasos sanguíneos para distinguir os lóbulos pulmonares.

Referências Bibliográficas

ACHARYA, T.; RAY, A. K. *Image Processing: Principles and Applications*. 1. ed. [S.l.]: Wiley-Interscience, 2005.

ANDERSON, F. A. et al. A population-based perspective of the hospital incidence and case-fatality rates of deep vein thrombosis and pulmonary embolism. the worcester dvt study. *Arch Intern Med*, v. 151, p. 933 – 8, 1991.

BANKS, S. *Signal Processing, Image Analysis and Pattern Recognition*. [S.l.]: Prentice-Hall, 1990.

BARRETO, S. S. M.; GAZZANA, M. B. Hipertensão pulmonar: relato de seis casos e atualização do tema. *Jornal Brasileiro de Pneumologia*, p. 321–336, 2000.

BONTRAGER, K. L. *Tratado de Técnica Radiológica e Base Anatômica*. 5. ed. Rio de Janeiro: Guanabara Koogan, 2000.

BUSHONG, S. C. *Radiologic science for technologists: physics, biology, and protection*. 6. ed. [S.l.]: Mosby-Year Book, 2005.

CARAMELLI, B. et al. *Diretriz de Embolia Pulmonar*. 7a.. ed. Rio de Janeiro: SBC, 2004.

CARVALHO, A. F. C. A. *Circulação e Respiração - Fundamentos de Biofísica e Fisiologia*. 1. ed. [S.l.]: Cultura Médica, 1983.

CAVALCANTE, T. *Técnica para segmentação automática de vias aéreas em imagens de tomografia computadorizada do tórax*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2010.

CHANNICK, T. W. R. Diagnosis and treatment of pulmonary arterial hypertension. *Cardiol Clin*, 2004.

- COHEN, L. D. On active contour models and balloons. *CVGIV: Image Understanding*, v. 53, p. 211–218, March 1991.
- COON P.W. WILLIS, J. K. W. Venous thromboembolism and other venous diseases in the tecumseh community health study. *Circulation*, v. 48, p. 839–46, 1973.
- DÂNGELO, J. G.; FATTINI, C. A. *Anatomia Humana Básica*. 2. ed. [S.l.]: Atheneu., 2002.
- E.HALL, J.; GUYTON, A. C. *Tratado de Fisiologia Médica*. 12. ed. [S.l.]: Elsevier, 2011.
- EPSTEIN, C. L. *The Mathematics of Medical Imaging*. Philadelphia: University of Pennsylvania, 2001.
- FAUCI, E. B. A. et al. Primary pulmonary hypertension (pph) fact sheet. *American Lung Association*, 2003.
- FÉLIX, J. H. S. *Sistema de visão computacional para detecção e quantificação de enfisema pulmonar*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2007.
- FELIX, J. H. S. et al. Lung and chest wall structures segmentation in CT images. *VIPIMAGE*, outubro 2007.
- FERRON, J. R. M. *Grande Atlas do Corpo Humano:/Anatomia/Histologia/Patologias*. 1. ed. [S.l.]: Manole Ltda, 2007.
- FLORES, J. M.; SCHMITT, F. Segmentation, reconstruction and visualization of the pulmonary artery and the pulmonary vein from anatomical images of the visible human project y. In: *Proceedings of the Sixth Mexican International Conference on Computer Science*. Washington, DC, USA: IEEE Computer Society, 2005. (ENC '05), p. 136–144. ISBN 0-7695-2454-0.
- FUKUNAGA, K. *Statistical Pattern Recognition*. [S.l.]: Academic Press, 1990.
- GEVENOIS, P. A.; YERNAULT, J. C. Can computed tomography quantify pulmonary emphysema. *European Respiratory Journal*, n. 5, p. 843–848, janeiro 1995.
- GOLDHABER, S. et al. Risk factors for pulmonary embolism.the framingham study. *Am J Med*, v. 74, p. 1023–8, 1983.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 3. ed. [S.l.]: Prentice-Hall, Inc., 2008.

