



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

John Hebert da Silva Felix

SISTEMA DE VISÃO COMPUTACIONAL PARA
DETECÇÃO E QUANTIFICAÇÃO DE ENFISEMA
PULMONAR

FORTALEZA - CEARÁ
DEZEMBRO - 2007

© John Hebert da Silva Felix, 2007

John Hebert da Silva Felix

SISTEMA DE VISÃO COMPUTACIONAL PARA
DETECÇÃO E QUANTIFICAÇÃO DE ENFISEMA
PULMONAR

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

Paulo César Cortez
(Orientador)

Marcelo Alcantara Holanda
(Co-Orientador)

FORTALEZA - CEARÁ
2007

F360s Felix, John Herbert da Silva
Sistema de visão computacional para detecção e quantificação de enfisema pulmonar / John Herbert da Silva Felix.2007
126 f. ;color. enc.

Orientador: Prof. Dr. Paulo César Cortez
Co-Orientador: Prof. Dr. Marcelo Alcantara Holanda
Área de concentração: Sinais e Sistemas
Dissertação (mestrado) - Universidade Federal do Ceará, Depto. de Engenharia de Teleinformática, Fortaleza, 2007

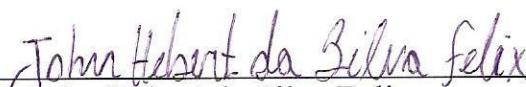
1. DPOC 2. Enfisema Pulmonar – Detecção e quantificação 3. Segmentação de imagens médicas digitais 4. Auxílio ao diagnóstico
I. Cortez, Paulo César (orient.) II. Holanda, Marcelo Alcantara (co-orient.) III. Universidade Federal do Ceará – Curso de Mestrado em Engenharia de Teleinformática IV. Título

CDD 621.3

John Hebert da Silva Felix

Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Teleinformática e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Teleinformática da Universidade Federal do Ceará.

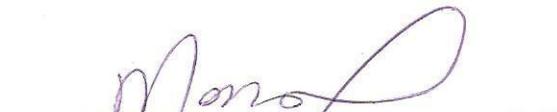


John Hebert da Silva Felix

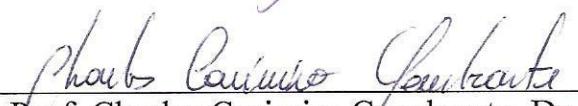
Banca Examinadora:



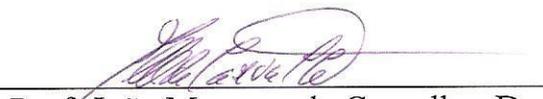
Prof. Paulo César Cortez, Dr.



Prof. Marcelo Alcântara Holanda, Dr.



Prof. Charles Casimiro Cavalcante, Dr.



Prof. João Marques de Carvalho, Dr.



Prof. José Daniel Vieira de Castro, Dr.

Fortaleza, 03 de Dezembro de 2007

*Aos meus pais, Cícero e Josélia,
e à minha namorada Andréa
pelo incentivo e apoio*

Sumário

Sumário	v
Lista de Tabelas	vii
Lista de Figuras	ix
Lista de Siglas	xviii
1 Introdução	1
1.1 Motivação	3
1.2 Objetivos deste trabalho	5
1.3 Organização da dissertação	5
1.4 Produção Científica	6
2 Conceitos Básicos de Processamento Digital de Imagem	8
2.1 Descrição de um típico sistema de visão computacional	9
2.2 Histograma de imagem	10
2.3 Técnicas de segmentação de imagens	11
2.3.1 Limiarização com limiar fixo	12
2.3.2 Limiarização global, local e dinâmica	14
2.3.3 Segmentação orientada a região	14
2.3.3.1 Crescimento de região	14
2.3.4 Segmentação através da transformada de <i>watershed</i>	16
2.3.4.1 Algoritmo de segmentação de <i>watershed</i>	18
2.3.4.2 Marcadores	19
2.3.5 Morfologia Matemática	19
2.3.5.1 Erosão e Dilatação	21
2.3.5.2 Abertura e Fechamento	22
2.3.5.3 Afinamento	22
2.3.6 Segmentação por Pseudo-Cores	23

2.3.7	Medidas aplicadas aos pulmões	24
2.3.7.1	Medidas de perímetro, área e volume	24
2.3.7.2	Medidas de densidade pulmonar média (DPM) e quinze pontos percentuais (Perc15)	25
2.4	Conclusão do Capítulo	26
3	Técnicas de Segmentação Aplicadas aos Pulmões	27
3.1	Segmentação pulmonar e de suas estruturas	27
3.1.1	Segmentação dos pulmões	28
3.1.2	Segmentação dos lobos e das fissuras pulmonares	30
3.1.3	Segmentação dos vasos sanguíneos pulmonares	32
3.1.4	Segmentação das vias aéreas	33
3.2	Detectando, quantificando e classificando as alterações de estruturas pulmonares na DPOC	34
3.2.1	Enfisema pulmonar	35
3.2.2	Bronquite crônica	38
3.2.3	Doença pulmonar obstrutiva crônica - (DPOC)	38
3.3	Conclusão do Capítulo	39
4	Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar	40
4.1	Aquisição das imagens	40
4.2	Metodologia	41
4.3	Descrição do sistema SDEP	42
4.4	Descrição dos algoritmos para a segmentação dos pulmões	43
4.4.1	Descrição do algoritmo do sistema SDEP	43
4.4.2	Descrição do algoritmo de segmentação do sistema Osiris	49
4.4.3	Descrição dos algoritmo SC e SAB	49
4.5	Descrição da interface do sistema Osiris	51
4.6	Descrição da interface do sistema SDEP	52
4.7	Utilizando o sistema SDEP	54
4.8	Conclusão do Capítulo	56
5	Resultados e Discussões	57
5.1	Resultados	57
5.1.1	Resultados dos algoritmos de segmentação	58
5.1.2	Resultados dos histogramas por faixa de densidade e histograma acumulado	63
5.2	Resultados da segmentação através da máscara colorida (pseudo-cores)	66
5.3	Limitações dos algoritmos de segmentação	69
5.4	Discussões	72

5.5 Conclusão do Capítulo	74
6 Conclusões, Contribuições e Trabalhos Futuros	75
Referências Bibliográficas	77
Apêndice	90
A Tomografia Computadorizada	90
A.1 Primeira geração da TC	91
A.2 Segunda geração da TC	92
A.3 Terceira geração da TC	93
A.4 Quarta geração da TC	94
A.5 Quinta geração da TC	95
A.6 TC espiral ou helicoidal	96
A.7 TC de múltiplos fatiamentos	97
A.8 Princípios básicos da TC	97
A.9 Princípios de Reconstrução da TC	100
A.10 Escala da TC em unidades Hounsfield	103
A.11 Padrão de Leituras de Imagens Médicas (DICOM)	104
A.12 Tomografia Computadorizada de Alta Resolução - TCAR	105

Lista de Tabelas

5.1	resultados de segmentação das 102 imagens de TCAR dos pulmões de voluntários sadios e das 141 imagens de TCAR dos pulmões de pacientes com DPOC.	60
5.2	comparação dos resultados dos sistemas Osiris e SDEP para as medidas de área e DPM de um voluntário sadio e de um paciente com DPOC.	63
5.3	resultados obtidos através da máscara colorida dos sistemas Osiris e SDEP para as faixas de densidade pulmonar da Figura 5.1(f) de um paciente com DPOC.	69
A.1	doenças perceptíveis através da TCAR: opacidade pulmonar crescente e decrescente (GOTWAY et al., 2005).	109

Lista de Figuras

1.1	tecido de um pulmão (a) normal e (b) com enfisema panlobular (HEARD et al., 1979).	3
2.1	sistema típico de Visão Computacional.	9
2.2	imagem dos pulmões (a) original e (b) seu histograma.	12
2.3	aplicação do limiar fixo de -650 UH na imagem dos pulmões (a) original e (b) binarizada.	13
2.4	perfil de inundação das bacias de captação com a represa (PRATT, 2001).	17
2.5	representação de uma watershed (VINCENTE; SOILLE, 1991).	17
2.6	segmentação de <i>watershed</i> com o uso de marcadores (a) imagem de eletroforese, (b) sobre-segmentação com o uso da <i>watershed</i> , (c) marcadores internos (região de alta intensidade dos níveis de cinza) e marcadores externos (linha da <i>watershed</i>) e (d) resultado da segmentação (GONZALEZ; WOODS, 2002).	20
2.7	interpretação geométrica da técnica de fatiamento de densidade (GONZALEZ; WOODS, 2002).	24
2.8	típico histograma dos pulmões (na esquerda) e o histograma acumulado (na direita), adaptada de (STOEL; STOLK, 2004).	26
3.1	anatomia dos lobos pulmonares, adaptada de (ZHANG; HOFFMAN; REINHARDT, 2006).	31
3.2	representação dos canais de ar dos pulmões, adaptada de (SLUIMER, 2005).	33

3.3	pulmão normal e com enfisema (a) normal, (b) enfisema panlobular, (c) enfisema centrilobular e (d) enfisema paraseptal (HEARD et al., 1979).	35
3.4	diagrama de um lobo do pulmão, ilustrando ácinos (bagos) normais, enfisema centrilobular e panlobular (HEARD et al., 1979).	37
4.1	imagem de TC dos pulmões (a) imagem convertida para 8- <i>bits</i> e (b) seu histograma com a semente = 58.	44
4.2	imagem rotulada através do CR com as sub-imagens (região retangular em cada pulmão).	45
4.3	máscaras dos pulmões (a) esquerdo e (b) direito.	46
4.4	operações morfológicas (a) fechamento aplicado no pulmão esquerdo, (b) fechamento aplicado no pulmão direito, (c) erosão aplicada no pulmão esquerdo e (d) erosão aplicada no pulmão direito.	47
4.5	imagens de (a) máscara dos pulmões e (b) intersecção (resultado da segmentação).	48
4.6	recorte da imagem original com a sobreposição das bordas extraídas da máscara dos pulmões (Figura 4.5(a)).	48
4.7	interface do sistema Osiris.	51
4.8	interface do sistema SDEP.	52
4.9	recorte da parte 1 da interface do sistema SDEP.	53
4.10	recorte da parte 2 da interface do sistema SDEP.	54
4.11	recorte da parte 3 da interface do sistema SDEP.	54
5.1	imagens de TCAR dos pulmões. Na coluna da esquerda os voluntários sadios e na coluna da direita os pacientes com DPOC.	59
5.2	segmentação das imagens de TCAR dos pulmões de um voluntário sadio. Na coluna da esquerda dos algoritmos SC e SAB, na coluna central do sistema Osiris e na coluna da direita do SDEP.	61

5.3	segmentação das imagens de TCAR dos pulmões de um paciente com DPOC. Na coluna da esquerda dos algoritmos SC e SAB, na coluna central do sistema Osiris e na coluna da direita do SDEP.	62
5.4	histograma por faixa de 20 em 20 (a) voluntário sadio mostrado na Figura 5.1(g) e (b) paciente com DPOC apresentado na Figura 5.1(h).	64
5.5	histograma acumulado (a) voluntário sadio mostrado na Figura 5.1(g) e (b) paciente com DPOC apresentado na Figura 5.1(h).	65
5.6	janela de sobreposição dos histogramas (a) sobreposição dos histogramas por faixas e (b) sobreposição dos histogramas acumulados.	67
5.7	segmentação das faixas de densidade do tecido pulmonar. Do sistema Osiris de (a) -1000 a -950, (b) -949 a -700, (c) -699 a -100 até (d) -99 a +100. Do sistema SDEP (e) estão todas as faixas de densidade da Tabela 5.3.	68
5.8	resultados em área e em porcentagem da segmentação pela máscara colorida do tecido pulmonar, para as regiões ventral (1), medial (2) e dorsal (3).	70
5.9	início da segmentação dos algoritmos SC e SAB, (a) imagem binarizada, (b) imagem da operação de abertura, (c) imagem da detecção de bordas e (d) imagem após a eliminação dos objetos com contornos conectados e desconectados.	71
5.10	limitação da segmentação com a técnica de CR (a) imagem dos pulmões de um paciente com DPOC, (b) segmentação com perdas do sistema Osiris e (c) segmentação com perdas do sistema SDEP.	72
A.1	desenho esquemático da primeira geração, adaptada de (JAN, 2006).	91
A.2	desenho esquemático da segunda geração, adaptada de (KALENDER, 2006).	93
A.3	desenho esquemático da terceira geração, adaptada de (JAN, 2006).	94
A.4	desenho esquemático da quarta geração, adaptada de (JAN, 2006).	95
A.5	desenho esquemático da quinta geração, adaptada de (BRONZINO, 2006).	96

A.6	princípio da TC helicoidal, adaptada de (JAN, 2006).	97
A.7	visualização perpendicular da esquerda para a direita, princípio da TC helicoidal e da TC de múltiplos fatiamentos, adaptada de (JAN, 2006).	98
A.8	representação de um elemento de volume <i>voxel</i> no lado esquerdo e de um pixel no lado direito, adaptada de (BONTRAGER, 2000).	99
A.9	imagens de seções do pulmão (a) planos de cortes no corpo, (b) seção sagital, (c) seção axial, (d) seção coronal, adaptada de (SLUIMER, 2005).	100
A.10	desenho esquemático da instalação de uma típica TC. 1) console de controle, 2) armação padrão, 3) mesa para o paciente, 4) apoio para cabeça e 5) imageador de laser, adaptada de (BRONZINO, 2006).	101
A.11	escala em Unidades Hounsfield, adaptada de (SIEMENS, 2004).	104
A.12	estrutura de uma imagem no padrão DICOM (SILVA, 2005).	106
A.13	RI dos pulmões obtidas através de uma TCAR (a) RI destacadas na imagem, (b) os pulmões direitos usadas na seleção das RI. As imagens de A1 e A2 até D1 e D2 mostram os padrões patológicos escolhidos para representar cada um dos quatro grupos de pneumopatias: A) linear e opacidades reticulares, B) nodular ou opacidades reticulonodulares, C) opacificação do parênquima, D) cistos e enfisemas. O tecido pulmonar normal é visto nas imagens E1 e E2 (SLUIMER, 2005).	108

Resumo

A Doença Pulmonar Obstrutiva Crônica (DPOC) é um problema de saúde mundial com altos índices de mortalidade, sendo o tabagismo o principal causador desta. Apesar da DPOC ser uma doença de âmbito mundial é, geralmente, subestimada e subdiagnosticada, levando desta forma ao subtratamento. Para evitar um aumento de casos patológicos com diagnósticos incorretos, a tomografia computadorizada deve ser utilizada já que esta constitui uma excelente ferramenta para diagnóstico precoce da componente de enfisema pulmonar na DPOC. Porém, as análises nas imagens feitas pelos radiologistas ou médicos é subjetiva levando-os a realizarem medições imprecisas, devido à limitação da visão humana. O objetivo deste trabalho é desenvolver um sistema de Visão Computacional para análise de imagens tomográficas (SDEP) capaz de segmentar automaticamente as imagens de Tomografia Computadorizada de Alta Resolução (TCAR) dos pulmões, detectar e quantificar a presença de enfisema pulmonar de modo preciso e automático, possibilitando sua visualização. Também, neste trabalho são analisados os resultados, buscando avaliar a eficiência do sistema SDEP comparando-o com o sistema Osiris 4, e com dois algoritmos de segmentação. Os resultados da segmentação são analisados através da visualização de 102 imagens de 8 voluntários saudáveis e 141 imagens de 11 pacientes com DPOC. O sistema SDEP apresenta-se mais eficiente do que os outros métodos considerados neste trabalho, tomando-se como base segmentação correta, sobre-segmentação, segmentação com perdas e segmentação errada. Este sistema realiza a segmentação das

faixas das densidades pulmonares através da máscara colorida, aplicando várias cores em uma única imagem e quantifica cada cor por área e porcentagem, enquanto que o sistema Osiris usa apenas uma cor por vez em cada imagem. O sistema SDEP possui também uma ferramenta que faz a sobreposição dos histogramas, o qual permite uma análise visual mais adequada da evolução da componente do enfisema. Este sistema possibilita auxílio ao diagnóstico, bem como mostra-se ser uma ferramenta de pesquisa para análise do enfisema pulmonar.

Palavras-Chave: DPOC, Detecção e Quantificação de Enfisema Pulmonar, Segmentação de Imagens Medicas Digitais, Auxílio ao Diagnóstico.

Abstract

The Chronic Obstructive Pulmonary Disease (COPD) is a worldwide public health problem with high rates of mortality, being the tobacco the main causer of this disease. COPD is underestimated and underdiagnosed globally, and consequently the patient receives an undertreatment. To avoid an increase of pathological cases with incorrect diagnoses, the computerized tomography should be used as an excellent tool for premature diagnosis of pulmonary emphysema component from COPD. However, the analysis on images accomplished by radiologists or doctors is subjective, leading them to accomplish inaccurate measurements, due to human vision limitation. The objective of this work is to develop a Computational Vision System for Detection and Quantification of the Pulmonary Emphysema (SDEP) capable of segment automatically the images of High-Resolution Computerized Tomography (HRCT) of the lungs, allowing its better view. Also, in this study are analysed the obtained results to evaluate the efficiency of SDEP system comparing it with the Osiris 4 system, and with two segmentation algorithms. Results of the segmentation are analysed through the viewing of 102 images of 8 healthy volunteers and 141 images of 11 COPD patients. The SDEP system presents more efficient than other methods considered in this work, evaluating the correct segmentation, the over segmentation, segmentation with losses, and wrong segmentation. The proposed system accomplishes the segmentation of zone from lung densities using colorful mask, applying several colors in a single image quantifying each color per area and percentage, while the Osiris system uses only one color on each image. The SDEP system has, beside of advantage presented, a tool that accomplish the overlap of histograms, which permit a more

appropriate visual analysis of evolution of component on the emphysema. The proposed system offers to aided diagnosis, researchers, engineers, medical doctors and specialist and others of Medical Digital Image Processing field, one valid option for pulmonary emphysema analysis from HRCT images.

Key Words: COPD, Detection and Quantification of the Pulmonary Emphysema, Segmentation Medical Digital Image, Aided diagnosis.

Agradecimentos

A Deus;

Ao meu Orientado Prof. Dr. Paulo César Cortez, pela confiança depositada, paciência e orientação;

Ao meu Co-Orientador Prof. Dr. Marcelo Alcanta Holanda, pela paciência e orientação;

Aos professores e funcionários do Departamento de Engenharia de Teleinformática;

Aos meus avós;

Aos meus irmãos: Jozualdo, Jucivânia e Jucilância, pelo apoio e incentivo;

Aos meus tios, sobrinhos e demais familiares;

A Adail, Aragão, Auzuir, Colaço, Francisco, Georgia, Gustavo, João Alexandre, João Paulo, José Maria, Rodrigo, Simone, Victor;

Aos amigos e amigas;

Aos amigos e amigas do Senai de Juazeiro do Norte-CE;

Ao Laboratório de Teleinformática (LATIN/LESC);

Aos Serviços de Pneumologia e de Imagem do Hospital Universitário Walter Cantídio da Universidade Federal do Ceará;

À Fundação Cearense de Apoio ao Desenvolvimento Científico e tecnológico (FUN-CAP) pelo suporte financeiro;

A todos que colaboraram de forma direta ou indireta na elaboração deste trabalho;

Em especial a minha namorada Lucia Andrea pela atenção, apoio, carinho e incentivo.

Lista de Siglas

CAD	Diagnóstico Auxiliado por Computador (<i>Computer Aided Diagnosis</i>)
CR	Crescimento de Região
DICOM	Imagem Digital e Comunicações em Medicina (<i>Digital Imaging and Communications in Medicine</i>)
DPOC	Doença Pulmonar Obstrutiva Crônica
DPM	Densidade Pulmonar Média
MM	Morfologia Matemática
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagens
RI	Regiões de Interesse
SDEP	Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar
TC	Tomografia Computadorizada
TCAR	Tomografia Computadorizada de Alta Resolução
UH	Unidades Hounsfield
VC	Visão Computacional

Capítulo 1

Introdução

O processo de aquisição de imagens médicas teve como passo inicial a descoberta dos raios-X no final de 1885 pelo físico Wilhelm Conrad Röntgen na Universidade de Wurzburg, através de observações num experimento de raios catódicos (HENDEE; RITENOUR, 2002; STERGIOPOULOS, 2001). Outro passo importante foi realizado por Johan Radon que, em 1917, conclui o desenvolvimento da teoria matemática aplicada à tomografia. No início da década de 70 foi desenvolvida por Godfrey M. Hounsfield uma máquina de tomografia que permite computar imagens em seções cruzadas de alta qualidade, possibilitando processar um número muito grande de medidas com operações matemáticas bastante complexas, e ainda adquirir uma imagem com grande precisão (KALENDER, 2006).

Atualmente, o processo de representação de imagens médicas é utilizado nas diversas áreas da Medicina, sendo aplicado na aquisição de imagens pulmonares, cardíacas, cerebrais, arteriais, ósseas, dentre outras. Estas imagens são obtidas através de equipamentos de *doppler* colorido, Tomografias Computadorizadas (Apêndice A), ressonância magnética, ultrassonografia e medicina nuclear. Estes tipos de aquisição de imagens médicas são importantes porque tratam de métodos que contém informações relevantes sobre a imagem adquirida, permitindo inferir diagnósticos com precisão

em diversas especialidades médicas como, por exemplo, oncologia, ginecologia, pneumologia e cardiologia (SILVA, 2004).

As informações a partir de imagens médicas, são obtidas por meio de processamento computacional, realizado através de Processamento Digital de Imagem, reconhecimento de padrões, métodos estatísticos e outros. Com o advento das ferramentas computacionais, é possível melhorar a qualidade na visualização de detalhes e no processamento dos dados, promovendo assim uma grande utilização de sistemas de Visão Computacional, para aplicações como detecção, reconhecimento e classificação de objetos, estimativa de parâmetros, análise de formas e descrição de cenas (GONZALEZ; WOODS, 2002).

Os métodos de diagnósticos por imagens proporcionam enormes avanços na medicina atual, pois são baseados em técnicas computacionais que realizam a extração e análise de informações, tendo importância científica e relevância clínica. Ainda hoje, os médicos elaboram, por meio da análise visual, os diagnósticos reproduzidos em películas de filmes ou papéis especiais, portanto com grande subjetividade.

As patologias pulmonares podem ser diagnosticadas com base no conhecimento das características dos equipamentos médicos que concentram as informações dos tecidos analisados nas imagens e, de modo especial, a tomografia computadorizada, que detecta os tecidos com doenças como enfisema, bronquite crônica e outras (HOUNSFIELD, 1973; DRUMMOND, 1998).

O enfisema pulmonar é uma das principais componentes da Doença Pulmonar Obstrutiva Crônica (DPOC), que é considerada uma das mais importantes patologias que afetam os pulmões. Este pode ser mensurado através da alteração da densidade radiográfica dos pulmões, utilizando imagens adquiridas pela tomografia computadorizada (CELLI, 1998).

O enfisema pulmonar é caracterizado por um aumento anormal dos espaços alveolares com destruição das suas paredes, ou seja, os alvéolos pulmonares são destruídos e, conseqüentemente, ocorre uma dilatação anormal do espaço aéreo distal ao longo do bronquíolo terminal (HEARD et al., 1979).

Um tecido de pulmão normal é apresentado na Figura 1.1(a) e na Figura 1.1(b) é mostrado o tecido com enfisema panlobular, onde observa-se que os alvéolos estão mais dilatados do que no tecido normal. Na Subseção 3.2.1 são descritos com mais detalhes os tipos de enfisema pulmonar.

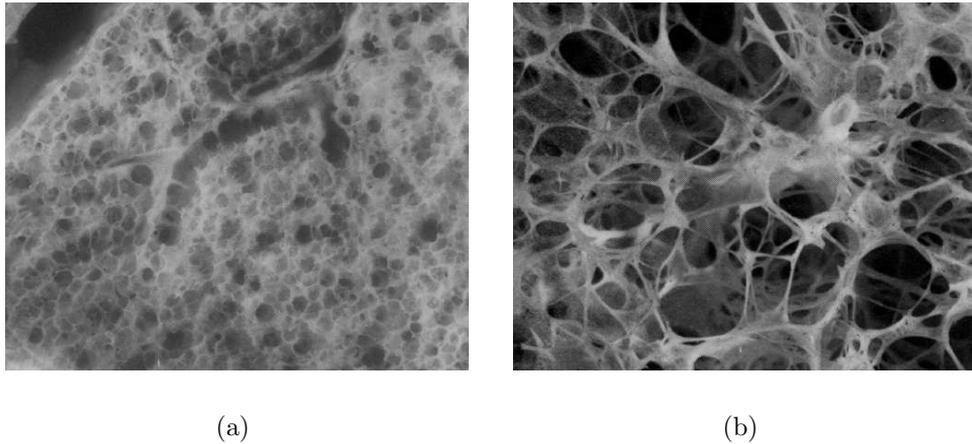


Figura 1.1: tecido de um pulmão (a) normal e (b) com enfisema panlobular (HEARD et al., 1979).

A principal vantagem da Tomografia Computadorizada (TC) é obter dados detalhados da destruição pulmonar global, bem como identificar os locais específicos onde ocorrem as destruições alveolares, permitindo identificar regiões afetadas pelo enfisema pulmonar (MADANI; KEYZER; GEVENOIS, 2001). Neste sentido, é de fundamental importância uma avaliação qualitativa e quantitativa das áreas enfisematosas, resultando em diagnósticos mais precisos, que possibilitam adotar um tratamento clínico mais adequado para cada paciente.

1.1 Motivação

A DPOC é um problema de saúde mundial com altos índices de mortalidade. O tabagismo é o principal causador desta e de outras patologias, como a coronariana,

acidente vascular encefálico, hipertensão arterial, bronquite, enfisema e câncer. Estimativa da Organização Mundial da Saúde (OMS), afirma que o número de fumantes terá um aumento de 1,2 bilhões para 1,6 bilhões entre os anos de 2000 a 2030, e as mortes em decorrência das doenças causadas pelo tabaco, passará de 4,9 milhões para 10 milhões, sendo que 70 % acontecerão nos países em desenvolvimento (SILVA; DAVID, 2004).

No Brasil, cerca de 11 milhões de pessoas com idade a partir de 40 anos são tabagistas, destas aproximadamente 10 milhões são portadores de DPOC. Em 2003, o número de óbitos chegou a 33.560, e em 2004 tiveram 191.681 internações hospitalares causadas pelo fumo. No Estado do Ceará 440.207 pessoas com idade acima de 40 anos são tabagistas, sendo que destas 400.255 são portadores de DPOC. Os óbitos em 2003 neste Estado chegaram a 588, e em 2004 foram internadas 2.816 dependentes do tabaco. Apesar da DPOC ser uma doença de âmbito mundial é, geralmente, subestimada e subdiagnosticada, levando desta forma ao subtratamento. É de fundamental importância para a saúde pública realizar e determinar os diagnósticos corretos para apresentar uma prevalência real da doença (JARDIM; OLIVEIRA; NASCIMENTO, 2006).

De acordo com The World Bank (JHA; CHALOUPIKA, 1999) o aumento de gastos públicos nos hospitais e os custos diretos e indiretos relacionados aos tratamentos com as doenças associadas ao tabagismo, nos países em desenvolvimento, consomem cerca de 6% a 15% dos custos totais aplicados na saúde, e os gastos médios com pacientes fumantes são superiores aos de pacientes não-fumantes.

Para evitar um aumento de diagnósticos incorretos dos casos patológicos, a TC deve ser melhor utilizada, já que esta constitui uma excelente ferramenta para diagnóstico precoce da componente de enfisema pulmonar na DPOC. Porém, existem limitações, como a ausência de programas (*softwares*) mais robustos que possibilitem realizar uma análise da imagem de forma quantitativa e qualitativa.

Além disso, as análises em imagens de TC na escala de cinza feitas pelos radiologistas ou médicos é subjetiva levando-os a realizarem medições imprecisas, devido à limitação da visão humana, que não consegue distinguir os tons de cinza da escala

em UH, ocasionando fadiga visual e imprecisão na leitura (NIXON; AGUADO, 2002).

Com a finalidade de atenuar os problemas citados, ou seja, análise de imagem de forma subjetiva, erros de medição, diagnósticos imprecisos e fadiga visual do radiologista ou médico, é necessário desenvolver um sistema que possibilite uma análise quantitativa e ao mesmo tempo visual do parênquima pulmonar.

1.2 Objetivos deste trabalho

O presente trabalho busca desenvolver um sistema de Visão Computacional para análise de imagens tomográficas capaz de:

- segmentar automaticamente os pulmões com precisão;
- detectar e quantificar a presença de enfisema pulmonar de modo preciso e automático;
- possibilitar uma melhor visualização da presença, tipo e distribuição de enfisema pulmonar;
- comparar as ferramentas do novo sistema proposto com o programa Osiris versão 4 e dois algoritmos de segmentação: o primeiro denominado de algoritmo SC proposto por Silva e Carvalho (SILVA; CARVALHO, 2002) e o segundo chamado de algoritmo SAB apresentado por Shojaii, Alirezaie e Babyn (SHOJAI; ALIREZAIE; BABYN, 2005).

1.3 Organização da dissertação

No Capítulo 2 são apresentados alguns conceitos básicos de Processamento Digital de Imagem: histograma, segmentação de imagens através de limiar, segmentação orientada a regiões e segmentação por pseudo-cores.

No Capítulo 3 é realizada uma revisão sobre os pulmões e as estruturas pulmonares, e também é apresentado a DPOC com as suas componentes principais, o enfisema e a bronquite crônica, bem como as técnicas utilizadas na detecção, quantificação e classificação do enfisema pulmonar.

Descreve-se no Capítulo 4 o sistema de visão computacional para detecção e quantificação de enfisema pulmonar, bem como as técnicas de Processamento de Imagem Digital utilizadas no sistema para realizar a análise da imagem através de histograma, e a segmentação das imagens pulmonares por meio de limiar fixo, adaptativo, global, segmentação orientada a região e segmentação através de pseudo-cores.

No Capítulo 5 são apresentados os resultados de detecção e quantificação de enfisema pulmonar obtidos com o sistema proposto e comparado com o programa Osiris versão 4, bem como as avaliações de dois algoritmos de segmentação: o primeiro denominado de algoritmo SC proposto por Silva e Carvalho (SILVA; CARVALHO, 2002) e o segundo chamado de algoritmo SAB apresentado por Shojaii, Alirezaie e Babyn (SHOJAI; ALIREZAIE; BABYN, 2005).

No Capítulo 6, por fim, são apresentadas as contribuições finais deste trabalho e as que podem ser desenvolvidas a partir deste.