- GUYTON, J. E. H. A. C. *Tratado de Fisiologia Médica*. 9. ed. [S.l.]: Guanabara Koogan, 1997.
- HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. description of system. *British Journal of Radiology*, v. 46, p. 1016–1022, 1973.
- HOVNANIAN, A. c. et al. O papel dos exames de imagem na avaliação da circulação pulmonar. *Jornal Brasileiro de Pneumologia*, scielo, v. 37, p. 389 – 403, 06 2011.
- JAN, J. *Medical image processing, reconstruction, and restoration: concepts and methods*. [S.l.]: Taylor e Francis Group, 2006.
- JHONSON, D. W. W. R. A. *Applied Multivariate Statistical Analysis*. 6. ed. [S.l.]: Prentice-Hall, 1988.
- KAFTAN, J. N. et al. Fuzzy pulmonary vessel segmentation in contrast enhanced ct data. In: REINHARDT, J. M.; W.PLUIM, J. P. (Ed.). *Medical Imaging 2008: Image Processing*. San Diego, USA: SPIE, 2008. v. 6914, p. 69141Q–1–12.
- KASPER, W. et al. Management strategies and determinants of outcome in acute major pulmonary embolism: Results of a multicenter registry. *Journal of the American College of Cardiology*, v. 30, n. 5, p. 1165 – 1171, 1997.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: active contours models. *International Journal of Computer Vision*, v. 1, n. 4, p. 321–331, january 1988.
- KLEINFELDER, D. et al. A sazonalidade do tromboembolismo venoso no clima subtropical de são paulo. *Jornal Vascular Brasileiro*, scielo, v. 8, p. 29 – 32, 03 2009.
- KORFIATIS, P.; KARAHALIOU, A.; COSTARIDOU, L. Automated vessel tree segmentation: Challenges in computer aided quantification of diffuse parenchyma lung diseases. In: *Information Technology and Applications in Biomedicine*. [S.l.: s.n.], 2009. p. 1 –4.
- LAGE, D. M. *Visibilização das artérias coronárias epicárdicas em imagens ecocardiográficas tridimensionais com contraste de microbolhas*. Tese (Doutorado) — Faculdade de Medicina da Universidade de São Paulo, 2010.
- LINGURARU, M. G. et al. Ct and image processing non-invasive indicators of sickle cell secondary pulmonary hypertension. In: *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*. [S.l.: s.n.], 2008. p. 859 –862.

Marques Filho, H. V. O. *Processamento Digital de Imagens*. [S.l.]: Brasport, 1999.

MARQUES, J. S. *Reconhecimento de padrões: métodos estatísticos e neuronais*. 2. ed. [S.l.]: IST Press, 2005.

MASUTANI, Y.; MACMAHON, H.; DOI, K. Computerized detection of pulmonary embolism in spiral ct angiography based on volumetric image analysis. *Medical Imaging, IEEE Transactions on*, v. 21, n. 12, p. 1517–1523, dec. 2002.

MCGOON, M. et al. Screening, early detection, and diagnosis of pulmonary arterial hypertension. *Chest*, v. 126, p. 14S–34S, 2004.

MORAES, D.; LOSCALZO, J. Pulmonary hypertension: Newer concepts in diagnosis and management. *Clinical Cardiology*, Wiley Periodicals, Inc., v. 20, n. 8, p. 676–682, 1997.

RAGHUPATHI, L.; LAKARE, S. A hybrid lung and vessel segmentation algorithm for computer aided detection of pulmonary embolism. In: KARSSEMEIJER, N.; GIGER, M. L. (Ed.). [S.l.]: SPIE, 2009. v. 7260, n. 1, p. 726033.

Rebouças Filho, P. *MCA Crisp: nova técnica de segmentação dos pulmões em imagens de Tomografia Computadorizada baseada no Método de Contorno Ativo*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2010.