1.4 Produção Científica

No período de desenvolvimento do projeto desta dissertação, foram produzidos e publicados artigos em congressos nacionais, internacionais e periódicos. São os seguintes os artigos publicados:

- **FELIX, J.H.S.**; CORTEZ, P.C.; HOLANDA, M.A.; COSTA, R.C.S. Automatic Segmentation and Measurement of the Lungs in healthy persons and in patients with Chronic Obstructive Pulmonary Disease in CT Images. CLAIB 2007, IFMBE Proceedings 18, p.370-373, 2007.
- **FELIX, J. H. S.**; CORTEZ, P. C.; HOLANDA, M. A.; ALBUQUERQUE,

V. H. C.; COLAÇO D. F.; ALEXANDRIA, A. R. Lung and Chest Wall Structures Segmentation in CT Images. In: Proceedings of VIPIMAGE, 2007, Porto. Computational Vision and Medical Image Processing. London: Taylor & Francis Group, p. 291-294, 2007.

- **FELIX, J. H. S.**; CORTEZ, P. C.; HOLANDA, M. A.; COLAÇO D. F. Segmentação Automática dos Pulmões Através de Crescimento de Região Aplicando em Imagens de TC. VII encontro de Pesquisa e Pós-Graduação do CEFET, 2007.

Capítulo 2

Conceitos Básicos de Processamento Digital de Imagem

Os métodos de processamento digital de imagens possuem sua base de interesse em duas principais áreas de aplicação: melhoramento da informação visual para a interpretação humana e processamento de dados de imagens para armazenamento, transmissão, e representação para percepção de máquinas autônomas.

A primeira área concentra-se em técnicas de ajuste de contraste, realce e restauração de imagens degradadas. A segunda área concentra-se em procedimentos para identificar e extrair de uma imagem informação de interesse da forma mais adequada, para o reconhecimento de padrões, seja através de formas e/ou medidas (GONZALEZ; WOODS, 2002).

Desta forma, neste Capítulo é apresentado uma descrição de um típico sistema de Visão Computacional, bem como é realizada uma revisão de alguns conceitos de Processamento Digital de Imagem (PDI), que são utilizadas no desenvolvimento do sistema proposto.

2.1 Descrição de um típico sistema de visão computacional

Um sistema de Visão computacional é constituído por processos capazes de adquirir, processar e interpretar imagens correspondentes de cenas, obtidas de ambientes reais. Constituído por processos como aquisição de imagens, pré-processamento, segmentação, extração de atributos, reconhecimento e interpretação (FILHO; NETO, 1999), como é apresentado na Figura 2.1.



Figura 2.1: sistema típico de Visão Computacional.

Seguindo o fluxo de informação presente num sistema típico de Visão computacional, cada bloco deste fluxo é descrito a seguir (FACON, 1996; GONZALEZ; WOODS, 2002).

- **Aquisição:** neste processo tem que ser dada bastante atenção às condições de iluminação, preparação da imagem, ajuste e aferição dos dispositivos de aquisição; as imagens podem ser adquiridas através de câmeras de vídeos, máquina fotográfica digital, *scanner*, dentre outros. Já na aquisição de imagens médicas são utilizados equipamentos de raios-X, *doppler* colorido, tomografias computadorizadas, ressonância magnética, ultrassonografia, medicina nuclear e outros.
- **Pré-processamento:** tem a finalidade de melhorar as características relevantes na imagem, ou seja, minimizar ou extrair a presença de ruídos, introduzidos no processo de aquisição. O pré-processamento é realizado através de técnicas de filtragem de ruído, realce e reconstrução de imagem, dentre outras.

- **Segmentação:** a segmentação de imagens é um processo complexo e difícil de ser realizado, sendo de fundamental importância em qualquer sistema de Visão Computacional, de tal forma que o desempenho do sistema depende essencialmente do desempenho do processo de segmentação. A técnica de segmentação a ser utilizada varia com as características de aplicação do sistema; a segmentação pode ser realizada através da detecção de descontinuidades e/ou similaridades de áreas ou regiões da imagem. Existem várias técnicas de segmentação como: limiarização, segmentações baseadas em regiões, segmentação através de morfologia matemática, *watershed*, *wavelet*, contorno ativos e outras.
- **Extração de atributos:** este processo tem por finalidade agrupar as informações com características semelhantes em áreas distintas, ou seja, identificar os atributos ou feições que melhor representem as características desejadas dos objetos segmentados. Para, desta forma, facilitar a execução do próximo processo. Na extração dos atributos podem ser utilizadas técnicas como: código de cadeia, aproximação poligonal, descritores de Fourier, descritores regionais, medidas de texturas, dentre outros.
- **Reconhecimento e interpretação:** o reconhecimento consiste em rotular os objetos que foram identificadas algumas feições ou atributos no processo anterior. Estes objetos, são então identificados para um grupo ou classe, à qual aquele novo rótulo pertence, de acordo com informações *a priori* do objeto que se busca. Neste processo podem ser utilizadas: técnicas de Reconhecimento de Padrões, Estatísticas, Inteligência Artificial, dentre outras.

2.2 Histograma de imagem

O histograma $h(n_c)$ de uma imagem $g(x, y)$ é um gráfico de frequência do número de ocorrência (n_o) de cada nível de cinza da imagem (BOVIK, 2000), de acordo com a equação

$$h(n_c) = n_o, \quad (2.1)$$

em que n_c representa o nível de cinza do *pixel* e n_o o número da ocorrência dos pixels.

No histograma os níveis de cinza se encontram nas abcissas (imagens de 8 *bits* de 0 a 255) e nas ordenadas a quantidade de *pixels* de cada nível de cinza ou o percentual destes em relação ao total de *pixels* da imagem (GONZALEZ; WOODS, 2002).

O histograma normalizado (h_n) é dado pela equação

$$h_n = \frac{n_o}{n_t}, \quad (2.2)$$

em que n_t é o número total de pixels da imagem $g(x, y)$ (GONZALEZ; WOODS, 2002).

O histograma fornece uma descrição global dos níveis de cinza da imagem. Este pode assumir a forma unimodal, caso a imagem apresente um único objeto. Pode também ser bimodal, quando a imagem é constituída de duas regiões (objeto e fundo), ou ainda multimodal quando se tem vários objetos na imagem.

De forma geral, a cena contém vários objetos distintos. Desta forma, o histograma fornece nesse casos uma soma ponderada das probabilidades condicionais (FACON, 1996). Na Figura 2.2(a) é apresentado a imagem dos pulmões, e na Figura 2.2(b) é mostrado o seu respectivo histograma bimodal, que apresenta dois picos de informações. No caso de um histograma unimodal, este mostra apenas um pico de informação.

2.3 Técnicas de segmentação de imagens

A segmentação é um importante processo utilizado para separar diferentes objetos da imagem, com características semelhantes. Imagens com regiões disjuntas, podem ser caracterizadas individualmente como áreas com semelhanças de níveis de cinza, textura ou outra característica de interesse para uma dada aplicação. Desta forma, a segmentação consiste em rotular cada *pixel* da imagem, para assim, identificar a

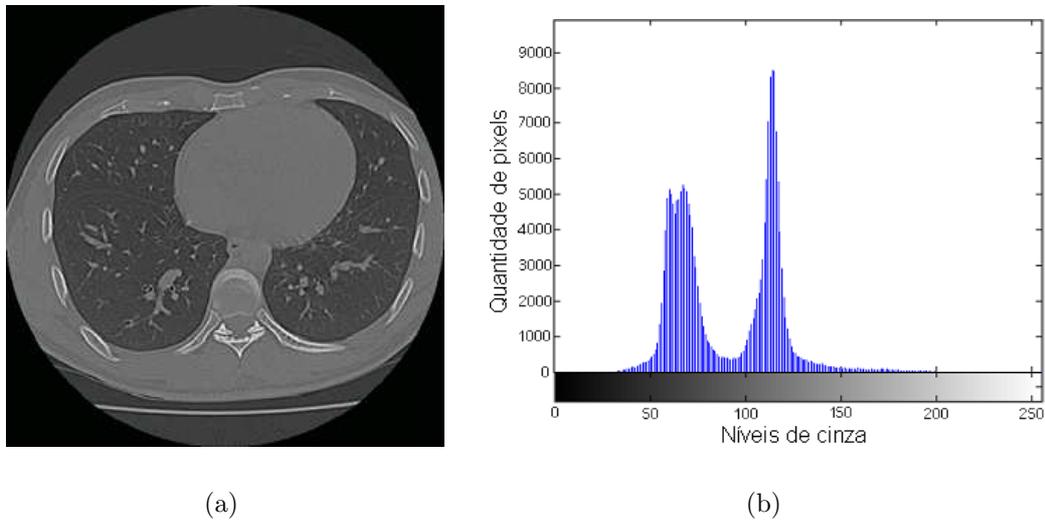


Figura 2.2: imagem dos pulmões (a) original e (b) seu histograma.

qual região ele pertence, de acordo com suas propriedades (ALEXANDRIA, 2005). O processo de segmentação está presente, em geral, em todos os sistemas de Visão Computacional, sendo que a limiarização é um método bastante utilizado.

2.3.1 Limiarização com limiar fixo

A limiarização é uma técnica de segmentação simples, que geralmente é aplicada em imagens que apresentam o histograma bimodal. Tem grande aplicação na separação das Regiões de Interesse (RI) como, por exemplo, um objeto presente em uma imagem e o fundo. Para este caso, o valor do limiar L é um nível de cinza para o qual *pixels* de intensidade luminosa maior do que L pertencem à RI e os demais pertencem ao fundo (ALEXANDRIA, 2005).

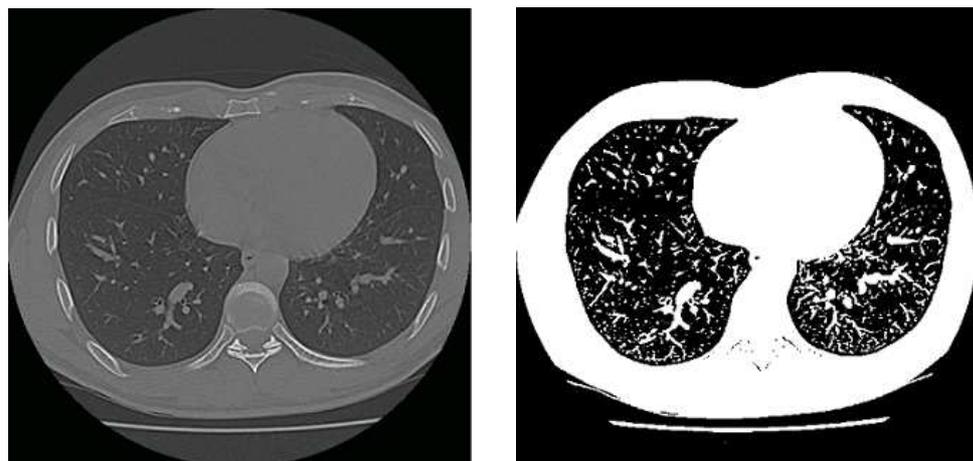
A operação de binarização por limiar fixo de uma imagem $g(x,y)$ é definida pela equação (GONZALEZ; WOODS, 2002)

$$g(x,y) = \begin{cases} 1, & \text{se } f(x,y) > L, \\ 0, & \text{caso contrário,} \end{cases} \quad (2.3)$$

em que L é o valor escolhido de limiar.

O objetivo da limiarização é realçar conjuntos de *pixels* de determinada RI de uma imagem que ocupam a mesma faixa de níveis de cinza. Estas faixas de *pixel* correspondem normalmente aos objetos de interesse, permitindo que a limiarização seja utilizada para efetuar um realce de um objeto em relação ao fundo. A limiarização quando aplicada para separar apenas duas regiões, como expresso pela equação (2.3), é denominada de binarização por limiar.

Uma imagem de TC dos pulmões quantizada em Unidades Hounsfield (UH), escala desenvolvida por Godfrey M. Hounsfield (Apêndice A) é apresentada na Figura 2.3(a), enquanto que na Figura 2.3(b) é ilustrado o resultado da aplicação do limiar de -650 UH, expresso pela equação (2.3), produzindo uma imagem binária.



(a)

(b)

Figura 2.3: aplicação do limiar fixo de -650 UH na imagem dos pulmões (a) original e (b) binarizada.

2.3.2 Limiarização global, local e dinâmica

A limiarização, de acordo com Gonzalez e Woods (GONZALEZ; WOODS, 2002) é uma operação que envolve testes sobre uma função na forma

$$L = l[x, y, p(x, y), f(x, y)], \quad (2.4)$$

em que $f(x, y)$ é o nível de cinza do ponto (x, y) e $p(x, y)$ denota propriedades da imagem na vizinhança deste ponto. Na equação (2.4), quando l depende somente de $f(x, y)$ o limiar é chamado global. Quando l depende tanto de $f(x, y)$ como de $p(x, y)$, então o limiar é local. Quando l depende somente das coordenadas x e y , o limiar é chamado de dinâmico. Algoritmos de limiar global definem um valor de limiar aplicado em toda a imagem, enquanto algoritmos de limiar local aplicam um limiar para cada RI da imagem.

2.3.3 Segmentação orientada a região

A segmentação orientada a região consiste na separação de RI de uma imagem, utilizando-se de atributos de cada uma delas. Dentre os algoritmos de segmentação orientados à região pode-se citar dois: crescimento de região e “divisão e fusão” (GONZALEZ; WOODS, 2002).

2.3.3.1 Crescimento de região

O Crescimento de Região (CR) é uma técnica aplicada a imagens para unir as RI. A técnica de CR realiza o agrupamento de subgrupos ou grupos de *pixels* em uma região desejada.

A agregação das regiões é determinada pela escolha de uma semente na região em análise como, por exemplo, um *pixel* que pertença a esta região e que tenha direção e sentido definidos e características semelhantes às do objeto desejado. Estas características são obtidas, normalmente, por parâmetros de intensidade, média do

local, variância local, entre outros (JAN, 2006).

O CR pode ser realizado através de técnicas locais, em que uma semente (*pixel*) é escolhida dentro da RI. Para as técnicas globais, mais de uma semente é distribuída por várias áreas de uma mesma imagem. Já na técnica de divisão e fusão, as regiões podem ser divididas ou fundidas usando gráficos estruturados (BALLARD; BROWN, 1982).

Na aplicação do algoritmo de CR, inicialmente determina-se uma RI na qual se deseja realizar a análise, sendo que esta pode ser subdividida em n regiões R_1, R_2, \dots, R_n , (BALLARD; BROWN, 1982; GONZALEZ; WOODS, 2002).

A seguir são descritos os passos para a aplicação do algoritmo de CR:

$$R = \bigcup_{i=1}^n R_i \quad (2.5)$$

$$R_i \text{ é uma região conectada para } i = 1, 2, \dots, n. \quad (2.6)$$

$$R_i \cap R_j = \emptyset \text{ para todo } i = 1, 2, \dots, n, \quad (2.7)$$

$$P(R_i) = \text{Verdadeiro para } i = 1, 2, \dots, n, \quad (2.8)$$

$$P(R_i \cup R_j) = \text{Falso para } i \neq j \quad (2.9)$$

O predicado $P(R_i)$ é uma definição lógica sobre um conjunto de pontos R_i e o conjunto vazio é \emptyset .

A equação (2.5) indica que a segmentação precisa ser completa. Na equação (2.6) os pontos tem que ser previamente conectados com algum ponto já definido. A aplicação da equação (2.7) é necessário para separar a região analisada. A região precisa satisfazer a condição na equação (2.8) para ser segmentada e a equação (2.9) indica que a região R_i e R_j são diferentes no sentido do predicado $P(R_i)$.

2.3.4 Segmentação através da transformada de *watershed*

O conceito de *watershed* é baseado na visualização de uma imagem 3D, em que as coordenadas de uma imagem $g(x, y)$ e a intensidade do nível de cinza são interpretados como uma imagem topográfica. São considerados três pontos para sua interpretação: os pontos (pixels) que pertencem a um mínimo regional; os pontos em que uma gota de água, se colocado no local de quaisquer desses pontos, cairia com certeza para um único mínimo, chamado de represa; e pontos de divisores de água (*watershed*) nos quais é igualmente provável que a água caia, mais não se consegue determinar qual o seu mínimo (GONZALEZ; WOODS, 2002).

Fazendo uma analogia da imagem com um ambiente topográfico, tem-se os níveis de cinza claro da imagem correspondente aos picos de uma montanha e os níveis de cinza escuros da imagem referentes aos vales. Os picos são locais de máximo gradiente na imagem. Existem duas aproximações algorítmicas básicas utilizadas para computar a *watershed* de uma imagem: a chuva e a inundação (PRATT, 2001).

Na aproximação por chuva, são achados mínimos locais ao longo da imagem. Para cada mínimo local é determinado uma única etiqueta (rótulo). Os mínimos locais mais próximos são combinados com uma única etiqueta. Desta forma, as gotas movem-se por sua vizinhança de baixo valor de intensidade dos pixels, assumindo o valor da etiqueta com características semelhantes (PRATT, 2001).

Já na aproximação por inundação, um buraco é perfurado em cada mínimo regional e toda a topografia da imagem é inundada, com a elevação da água nos buracos a uma taxa uniforme. Quando a água em bacias ou reservatórios de captação distintos estiverem a ponto de se fundirem, uma represa é construída para prevenir a fusão, conforme é apresentada na Figura 2.4. A inundação alcançará a sua fase final quando só os topos das represas forem visíveis sobre a água. Estes limites das represas correspondem às linhas da transformada de *watershed* bacias (GONZALEZ; WOODS, 2002; PRATT, 2001). Na Figura 2.5 são apresentados os mínimos locais, as bacias e as linhas das *watersheds* da aproximação por inundação.

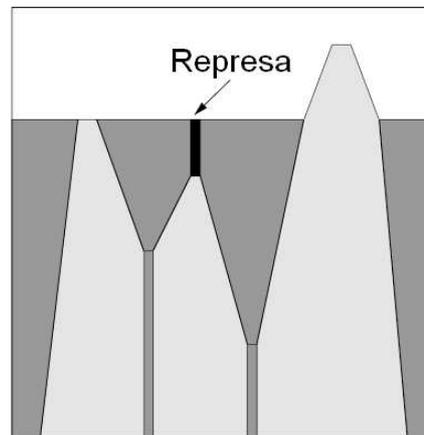


Figura 2.4: perfil de inundação das bacias de captação com a represa (PRATT, 2001).

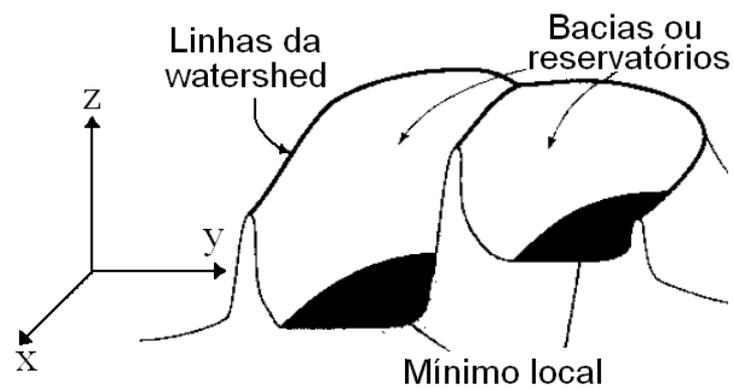


Figura 2.5: representação de uma watershed (VINCENTE; SOILLE, 1991).

2.3.4.1 Algoritmo de segmentação de *watershed*

O algoritmo de segmentação de *watershed* é descrito a seguir (GONZALEZ; WOODS, 2002):

Os conjuntos de mínimos (min) e máximos (max) regionais de uma imagem $g(x,y)$ são definidos M_1, M_2, \dots, M_R . A bacia de captação associada a mínimos regionais M é denominada de $BC(M_i)$. Os pontos, na bacia de captação, que possuem altitude menor ou igual a n são chamados de $T(n)$ com coordenadas (s, t) para que $g(s, t) < n$:

$$T(n) = \{(s, t) | g(s, t) < n\}. \quad (2.10)$$

A topografia da imagem pode ser inundada por incrementos inteiros, de $n = \min + 1$ para $n = \max + 1$. Em todo passo n do processo de inundação, o algoritmo precisa conhecer o número de pontos abaixo da profundidade de inundação. Supondo que todas as coordenadas no ponto $T(n)$ e que estão abaixo do plano $g(x, y) = n$, são marcados de preto, e todas as outras coordenadas são marcadas de branco.

Já $BC(n)$ é o subconjunto de todas as bacias de captação que possuem um valor menor ou igual a n :

$$BC(n) = \bigcup_{i=1}^R BC_n(M_i), \quad (2.11)$$

então $BC(\max + 1)$ é a união de todos os subconjuntos das bacias de captação dada por

$$BC(\max + 1) = \bigcup_{i=1}^R BC(M_i), \quad (2.12)$$

em que $BC_n(M_i)$ é o conjunto de pontos das coordenadas das bacias de captação associadas com um mínimo M_i que são inundadas no estágio n , podendo ser vista como uma imagem binária dada por

$$BC_n(M_i) = BC(M_i) \cap T(n), \quad (2.13)$$

em que $BC(M_i) = 1$ na posição (x, y) se $(x, y) \in BC(M_i)$ AND (operação de intersecção) $(x, y) \in T(n)$.

2.3.4.2 Marcadores

Os marcadores são componentes conectados na imagem, sendo aplicados com a finalidade de evitar a sobre-segmentação pela transformada de *watershed*, geralmente causada por ruído e outras irregularidades locais do gradiente. Existem dois tipos de marcadores: os marcadores internos, que estão associados com o objeto de interesse e os marcadores externos, associados com o fundo da imagem.

Um exemplo do uso de marcadores, aplicado na imagem de um eletroforese é apresentado na Figura 2.6. Na Figura 2.6(a) é mostrada a imagem original de eletroforese. Uma segmentação frustrada, em que é aplicado somente a transformada de *watershed*, causando uma sobre-segmentação, ou seja, gerando várias linhas da watershed, como é ilustrada na Figura 2.6(b).

Os marcadores internos, ou seja, região de bolhas (cor branca), que representam o nível de cinza mais alto, são mostrados na Figura 2.6(c). Os marcadores foram obtidos através da suavização da imagem. Já na Figura 2.6(c) são apresentados os marcadores externos adquiridos através da transformada de *watershed*, representados pelas linhas da *watershed*.

O resultado da segmentação é obtido fazendo uma suavização do gradiente da imagem, e restringindo o algoritmo de *watershed* para operar em uma única bacia de captação que contenha os marcadores, de acordo com a Figura 2.6(d).

2.3.5 Morfologia Matemática

A Morfologia Matemática (MM) teve a sua pesquisa iniciada na França em meados de 1964 na Escola Nacional de Minas de Paris com Matheron (MATHERON, 1975) e Jean Serra (SERRA, 1982). A idéia deles era de experimentar uma abordagem singular para resolver problemas de análise de imagens: extrair informação de imagens a partir

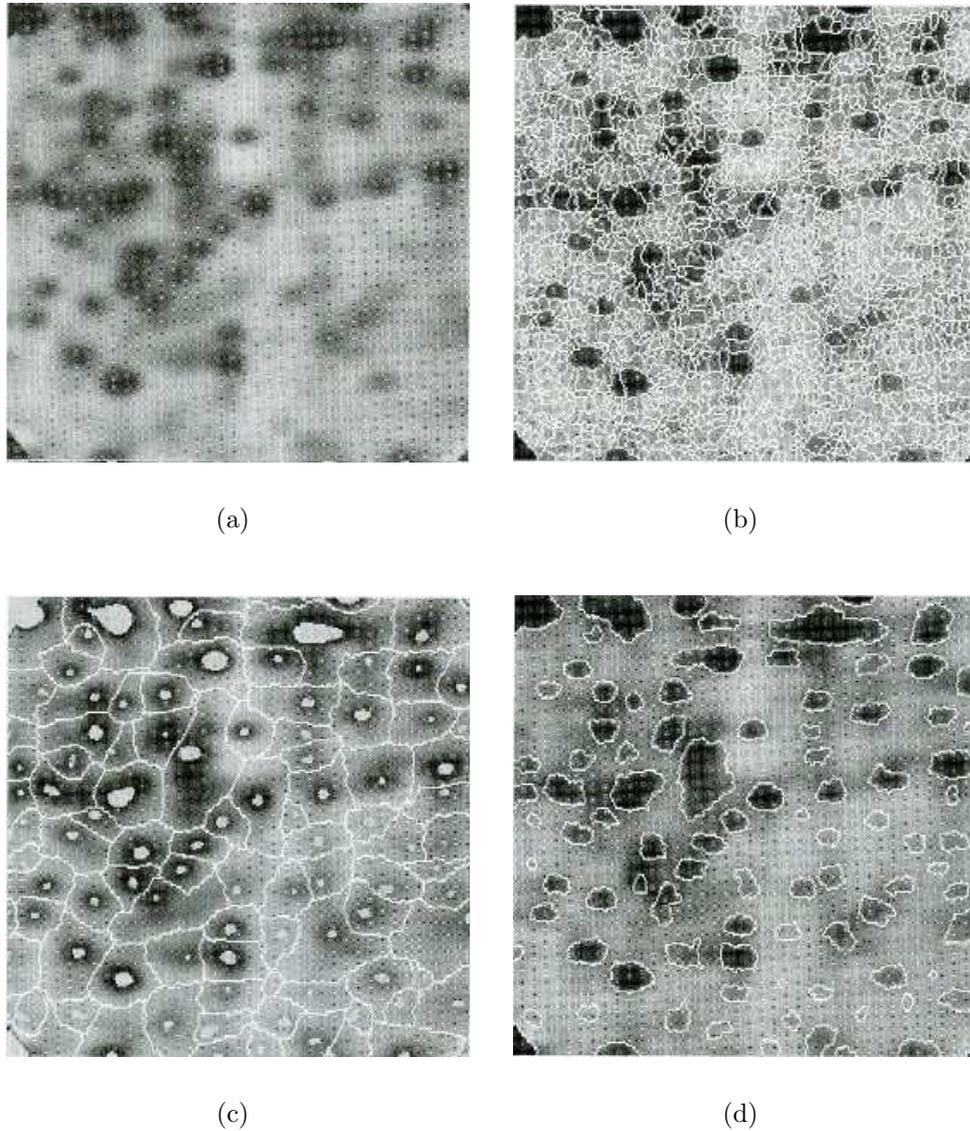


Figura 2.6: segmentação de *watershed* com o uso de marcadores (a) imagem de eletroforese, (b) sobre-segmentação com o uso da *watershed*, (c) marcadores internos (região de alta intensidade dos níveis de cinza) e marcadores externos (linha da *watershed*) e (d) resultado da segmentação (GONZALEZ; WOODS, 2002).

de transformações de formas (BANON; BARRERA, 1998).

A MM define alguns operadores morfológicos básicos: dilatação, erosão, anti-dilatação e anti-erosão. A partir destes são realizados estudos de decomposição de operadores entre reticulados (BANON; BARRERA, 1998).

A transformação morfológica consiste em aplicar um elemento estruturante sobre a imagem em análise. Este elemento é uma máscara planar que pode assumir diferentes formas geométricas, como, por exemplo, círculo, quadrado, retângulo, triângulo, hexágono, cruz, ponto e outros polígonos (FACON, 1996; GONZALEZ; WOODS, 2002).

2.3.5.1 Erosão e Dilatação

Sejam A e B conjuntos não-vazios, sendo que A representa a imagem em análise e B o elemento estruturante. Define-se matematicamente a erosão binária para os conjuntos A e B ($A \ominus B$) em Z^2 por

$$(A \ominus B) = \{z | (B)_z \subseteq A\}, \quad (2.14)$$

em que a erosão de A por B é um conjunto de todos os pontos em z tal que $((B)_z)$, transladado por z , esteja contido em A , sendo esta caracterizada pela redução da imagem analisada, e dilatação binária para os conjuntos A e B ($A \oplus B$) em Z^2 por

$$(A \oplus B) = \{z | [(\hat{B})_z \cap A] \subseteq A\}, \quad (2.15)$$

em que $(\hat{B})_z$ é a reflexão de B sobre a sua origem e transladado por z , na qual resulta na expansão da imagem analisada (GONZALEZ; WOODS, 2002).

Os operadores morfológicos dilatação e erosão, aplicados alternadamente numa imagem evidenciam melhor as características desta, pois, permitem construir funções importantes como, por exemplo, gradiente morfológico, abertura, fechamento, entre outras.

2.3.5.2 Abertura e Fechamento

A abertura binária de um conjunto A por B é definida pela erosão de A por B , seguida da dilatação deste resultado por B , denotada por

$$(A \circ B) = (A \ominus B) \oplus B, \quad (2.16)$$

causando o efeito de suavização no contorno, eliminando pequenas protuberâncias (GONZALEZ; WOODS, 2002).

Invertendo-se a ordem das operações que definem a abertura, ou seja, dilatação de A por B , seguida da erosão do resultado por B , produz-se a operação de fechamento, expressa por

$$(A \bullet B) = (A \oplus B) \ominus B, \quad (2.17)$$

resultando no preenchimento de pequenos buracos e/ou lacunas no contorno da imagem analisada (GONZALEZ; WOODS, 2002).

2.3.5.3 Afinamento

O afinamento de um conjunto A por um elemento estruturante B , denotado de $A \otimes B$, pode ser definida em termos da operação toca-não-toca (hit-or-miss):

$$A \otimes B = A - (A \circledast B) = A \cap (A \circledast B)^c, \quad (2.18)$$

em que o símbolo \circledast denota a operação de toca-não-toca. A expressão mais usual para o afinamento de A simetricamente é baseada numa seqüência de elementos estruturantes (GONZALEZ; WOODS, 2002):

$$\{B\} = \{B^1, B^2, B^3, \dots, B^n\}, \quad (2.19)$$

em que B^i é a versão rotacionada de B^{i-1} . Usando este conceito o afinamento é definido por uma seqüência de elementos estruturantes como

$$A \otimes \{B\} = (((A \otimes B^1) \otimes B^2) \dots) \otimes B^n. \quad (2.20)$$

Este processo consiste em afinar A passando B^1 , o resultado é passado com B^2 e assim por diante, até afinar A com o passo de B^n (GONZALEZ; WOODS, 2002).

2.3.6 Segmentação por Pseudo-Cores

O processamento de imagens através de pseudo-cores (cores falsas), consiste nas rotulações dos níveis de cinza para as cores de interesse, cujo objetivo é permitir que a visualização humana reconheça determinadas áreas e/ou detalhes nas imagens, o que é difícil em vários casos quando se utiliza escala em níveis de cinza (GONZALEZ; WOODS, 2002). Este é o caso das imagens obtidas com a TC e a Tomografia Computadorizada de Alta Resolução (TCAR) (Apêndice A).

Um dos métodos aplicados com pseudo-cores é denominado de fatiamento da intensidade ou densidade, podendo ser visto como um deslocamento de planos paralelos montados sobre as coordenadas da imagem. Considerando a imagem num plano tridimensional, como é apresentado na Figura 2.7, um plano de fatiamento usa a função $f(x, y) = l_i$, em que l_i corresponde aos vários planos de fatiamento (GONZALEZ; WOODS, 2002).