RENSHAW S.R. BRENNAN, T. H. A. The clinical presentation of deep vein thrombosis and pulmonary embolism. In: *Pulmonary Embolism*. [S.l.: s.n.], 1999. p. 34 –42.

ROBBINS, S. L.; COTRAN, R. S. *Patologia - Bases Patológicas das Doenças*. 7. ed. Rio de Janeiro: Saunders Elsevier, 2005.

SANTOS, A. P.; GAIVÃO, A. M.; TAVARES, S. F. A. Produtos de contraste iodados. *Revista Científica da ordem dos médicos*, v. 22, p. 261 – 274, 2009.

SATO, Y. et al. *3D Multi-Scale Line Filter for Segmentation and Visualization of Curvilinear Structures in Medical Images*. 1998.

SHANG, Y. et al. Vascular active contour for vessel tree segmentation. *Biomedical Engineering, IEEE Transactions on*, v. 58, n. 4, p. 1023 –1032, april 2011.

SHAW, L. S.; SIMÕES, M. G. *Controle e Modelagem Fuzzy*. 2. ed. [S.l.]: Edgard Blucher, 2010.

SIEMENS. *Computed Tomography: Its History and Technology*. [S.l.], setembro 2004. Disponível em: <www.SiemensMedical.com>. Acesso em: 21 maio de 2007.

SILVA, J. S. S. *Segmentação Pulmonar em Estudos de Tomografia Axial Computorizada*. Dissertação (Mestrado) — Universidade de Aveiro, 2005.

SLUIMER, I.; PROKOP, M.; GINNEKEN, B. van. Toward automated segmentation of the pathological lung in ct. *IEEE Transactions on Medical Imaging*, v. 24, n. 8, p. 1025–1038, agosto 2005.

SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis, and Machine Vision*. 3. ed. USA: Thomson, 2008.

TOZAKI, T. et al. Three-dimensional analysis of lung areas using thin-slice ct images. In: *Pattern Recognition, 1996., Proceedings of the 13th International Conference on*. [S.l.: s.n.], 1996. v. 3, p. 548 –552 vol.3.

UDUPA, J.; SAHA, P. Fuzzy connectedness and image segmentation. *Proceedings of the IEEE*, v. 91, n. 10, p. 1649 – 1669, oct. 2003. ISSN 0018-9219.

UDUPA, J. K.; SAMARASEKERA, S. Fuzzy connectedness and object definition: Theory, algorithms, and applications in image segmentation. *CVGIP: Graphical Model and Image Processing*, p. 246–261, 1996.

VIEIRA, S. R. R. et al. A lung computed tomographic assessment of positive end-expiratory pressure-induced lung overdistension. *American Journal of Respiratory and Critical Care Medicine*, v. 158, p. 1571–1577, 1998.

WEBB W. E. BRANT, N. M. M. W. R. *Fundamentals of body CT*. 3. ed. [S.l.]: Estados Unidos, 2005.

WHITE., R. H. The epidemiology of venous thromboembolism. *Circulation*, v. 107, n. 23, p. I4 – 8, 2003.

ZAFFARI, C. *VISUALIZAÇÃO E PROCESSAMENTO DIGITAL DE IMAGENS MÉDICAS*. Dissertação (Mestrado) — Universidade Católica do Rio Grande do Sul, 2006.

ZHOU, C. et al. Automatic multiscale enhancement and segmentation of pulmonary vessels in ct pulmonary angiography images for cad applications. *Medical Physics*, v. 34, n. 12, p. 4567–4577, 2007.

ZHU, X. et al. Voles: Vascularity-oriented level set algorithm for pulmonary vessel segmentation in image guided intervention therapy. In: *Biomedical Imaging: From Nano to Macro, 2009. ISBI '09. IEEE International Symposium on*. [S.l.: s.n.], 2009. p. 1247–1250.

ZOU, K. H. et al. Statistical validation of image segmentation quality based on a spatial overlap index. *Academic Radiology*, v. 11, p. 178–189, 2004.