Então, para colorir determinada intensidade de um nível de cinza, aplica-se a seguinte relação:

$$f(x, y) = c_i \quad \text{se } f(x, y) \in V_i, \quad (2.21)$$

em que c_i é a cor associada com o i -ésimo intervalo de intensidade dos níveis de cinza V_i , definidos através dos planos de fatiamentos em $l = i - 1$ e $l = i$.

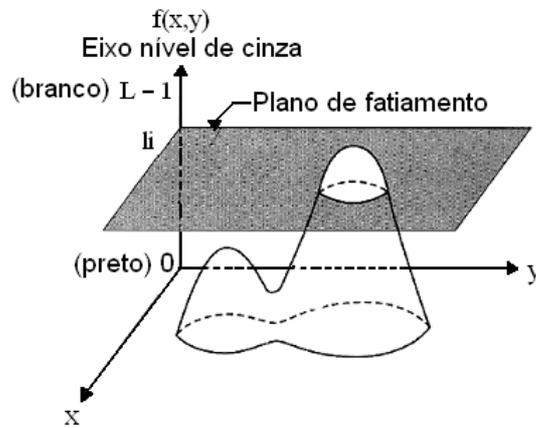


Figura 2.7: interpretação geométrica da técnica de fatiamento de densidade (GONZALEZ; WOODS, 2002).

2.3.7 Medidas aplicadas aos pulmões

As medidas são importante para quantificar determinados objetos de diferentes formas, principalmente na área médica, pois, as medidas estão ligadas aos diagnósticos mais detalhados.

2.3.7.1 Medidas de perímetro, área e volume

O perímetro de um objeto contido numa imagem é a soma dos pixels na borda do objeto, contados a partir de um pixel escolhido arbitrariamente, que também finaliza a contagem. A área de cada objeto na imagem é a contagem dos números de pixels no interior daquele objeto. Então, o perímetro (P) e a área (A) são dados por

$$P = \sum_{x=1}^N \sum_{y=1}^M b(x, y), \quad (2.22)$$

$$A = \sum_{x=1}^N \sum_{y=1}^M r(x, y), \quad (2.23)$$

onde N e M são as dimensões da imagem, $r(x, y) = 1$ corresponde ao objeto, $b(x, y) = 1$ ao contorno do objeto e (x, y) as coordenadas dos pixels na imagem (PRATT, 2001; ARAÚJO, 2004).

O volume da imagem é calculada multiplicado o resultado da área pelo valor da espessura da seção (fatia) da imagem tomográfica, sabendo que a imagem obtida com uma TC apresenta uma medida uniforme para a seção da imagem adquirida. Então o volume é calculado por

$$V = A \cdot Esp, \quad (2.24)$$

em que A é a área do objeto e Esp é o valor da espessura da seção.

2.3.7.2 Medidas de densidade pulmonar média (DPM) e quinze pontos percentuais (Perc15)

A Densidade Pulmonar Média (DPM) pode ser considerada uma medida primeira ordem calculadas a partir do histograma.

As medidas de primeira ordem são computadas a partir de um histograma da imagem, que consiste em computar a frequência de ocorrência de certas intensidades na imagem.

A medida de primeira ordem calculada para os valores de níveis de cinza da imagem é chamada de média (HARALICK, 1972; PRATT, 2001). Já para uma imagem de tomografia os níveis de cinza são equiparados aos valores de atenuação dos raios-X, medidos em Unidades Hounsfield (UH) (Apêndice A).

Então a DPM é dada em termos da média por

$$DPM = M = \sum_{d=i}^N d \cdot h(d), \quad (2.25)$$

em que N é o número de níveis de cinza da imagem (número de intensidade em UH); d é a intensidade do pixel, $h(d)$ é a frequência de ocorrência da intensidade d em UH

e i é o valor inicial de intensidade em UH.

Os quinze pontos percentuais (Perc15) é uma medida obtida a partir do cálculo do histograma acumulado de intensidade em UH. O Perc15 é definido como o valor de limiar para o qual 15% de todos os pixels tem uma baixa densidade, ou seja, valores abaixo de -950 (STOEL; STOLK, 2004).

O Perc15 é computado realizando uma varredura no histograma acumulado, até o valor de 15%. Desta forma, é selecionada a densidade referente a posição dos 15%. Na Figura 2.8 é apresentada um típico histograma dos pulmões (na esquerda) e o seu típico histograma acumulado (na direita), ilustrando a seleção do Perc15.

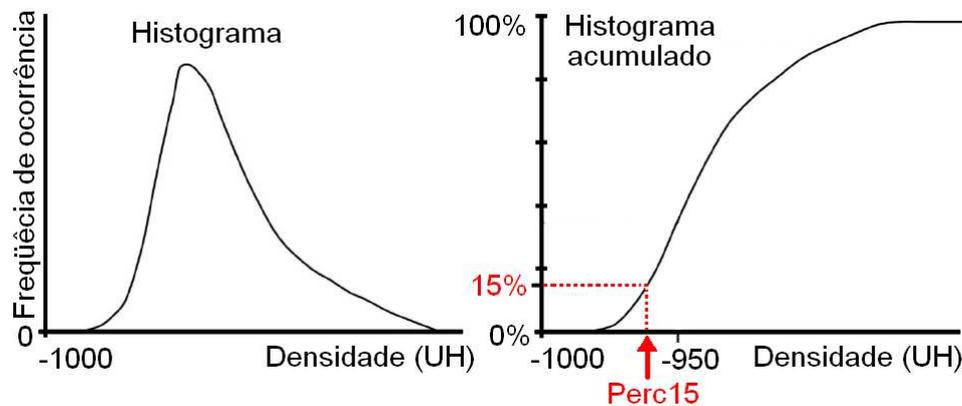


Figura 2.8: típico histograma dos pulmões (na esquerda) e o histograma acumulado (na direita), adaptada de (STOEL; STOLK, 2004).

2.4 Conclusão do Capítulo

Neste Capítulo é apresentado uma descrição de um típico sistema Visão Computacional e de algumas técnicas de PDI como histograma, segmentação de imagens através de limiar, segmentação orientada a regiões e por pseudo-cores. No Capítulo 3 é realizado uma revisão sobre as técnicas de PDI aplicadas nas imagens de tomografia dos pulmões, bem como na detecção e quantificação do enfisema pulmonar.

Capítulo 3

Técnicas de Segmentação Aplicadas aos Pulmões

A Tomografia Computadorizada (TC) se constitui em uma excelente ferramenta de diagnóstico, tendo em vista suas características de quantificação das densidades radiográficas do órgão e/ou tecido analisado (Apêndice A). Para uma melhor análise de determinadas estruturas pulmonares e até para realizar suas medições de área, perímetro e volume, é necessário aplicar as técnicas de segmentação às imagens dos pulmões. Assim são apresentadas diversas técnicas de segmentação da literatura, cuja finalidade é separar os pulmões e suas estruturas.

3.1 Segmentação pulmonar e de suas estruturas

Uma das etapas mais importantes em um sistema de Visão Computacional (VC) consiste na segmentação dos objetos de interesse contidos na cena em estudo. Por esta razão, são apresentadas nas próximas seções várias técnicas de segmentação, detecção e quantificação, aplicadas em pulmões e nas principais componentes da DPOC, iniciando-se pela segmentação dos pulmões.

3.1.1 Segmentação dos pulmões

Diversas técnicas de PDI são aplicadas para realizar a segmentação pulmonar. Dentre estas, apresenta-se o trabalho de Hu, Hoffman e Reinhardt (HU; HOFFMAN; REINHARDT, 2001) que utilizam um método automático para medir o volume pulmonar, através de técnicas de limiarização e operações morfológicas de erosão e dilatação.

Com o mesmo objetivo, e usando uma idéia semelhante Silva *et al.* (SILVA; CARVALHO, 2002) realizam a extração dos contornos pulmonares por meio de técnicas de limiarização: Usam a transformada de Radon no sentido vertical e horizontal, para obter o centro de massa dos pulmões esquerdo e direito, seguida de operações morfológicas. Já Brown, McNitt-Gray e Mankovich (BROWN; MCNITT-GRAY; MANKOVICH, 1997), utilizam as informações armazenadas no modelo anatômico para constituir as regras da lógica nebulosa, para fazer a segmentação dos pulmões e de suas estruturas. Nesse trabalho, os autores aplicam uma combinação de limiarização, crescimento de região em 3D e Morfologia Matemática para segmentar os pulmões.

Sistemas de diagnóstico auxiliado por computador (CAD - *Computer Aided Diagnosis*) utilizam combinações de técnicas de PDI para realizar automaticamente a segmentação e análise de imagens de TC. Vários trabalhos presentes na literatura utilizam sistemas CAD, sendo, portanto, bastante populares (KHAWAJA; AZIZ; IQBAL, 2004; ANTONELLI; LAZZERINI; MARCELLONI, 2005; GARNAVI *et al.*, 2005; SLUIMER; PROKOP; GINNEKEN, 2005; CHEN *et al.*, 2006).

Sluimer (SLUIMER, 2005) apresenta em sua tese, além da técnica de crescimento de região automático, o algoritmo de agrupamento que faz a fusão de dois grupos, se a aptidão exceder a média dos grupos combinados. Neste caso, a aptidão é dada pelas medidas de tamanho da região, textura e densidade.

Já Silva e Carvalho (SILVA; CARVALHO, 2002) realizam a segmentação pulmonar através da técnica de binarização da imagem, operações morfológicas de abertura e fechamento, detecção de bordas, afinamento e exclusões das estruturas não conectadas

e as conectadas com valores de área de até 300 *pixels*. Nesse trabalho, é aplicada a técnica de *rolling-ball* para reconstruir o parênquima pulmonar. Shojaii, Alirezaie e Babyn (SHOJAII; ALIREZAIE; BABYN, 2005) utilizam uma técnica bastante semelhante à técnica apresentada por Silva e Carvalho (SILVA; CARVALHO, 2002). A principal diferença, entre estes dois trabalhos está na adição da transformada de *watershed* na técnica apresentada por Shojaii, Alirezaie e Babyn (SHOJAII; ALIREZAIE; BABYN, 2005).

Itai *et al.* (ITAI *et al.*, 2005) aplicam, na segmentação dos pulmões, os modelos de contornos ativos paramétrico (*snakes*), sendo as curvas deste definidas dentro de um domínio da imagem. Estas curvas são movimentadas pela ação de forças internas e externas para se conformar na área de interesse. Seguindo este contexto, Silva (SILVA, 2005) utiliza na segmentação pulmonar, além dos contornos ativos paramétrico, os modelos de contornos ativos geométricos. Este se baseiam nas características geométricas (como formas) para realizarem suas evoluções.

Os resultados apresentados por Hu, Hoffman e Reinhardt (HU; HOFFMAN; REINHARDT, 2001) somente são satisfatórios devido ao baixo contraste das imagens utilizadas. Isto já que a limiarização utilizada não consegue separar completamente os pulmões do fundo da imagem, quando aplicado em imagem de TC de alto contraste.

A extração automática dos contornos pulmonares proposta por Silva *et al.* (SILVA *et al.*, 2001) apresenta resultados imprecisos. Tendo em vista que uma das finalidades das operações morfológicas no seu trabalho é separar os pulmões que estão conectados, é gerada, desta forma, uma separação com perda na parte da borda pulmonar conectada.

Brown, McNitt-Gray e Mankovich (BROWN; MCNITT-GRAY; MANKOVICH, 1997) ao invés de utilizarem a técnica de limiarização para rotular uma região e as demais com o crescimento de região, deveriam aplicar apenas o crescimento de região na rotulação de todas as regiões, pois, desta forma, o tempo de processamento pode ser diminuído.

Os algoritmos de segmentação propostos por Silva e Carvalho (SILVA; CARVALHO,

2002) e Shojaii, Alirezaie Babyn (SHOJAI; ALIREZAIE; BABYN, 2005) apresentam falhas na segmentação das imagens cujas paredes da cavidade pulmonar e do hilo, estão próximas e com pouca espessura, sendo então eliminadas quando é aplicada a operação de abertura. Conseqüentemente as bordas pulmonares não são identificadas através da operação de detecção de bordas.

As técnicas de segmentação pulmonar apresentadas por Itai *et al.* (ITAI *et al.*, 2005) e Silva (SILVA, 2005) mostram resultados semelhantes ao crescimento de região, com um tempo de iteração para realizar a segmentação bem maior que o das técnicas citadas anteriormente. Além disso, o método apresentado por Itai *et al.* (ITAI *et al.*, 2005) não é totalmente automatizado já que necessita da intervenção inicial do operador para a escolha da região onde deve ser aplicado o *snakes*.

3.1.2 Segmentação dos lobos e das fissuras pulmonares

Os pulmões são divididos em cinco lobos distintos, separados pelas fissuras lobolares, como mostrado na Figura 3.1. O pulmão direito contém três lobos que são: superior, médio e inferior. Os lobos superior e médio são separados pela fissura horizontal e os lobos médio e inferior estão separados pela fissura oblíqua. O pulmão esquerdo é formado pelos lobos superior e inferior e são separados por uma fissura oblíqua (ZHANG; HOFFMAN; REINHARDT, 2006).

Para realizar a segmentação dos lobos, Zhang, Hoffman e Reinhardt (ZHANG; HOFFMAN; REINHARDT, 2006) utilizam um sistema baseado em lógica nebulosa, o qual realiza a pesquisa dos lobos através das informações contidas em um atlas pulmonar, utilizando as medidas de intensidade e contraste baixo. Nesta mesma direção, ou seja, utilizando-se de lógica nebulosa, Guo *et al.* (GUO *et al.*, 2002) segmentam os lobos pulmonares aplicando uma análise da escala de cinza da imagem, e das características da forma anatômica dos lobos.

As fissuras pulmonares são os separadores naturais existentes entre os lobos pulmonares. Estas podem ser segmentadas por uma TC normal ou uma Tomografia

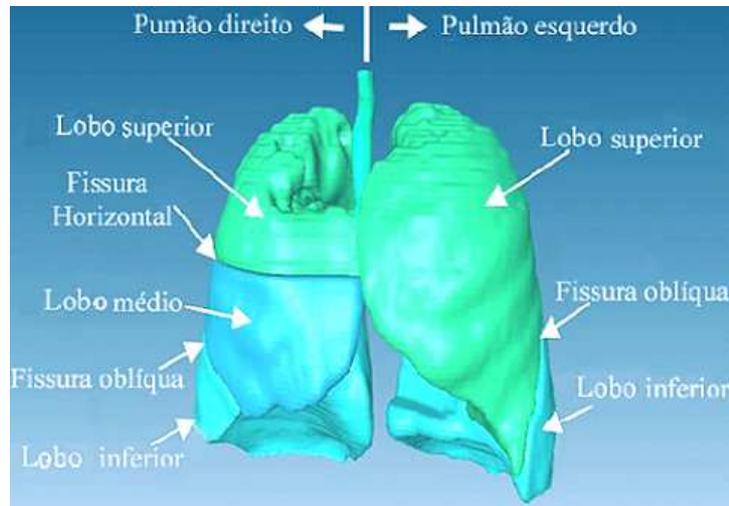


Figura 3.1: anatomia dos lobos pulmonares, adaptada de (ZHANG; HOFFMAN; REINHARDT, 2006).

Computadorizada de Alta Resolução (TCAR) (Apêndice A), e também através de técnicas de PDI, que são: cálculo de superfície de curvatura e filtros morfológicos (HAYASHI et al., 2001; YILDIZ et al., 2004; KUBO et al., 2000).

No trabalho de Wei *et al.* (WEI et al., 2006) é apresentado um algoritmo autônomo que segmenta os lobos pulmonares através de técnicas de fissura adaptável e varredura, que identifica, de modo grosseiro, as regiões com fissuras. Nesse trabalho também é utilizado a transformada de *watershed* para refinar o local e a curvatura das fissuras.

Para segmentar os lobos, Kuhnigk *et al.* (KUHNIK et al., 2003) utilizam uma combinação linear dos dados originais com um mapa de distância para as regiões que apresentam fissuras visíveis. Por último, aplicam o algoritmo de *watershed* em 3D na imagem de dados combinados, para fazer um refinamento das fissuras.

Os sistemas baseados em lógica nebulosa propostos por Zhang, Hoffman e Reinhardt (ZHANG; HOFFMAN; REINHARDT, 2006) e Guo *et al.* (GUO et al., 2002) apresentam limitações na segmentação quando aplicados em imagens com baixo contraste, geralmente imagens de pacientes com patologias. A diferença dos níveis de cinza

contém mudanças bastante significativas nas informações dos *pixels* das fissuras, ocasionando um não reconhecimento dos lobos pelo sistema nebuloso.

O algoritmo de segmentação das fissuras dos lobos apresentados por Wei *et al.* (WEI et al., 2006) possui um desempenho satisfatório em imagens com um bom contraste visual. Entretanto, os autores não testam o algoritmo em imagens com diferentes variações de contraste, para verificar se a eficiência é a mesma.

Já os resultados apresentados no trabalho de Kuhnigk *et al.* (KUHNIK et al., 2003) não são satisfatórios, tendo em vista que os marcadores aplicados pelo algoritmo de *watershed* ficam localizados em áreas próximas de grandes vasos e do hilo regiões, provocando reconhecimento dos vasos, ao invés das fissuras.

3.1.3 Segmentação dos vasos sanguíneos pulmonares

A segmentação dos vasos pulmonares é importante para um auxiliar ao diagnóstico mais complexo, tendo em vista que a dilatação ou retração dos vasos estão associadas com algum tipo de doenças.

Busayarat e Zrimec (BUSAYARAT; ZRIMEC, 2005) fazem a segmentação das artérias pulmonares aplicando a técnica de modelo adaptado de aproximação local da arteria, através de uma base de conhecimento, que guia a localização da artéria próxima ao brônquio. Além disso, utilizam o crescimento de região para segmentar as artérias.

Felix *et al.* (FELIX et al., 2007) apresentam a segmentação dos vasos pulmonares baseado nas operações de abertura e fechamento da Morfologia Matemática. O elemento estruturante utilizado é de forma retangular, que produziu o melhor resultado durante os teste realizados em imagens de pulmões.

Os resultados de segmentação mostrados nos trabalhos de Busayarat e Zrimec (BUSAYARAT; ZRIMEC, 2005) e Felix *et al.* (FELIX et al., 2007) apresentam uma segmentação satisfatória para um estagio inicial. Entretanto, uma evolução destes algoritmos é necessária, pois as informações relevantes, como medidas de área e volume dos vasos, devem ser calculados, para possibilitar um melhor auxílio ao diagnóstico

com parâmetros quantitativos e não somente visuais.

3.1.4 Segmentação das vias aéreas

O pulmão consiste em uma árvore de vias aéreas, vasos, e tecidos conectados chamados de interstício (uma estrutura de membranas finas que suportam e definem a estrutura do pulmão). As vias aéreas são recipientes dispostos em forma de árvores, iguais a uma complicada rede. Estas vias estão divididas em ramificações progressivamente mais finas, que começam no hilo, que é o local de entrada de ar nos pulmões. Os sacos alveolares, mostrados na Figura 3.2 - final da zona respiratória, são responsáveis pelas trocas gasosas entre a corrente sanguínea e os alvéolos pulmonares (SLUIMER, 2005).

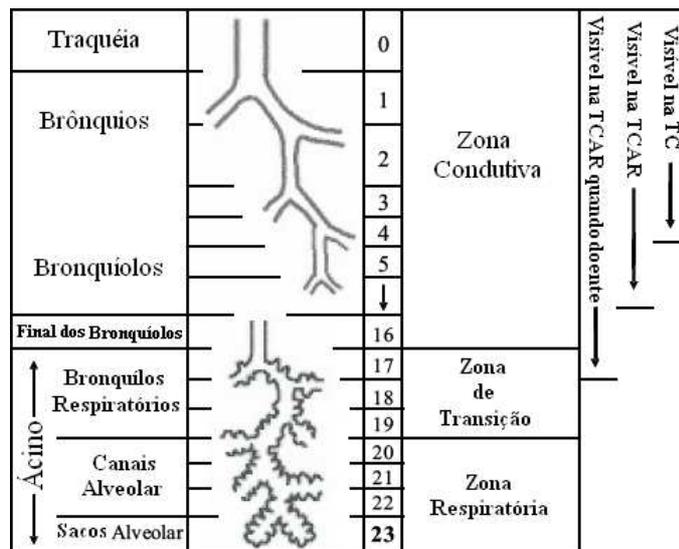


Figura 3.2: representação dos canais de ar dos pulmões, adaptada de (SLUIMER, 2005).

Park, Hoffman e Sonka (PARK; HOFFMAN; SONKA, 1998) apresentam uma aproximação para detectar as vias aéreas em estruturas de árvores baseada em lógica nebulosa, através das informações de brilho da região adjacente e do grau de presença

da parede das vias aéreas, que compõem as funções de pertinência de cada conjunto nebuloso. Sonka, Park e Hoffman (SONKA; PARK; HOFFMAN, 1996) utilizam o método baseado em uma combinação de crescimento de região 3D. Para identificar grandes vias aéreas é aplicada uma base de regras 2D, que é empregada na segmentação de fatias em 2D de TC individuais. Além disso, para identificar prováveis locais de canais de ar de diâmetro menores, os canais de ar são fundidos em um conjunto de fatias em 3D.

Mori *et al.* (MORI *et al.*, 2000) propõem em seu trabalho uma rotulação anatômica da ramificação bronquial, usando uma base de conhecimento desta anatomia. Esta base de conhecimento assegura a informação sobre cada ramificação bronquial, como sendo, um conjunto de regras para a sua rotulação anatômica. A rotulação anatômica é realizada a estrutura de árvore do brônquio, com a base de conhecimento.

A eficiência das segmentações dos trabalhos apresentados nesta Seção está diretamente ligada com a ausência de artefatos, ou seja, ruídos que geram erros de informação, assumindo valores de atenuação semelhantes aos das vias aéreas, causando, desta forma, um aumento errôneo das regiões segmentadas.

3.2 Detectando, quantificando e classificando as alterações de estruturas pulmonares na DPOC

A detecção das doenças pulmonares são relevantes para possibilitar algum tipo de tratamento. A quantificação e classificação da DPOC é importante para que seja realizado um tratamento adequado de acordo com as informações obtidas, permitindo uma precisão nos diagnósticos, nas aplicações dos medicamentos, nas definições de regiões a serem retiradas em cirurgias, com base num planejamento cirúrgico e um acompanhamento da evolução da doença.

Com o objetivo de auxiliar no diagnóstico da DPOC, é de fundamental importância realizar, além da detecção, uma quantificação e classificação do enfisema.

Algumas doenças como o enfisema pulmonar e a bronquite crônica estão associadas com a DPOC, sendo portanto, importante sua detecção, quantificação e classificação.

3.2.1 Enfisema pulmonar

O enfisema é patologicamente definido como o aumento permanente do espaço aéreo distal ao longo do bronquíolo terminal, acompanhado pela destruição de suas paredes sem fibrose óbvia (SNIDER et al., 1985). O enfisema pode ter um grau de ocorrência brando, moderado e severo. Na Figura 3.3 são apresentados exemplos de pulmão normal, enfisema panlobular, enfisema centrilobular e enfisema paraseptal.

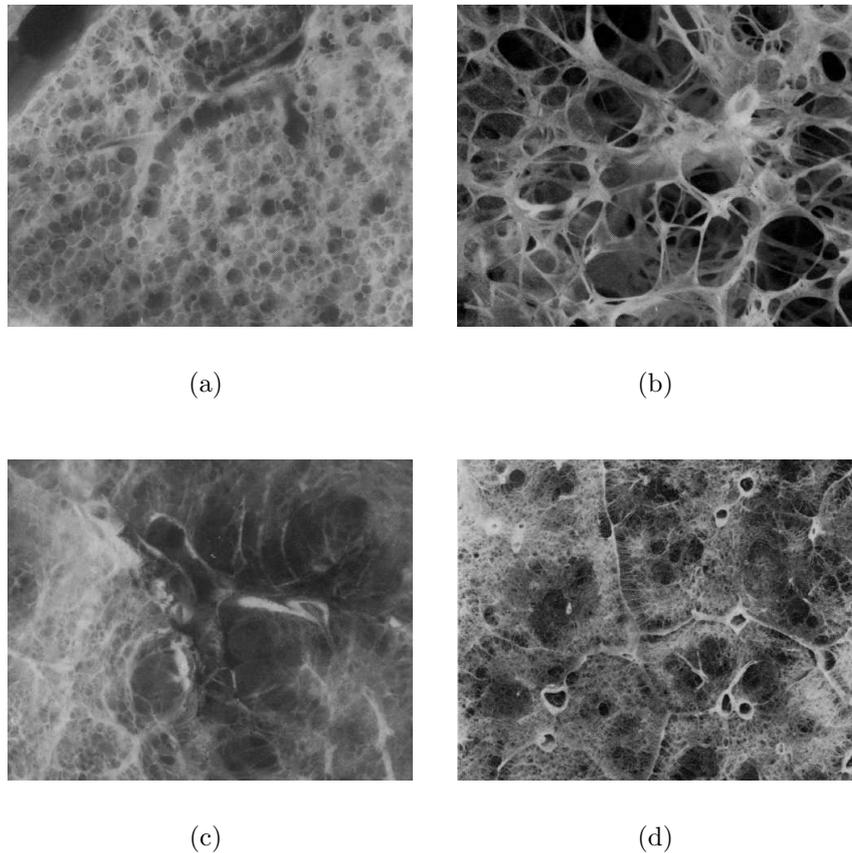


Figura 3.3: pulmão normal e com enfisema (a) normal, (b) enfisema panlobular, (c) enfisema centrilobular e (d) enfisema paraseptal (HEARD et al., 1979).

A classificação morfológica do enfisema pulmonar divide-se em vesicular e intersticial, definidos a seguir (HEARD et al., 1979; WRIGHT; CHURG, 2006).

1. Enfisema vesicular: um aumento anormal dos espaços de ar além do bronquíolo terminal, com destruição das paredes alveolares;
 - (a) panlobular: uma forma de enfisema que envolve todos os espaços de ar, além do bronquíolo terminal em uma maneira relativamente uniforme ao longo dos lobos afetados (Figura 3.3(b));
 - (b) centrilobular: uma forma de enfisema que envolve os espaços de ar no centro dos lobos (Figura 3.3(c));
 - (c) paraseptal: uma forma que envolve os espaços de ar na periferia dos lobos (Figura 3.3(d));
 - (d) irregular: uma forma de enfisema que afeta diferentes partes de diferentes lobos;
 - (e) não-classificado: uma forma de enfisema que não se ajusta a nenhuma das categorias anteriores. Por exemplo, casos em que há dificuldade em decidir entre enfisema centrilobular severo e panlobular ou entre enfisema centrilobular e enfisema irregular;
2. Enfisema intersticial: uma forma de enfisema com inflação do tecido intersticial do pulmão. aEnfisema intersticial pode ser espalhado pelo *mediastinum* e tecido subcutâneo. Uma bolha é uma coleção local de balões de ar nos tecidos intersticiais.

Um diagrama dos ácinos normais (bago), enfisemas centrilobular e panlobular é ilustrado na Figura 3.4.

A primeira correlação de patologia na TC com enfisema pulmonar é proposta por Hayhurst, Flenley e McLean (HAYHURST; FLENLEY; MCLEAN, 1984). Eles mostram através de um programa padrão chamado de máscara de densidade, que os pacientes

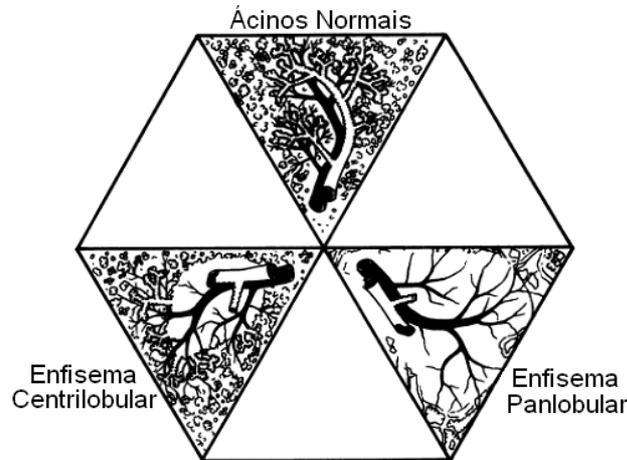


Figura 3.4: diagrama de um lobo do pulmão, ilustrando ácidos (bagos) normais, enfisema centrilobular e panlobular (HEARD et al., 1979).

com enfisema apresentam os *pixels* com os valores de atenuação entre -1000 UH e -900 UH. Este programa realça as unidades de volumes de uma imagem chamado de *voxels* que estão dentro da faixa da escala em UH.

A detecção do enfisema em imagem é realizado através de um cálculo do valor de atenuação para cada *voxel* pulmonar (MULLER et al., 1988; KALENDER et al., 1990).

Com a utilização desse programa, a TC torna-se uma ferramenta de quantificação de enfisema pulmonar em pessoas vivas mais eficiente, e permite um melhor acompanhamento da evolução do enfisema no paciente (ARCHER et al., 1993; GEVENOIS; YERNAULT, 1995).

A detecção e quantificação de enfisema pulmonar é um tema abordado por vários pesquisadores (COXSON et al., 1999; PARK; BERGIN; CLAUSEN, 1999; BLECHSCHMIDT; WERTHSCHÜTZKY; LÖRCHER, 2001). Estes trabalhos utilizam respectivamente, análise histológica da estrutura pulmonar, densitometria pulmonar e morfologia do enfisema pulmonar. Nakano *et al.* (NAKANO et al., 2000) utilizam a macroscopia e microscopia, para quantificar o enfisema em uma TC. Madani *et al.* (MADANI et al., 2006) utilizam uma TC com múltiplos detectores de linhas e mesma técnica apresentada por Nakano

et al. (NAKANO *et al.*, 2000), ao invés de adquirir as imagens com uma TC normal. O diferencial está na TC aplicada por Madani *et al.* (MADANI *et al.*, 2006) que possui maior velocidade na aquisição das imagens, comparada com a TC normal.

Várias técnicas são aplicadas para detectar e quantificar o enfisema pulmonar como lógica nebulosa (BUTEAU; MAKRAM-EBEID, 1996), atlas baseado em registro (SLUIMER; PROKOP; GINNEKEN, 2005), filtro iterativo (SCHILHAM *et al.*, 2006), processamento de imagens e reconhecimento de padrões com uma rede neural (FRIMAN *et al.*, 2002), análise por componentes independentes (PRASAD; SOWMYA; KOCH, 2004), análise de textura e dimensão fractal (MADANI; KEYZER; GEVENOIS, 2001; CHABAT; YANG; HANSELL, 2003; UPPALURI *et al.*, 1997, 1999; XU *et al.*, 2006).

3.2.2 Bronquite crônica

Em termos clínicos, a bronquite crônica é definida como uma condição inflamatória crônica dos brônquios. Esta produz um aumento na secreção do muco pelas glândulas da árvore brônquica, resultando na expectoração de muco durante o dia. Este fato acontece por pelo menos três meses, em dois anos consecutivos. Devido à patologia, a parede bronquial pode ser engrossada, e as seguintes características histológicas podem ser observadas: alargamento das glândulas mucosas, dilatação dos tubos da glândula mucosas, aumento no número de células mucosas no ácino de glândulas mucosas, grau variável da infiltração crônica de células inflamatórias (HEARD *et al.*, 1979).

3.2.3 Doença pulmonar obstrutiva crônica - (DPOC)

A Doença Pulmonar Obstrutiva Crônica (DPOC) é uma enfermidade caracterizada pela obstrução do fluxo de ar, tendo o enfisema e a bronquite crônica como principais componentes. A obstrução ao fluxo aéreo é parcialmente reversível e geralmente progressiva, associada com inflamação anormal do pulmão, como resposta deste às partículas nocivas e fumaça de cigarro (CELLI, 1998; FIGUEROA *et al.*, 2005; CELLI;

MACNEE, 2004).

O tabaco é o principal causador da DPOC, destruindo os alvéolos pulmonares gradualmente ao longo dos anos, gerando o enfisema pulmonar, que por sua vez causa a perda da retração elástica dos pulmões, resultando na redução do fluxo aéreo respiratório e aprisionamento gasoso, responsável pela hiperinsuflação pulmonar (O'DONELL; WEBB, 1993). Uma alternativa para melhoria da qualidade de vida dos pacientes com DPOC é a cirurgia redutora de volume pulmonar, que pode ser capaz de amenizar os sintomas desta doença (FIGUEROA et al., 2005).

A detecção e quantificação dos componentes patológicos em pacientes com DPOC, pode ser realizada, através de diversas técnicas de PDI. Mishima *et al.* (MISHIMA et al., 1999) analisam as propriedades estatísticas, agrupamento em áreas de baixa atenuação. Recentemente, Xu *et al.* (XU et al., 2006) mostram em seu trabalho diversos métodos de caracterização da DPOC e de suas principais componentes como enfisema e bronquite crônica baseados em técnicas de PDI.

3.3 Conclusão do Capítulo

Neste Capítulo é realizado uma revisão bibliográfica sobre os pulmões e suas estruturas, bem como, sobre as principais componentes da DPOC e as técnicas de segmentação, detecção e quantificação aplicadas. No Capítulo 4 é apresentado uma descrição das características do sistema proposto desenvolvido neste trabalho.

Capítulo 4

Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar

O sistema proposto para detecção e quantificação de enfisema pulmonar (SDEP) utiliza técnicas de Processamento de Imagens Digitais para realizar a segmentação dos pulmões, identificação e mensuração do enfisema pulmonar, apresentando-se como uma ferramenta para auxílio ao diagnóstico e a pesquisa.

Neste Capítulo, são apresentadas as características do sistema proposto e as aplicações que podem ser realizadas a partir deste, bem como é realizada a descrição do sistema Osiris 4 (GIRARD et al., 1996) e de dois algoritmos de segmentação, um proposto por Silva e Carvalho (SILVA; CARVALHO, 2002) e o outro por Shojaii, Alirezaie e Babyn (SHOJAII; ALIREZAIE; BABYN, 2005).

4.1 Aquisição das imagens

Antes da aquisição das imagens, para cada exame, o tomógrafo é calibrado para densidade de ar -1000 UH. A calibração para densidade de água é realizada em período

não superior a 3 meses da realização dos exames, conforme especificação técnica recomendada pelo fabricante (TOSHIBA, 1997). Ainda é realizado, antes da aquisição, um corte tomográfico do phantom de água, cuja densidade já é conhecida para análise e controle de parâmetro através de sistema (FORTALEZA, 2006; WINKELER, 2006).

As imagens dos voluntários sadios e dos pacientes com DPOC são adquiridas em um tomógrafo Toshiba modelo Auklet no Serviço de Imagem do Hospital Universitário Walter Cantídio, seguindo o protocolo de Tomografia Computadorizada de Alta Resolução (TCAR) (Apêndice A), sob as seguintes condições: os cortes possuem colimação (espessura da fatia) de 1,5 mm, campo de visão de 312 mm, voltagem do tubo de 120 kv, corrente elétrica do tubo de 200 mA, ajuste da janela pulmonar: centro e largura, respectivamente de -600/1600 UH, tamanho da imagem reconstruída é de 512×512 pixels, e voxel com tamanho de $0,585 \times 0,585 \times 1,5$ mm. As imagens são quantificadas em 16 bits e armazenadas no padrão DICOM (Digital Imaging and Communications in Medicine) (Apêndice A) (FORTALEZA, 2006; WINKELER, 2006).

Na aquisição das imagens dos voluntários sadios e dos pacientes com DPOC, os cortes tomográficos na posição supina são realizados em 3 regiões: ao nível do ápice, hilo e em base. Na posição prona, são realizados cortes somente ao nível da base (FORTALEZA, 2006; WINKELER, 2006).

4.2 Metodologia

Inicialmente é realizada uma comparação entre os algoritmos de segmentação aplicados aos pulmões, apresentados por Silva e Carvalho (SILVA; CARVALHO, 2002), Shojaii, Alirezaie e Babyn (SHOJAII; ALIREZAIE; BABYN, 2005), programa Osiris (GIRARD et al., 1996) e o sistema SDEP. Em seguida é realizada uma análise comparativa entre os resultados de área, densidade pulmonar média e da segmentação através da máscara colorida somente entre o programa Osiris e o sistema SDEP, pois, os algoritmos de Silva e Carvalho e de Shojaii, Alirezaie e Babyn não apresentam cálculos de medidas e segmentação através da máscara colorida.

Os parâmetros utilizados no sistema SDEP são: histograma por faixa de densidade pulmonar, máscara colorida (pseudo-cores), medidas de perímetro, área, volume, Densidade Pulmonar Média (DPM) e os 15% pontos percentuais adquiridos pelo histograma acumulado, denominado de Perc15 (PRATT, 2001; STOEL; STOLK, 2004).

Os algoritmos proposto por Silva e Carvalho e Shojaii, Alirezaie e Babyn, são denominados neste trabalho de algoritmo SC e Algoritmo SAB, respectivamente. São utilizadas nos testes para a comparação da segmentação dos pulmões entre os algoritmos SC, algoritmos SAB, sistema Osiris e o SDEP, 102 imagens de 8 (oito) voluntários saudáveis e 141 imagens de 11 (onze) pacientes com DPOC adquiridas conforme descrito na Seção 4.1. Para representar os resultados da segmentação são utilizadas 4 imagens de um voluntário sadio e 4 de um paciente com DPOC. O voluntário e o paciente são escolhidos de forma aleatória.

Na análise das medidas de área e DPM, e para a segmentação com a máscara colorida, na comparação, entre o sistema Osiris e o SDEP são utilizadas 8 imagens, sendo que 4 são de um voluntário sadio e 4 de um paciente com DPOC. Para representar a segmentação da máscara colorida é utilizado apenas uma imagem escolhida aleatoriamente dentre as 8 imagens.

4.3 Descrição do sistema SDEP

O protótipo do sistema proposto é desenvolvido em Matlab. O sistema é constituído por processos típicos de um sistema de Visão Computacional como aquisição da imagem, segmentação e identificação. Neste caso, são detectadas áreas normais e enfisematosas.

Seguindo a lógica do fluxo de um sistema de Visão computacional, conforme visto na Seção 2.1. O sistema SDEP, inicia sua descrição pela aquisição das imagens, realizadas através de um tomógrafo, conforme é apresentado na Seção 4.1.

Na próxima etapa, as imagens são segmentadas através do algoritmo de CR como descrito na Seção 4.4, tendo em vista que o sistema SDEP não apresenta a etapa de

pré-processamento. Após a segmentação pulmonar são calculadas as medidas de área, perímetro e volume dos pulmões, que consiste no passo da extração de atributos.

Uma vez realizada a extração de atributos, esta é submetida à análise através da máscara de cores, que aplica uma pseudo-cor sobre os *pixels* escolhidos dentro de uma faixa determinada pelo usuário do sistema, realizando o reconhecimento das regiões normais e enfisematosas do tecido pulmonar. Esta aplicação permite identificar e quantificar as regiões da faixa de densidade pulmonar, cuja descrição é feita com base nas cores pseudo-cores escolhidas para tal.

As principais faixas de densidade pulmonar são: área hiperaeradas ou hiperdistendida (-1000 a -950 UH), normalmente aerada (-900 a -500 UH), pouco aerada (-500 a -100 UH) e não-aerada (-100 a 100 UH). Com isso, é possível detectar e quantificar regiões enfisematosas que estão compreendidas dentro da área hiperaeradas, sendo adotado os valores de -1000 a -950 para a análise dos resultados, sabendo que as imagens foram obtidas através de uma TCAR (VIEIRA et al., 1998; GEVENOIS et al., 1996).

4.4 Descrição dos algoritmos para a segmentação dos pulmões

Nesta Seção são descritos os algoritmos de segmentação utilizados no programa Osiris e no sistema SDEP, bem como, do algoritmo SC proposto por Silva e Carvalho (SILVA; CARVALHO, 2002) e do algoritmo SAB apresentado por Shojaii, Alirezaie e Babyn (SHOJAI; ALIREZAIE; BABYN, 2005).

4.4.1 Descrição do algoritmo do sistema SDEP

O sistema SDEP faz a segmentação automática dos pulmões através da técnica de Crescimento de Região associadas com as operações morfológicas de fechamento e erosão (GONZALEZ; WOODS, 2002).

O algoritmo inicia seu processamento convertendo a imagem original do padrão DICOM quantizada em 16-*bits* para um padrão quantizado em 8-*bits*, para facilitar o cálculo do histograma. Na Figura 4.1(a) é apresentada a imagem convertida para o padrão em 8-*bits*. A conversão da imagem é realizada através da função “im2uint8” do Matlab, que utiliza uma função logarítmica para comprimir a informação contida na imagem. Esta conversão possibilita, sempre, o cálculo de um histograma bimodal. Na Figura 4.1(b) é mostrado o histograma dessa imagem, e o valor da semente igual a 58. A semente é selecionada através da varredura no histograma, que identifica o maior valor presente no primeiro pico deste. O critério de parada do CR é de 40% do valor da semente.

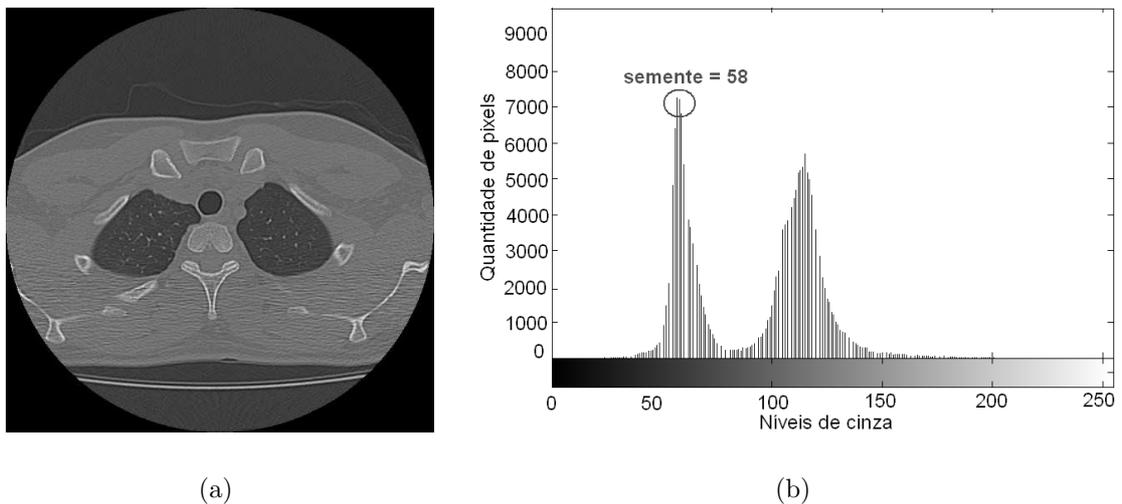


Figura 4.1: imagem de TC dos pulmões (a) imagem convertida para 8-*bits* e (b) seu histograma com a semente = 58.

No segundo passo é aplicada uma sub-imagem no formato retangular, com o tamanho de 100×80 , em cada pulmão, localizados na mesma posição para todas as imagens testadas, com a finalidade de identificar o único rótulo existente, que representa cada pulmão, obtido pela aplicação da técnica de CR. O tamanho e a posição das sub-imagens são determinados de forma empírica, através de testes aplicados em todas as imagens.

A imagem rotulada com o CR e as sub-imagens (região retangular), localizadas no pulmão esquerdo e no pulmão direito são apresentadas na Figura 4.2. Para cada sub-imagem é calculado o histograma e identificado o valor do rótulo (índice) de maior ocorrência. Cada índice é utilizado para construir uma máscara que represente o pulmão esquerdo e o pulmão direito, conforme são mostradas nas Figuras 4.3(a) e 4.3(b).

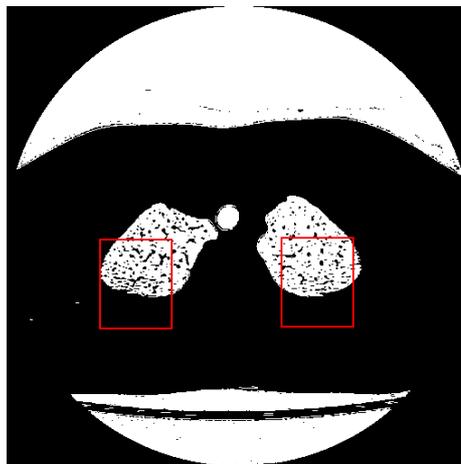


Figura 4.2: imagem rotulada através do CR com as sub-imagens (região retangular em cada pulmão).

O terceiro passo é aumentar o tamanho das máscaras de 512×512 para 552×552 , para evitar que as bordas laterais das máscaras sejam rompidas, quando aplicada a operação morfológica de fechamento, cuja finalidade é eliminar os vasos. Nas Figuras 4.4(a) e 4.4(b) são apresentadas as máscaras dos pulmões esquerdo e direito, após aplicação da operação de fechamento, com um elemento estruturante no formato de disco com o raio de 16. O tamanho do elemento estruturante é definido de acordo com as medidas dos maiores vasos pulmonares encontrados nas imagens testadas. Já o formato do elemento estruturante é baseado na técnica de *rolling ball* (GONZALEZ; WOODS, 2002).

A operação de erosão é realizada com o objetivo de ajustar a máscara dos pulmões

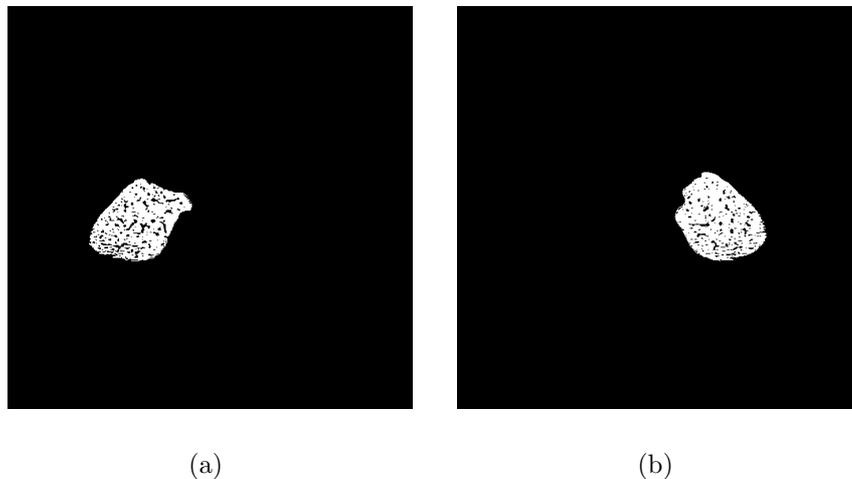


Figura 4.3: máscaras dos pulmões (a) esquerdo e (b) direito.

ao tamanho real da imagem original, conforme são mostradas nas Figuras 4.4(c) e 4.4(d). Na erosão é utilizado o elemento estruturante no formato de disco com raio de 2.

O último passo consiste em reduzir os tamanhos das máscaras para o tamanho original de 512×512 , e unir estas em uma mesma máscara (imagem) contendo os dois pulmões. Em seguida é aplicada a operação de intersecção entre a máscara que contém os pulmões e a imagem original, objetivando restaurar os valores dos pixels originais dos pulmões. Nas Figuras 4.5(a) e 4.5(b) são apresentadas a máscara dos pulmões e a imagem de intersecção (resultado da segmentação).

Para visualizar os detalhes das bordas da segmentação do sistema SDEP, é aplicado a operação de detecção de bordas com o operador de Sobel na máscara dos pulmões da Figura 4.5(a), para extrair os contornos dos pulmões. Os contornos são sobrepostos na imagem original. Na Figura 4.6 é mostrado um recorte da imagem original com os contornos sobrepostos, na qual podem ser vistos os detalhes nas bordas pulmonares contornadas pela borda da máscara dos pulmões (bordas de cor branca).

Após a segmentação descrita nos passos anteriores, são realizados os cálculos das medidas de perímetro, área e volume. Para os outros parâmetros como: Perc15 e

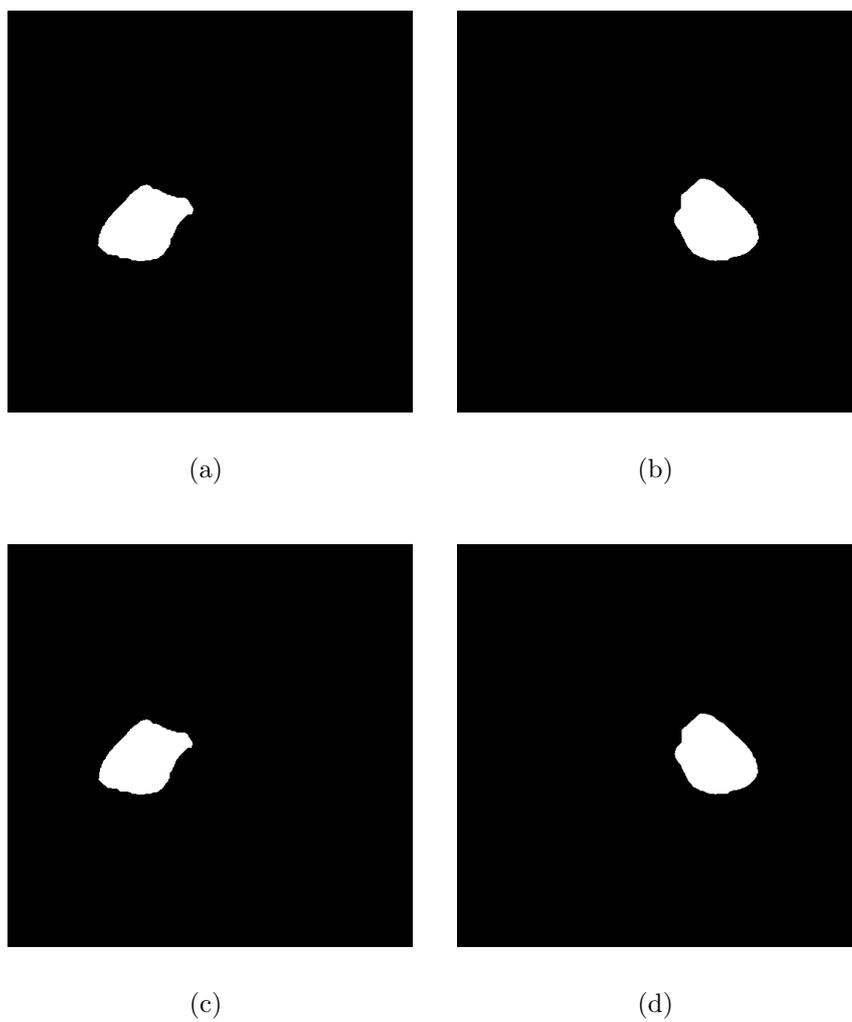


Figura 4.4: operações morfológicas (a) fechamento aplicado no pulmão esquerdo, (b) fechamento aplicado no pulmão direito, (c) erosão aplicada no pulmão esquerdo e (d) erosão aplicada no pulmão direito.

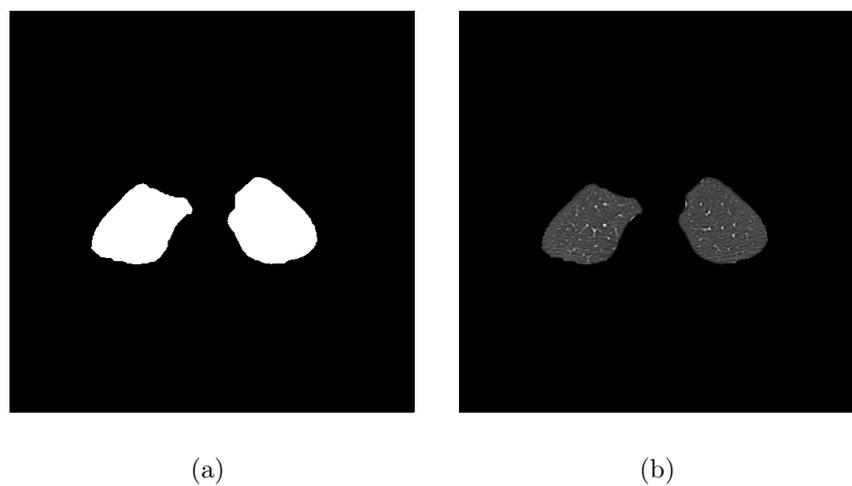


Figura 4.5: imagens de (a) máscara dos pulmões e (b) intersecção (resultado da segmentação).

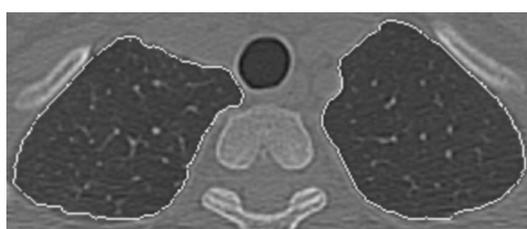


Figura 4.6: recorte da imagem original com a sobreposição das bordas extraídas da máscara dos pulmões (Figura 4.5(a)).

DPM é necessário calcular o histograma da imagem, bem como o histograma por faixa e o histograma acumulado. Além da segmentação o sistema SDEP realiza a divisão do pulmão em regiões ventral, medial e dorsal.

4.4.2 Descrição do algoritmo de segmentação do sistema Osiris

O sistema Osiris realiza a segmentação individual de cada pulmão através da técnica de CR e os resultados dos cálculos de média, desvio padrão, valor do *pixel* mínimo e máximo, área e tamanho são apresentados separadamente para cada pulmão, quando é selecionada a opção *show data* na barra de ferramentas. A técnica de CR é iniciada com uma semente selecionada pelo usuário, e o critério de crescimento (agregação) é baseado no nível de cinza da imagem. Um polígono fechado define a região a ser segmentada.

A segmentação pulmonar realizada pelo sistema Osiris é descrita nos seguintes passos (GIRARD et al., 1996):

1. realizar chamada da segmentação na barra de ferramentas;
2. especificar os parâmetros de segmentação numa caixa de diálogo aberta pela ação do item anterior;
3. selecionar a semente com o botão esquerdo do *mouse* na RI desejada;
4. ajustar manualmente o polígono ou realizar novamente os passos anteriores, caso ocorra uma especificação equivocada do operador no item anterior.

4.4.3 Descrição dos algoritmo SC e SAB

Para os algoritmos SC e SAB são descritos as técnicas aplicadas para realizar a segmentação dos pulmões. O algoritmo SC proposto por Silva e Carvalho realiza a segmentação pulmonar através de binarização global da imagem com o valor do limiar de -250 UH, seguida das operações morfológicas de abertura e fechamento com um

elemento estruturante quadrado de dimensão 3×3 , em seguida é feita a detecção de bordas usando o operador de Sobel no sentido horizontal e vertical, e logo após é realizado um afinamento morfológico sobre as bordas extraídas. Para remover os objetos com contornos contínuos e não-contínuos com a área de 300 *pixels*, aplica-se o código de cadeia para calcular a área destes objetos e por último aplica-se a técnica de *rolling-ball* para reconstruir o parênquima pulmonar (SILVA; CARVALHO, 2002).

Já o algoritmo SAB apresentado por Silva e Carvalho (SHOJAI; ALIREZAIE; BABYN, 2005) utiliza parte da técnica apresentada por Shojai, Alirezaie e Babyn (SILVA; CARVALHO, 2002), diferenciando-se na operação de abertura que é aplicada ao complemento da imagem binarizada, e no tamanho dos objetos a serem removidos, que são de 200 *pixels*. São utilizados marcadores internos e externos, responsáveis pela limitação da área de atuação da transformada *watershed*. O marcador interno é obtido pelo complemento da imagem dos pulmões, e o marcador externo é adquirido através da dilatação do marcador interno. Os marcadores são fundidos em uma mesma imagem através da operação de intersecção para aplicar a transformada de *watershed*.

Durante a implementação dos algoritmos SC e SAB são realizadas adaptações em algumas operações, pois, são omitidas informações pelos autores nas suas publicações, sendo então, utilizado os parâmetro que produziram melhores resultados. A binarização através do limiar de Otsu (OTSU, 1979) é aplicada no algoritmo SAB. No algoritmo SC, para a operação de afinamento morfológico é utilizado um elemento estruturante quadrado de 3×3 . O código de cadeia utilizado é de oito elementos de conectividade (direção). Um elemento estruturante no formato de disco com diâmetro de 3 é aplicado para a técnica de *rolling-ball*.

Na operação morfológica de abertura para o algoritmo SAB é utilizado um elemento estruturante quadrado de 3×3 . Para obter o marcador externo, é aplicado a dilatação com um elemento estruturante no formato de disco com raio de 2.

Tendo em vista que o sistema SDEP é desenvolvido em Matlab, os algoritmos SC e SAB são também implementados neste, seguindo as descrições dos autores, em suas publicações, para se ter uma comparação justa entre os algoritmos. Já o programa

Osiris 4 é instalado no mesmo computador em que são obtidos os resultados com o sistema SDEP e os algoritmos 1 e 2, para realização dos teste.

4.5 Descrição da interface do sistema Osiris

A interface do sistema Osiris é mostrada na Figura 4.7, em que os resultados das operações de segmentação e filtragem são visto na mesma região da imagem original. Este programa apresenta uma barra de ferramenta com várias funções, dentre elas existe uma aba chamada de processamentos, onde encontra-se: filtros, detecção de contornos, fusão de imagem, equalização de histograma, segmentação e outros (GIRARD et al., 1996).

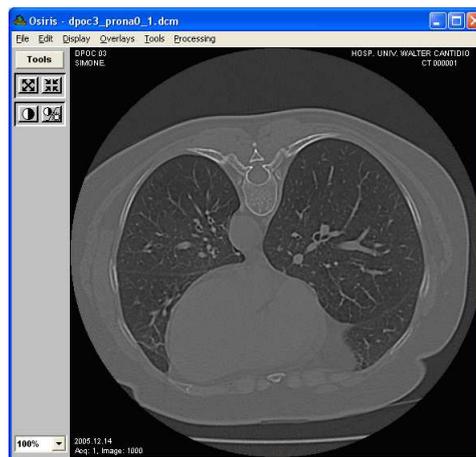


Figura 4.7: interface do sistema Osiris.

4.6 Descrição da interface do sistema SDEP

A interface do sistema SDEP é apresentada na Figura 4.8, em que pode ser visualizado a imagem dos pulmões no lado esquerdo, e no lado direito a imagem segmentada. Os números 1, 2 e 3, indicam as seguintes partes respectivamente: escolher imagem a segmentar dentro de uma pasta, segmentar esta imagem e visualizar os resultados das medidas de volume área e perímetro; calcular e visualizar os resultados dos histogramas e segmentação por cores através da máscara colorida.

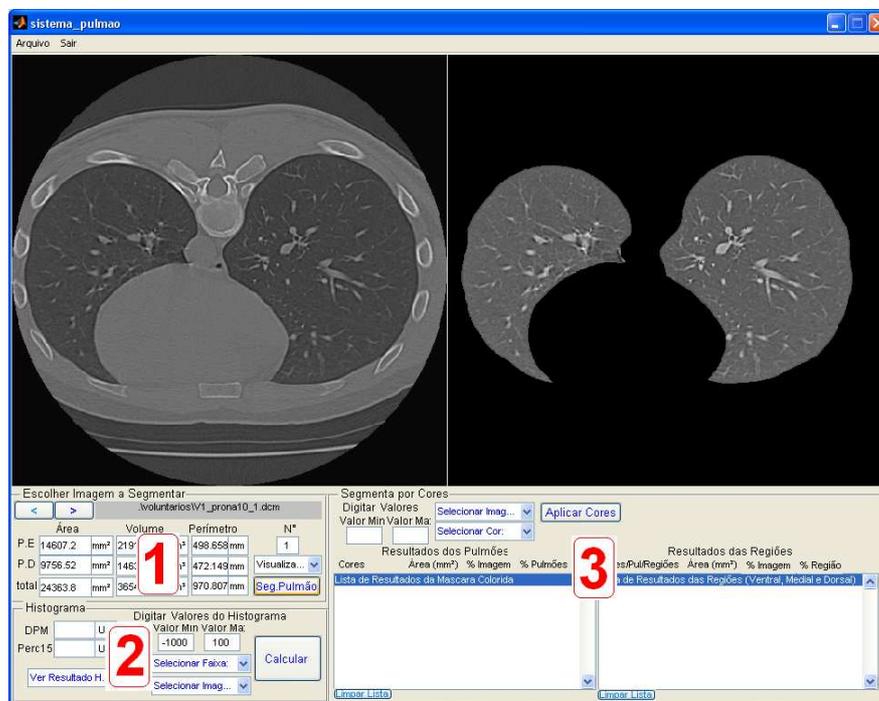


Figura 4.8: interface do sistema SDEP.

Um recorte da parte 1, referente à Figura 4.8 é mostrada na Figura 4.9. Nesta é possível visualizar a barra de seleção, que permite escolher as imagens dentro da pasta. Os símbolos < (anterior) e > (próximo) fazem esta tarefa. Para realizar a segmentação dos pulmões, basta clicar no botão “Seg.Pulmão”.

O campo onde esta escrito “Visualização”, logo acima do botão “Seg.Pulmão”,

permite que sejam mostradas as imagens dos vasos e das bordas do mesmo pulmão segmentado. O campo com o símbolo “N^o”, que por padrão está com 1 (um), deve ser modificado para 2 ou 3 quando o usuário quiser visualizar e adquirir os resultados dos pulmões dividido em regiões ventral, medial e dorsal. Também na parte 1 são vistos os resultados das medidas de perímetro, área e volume para o pulmão esquerdo e direito.

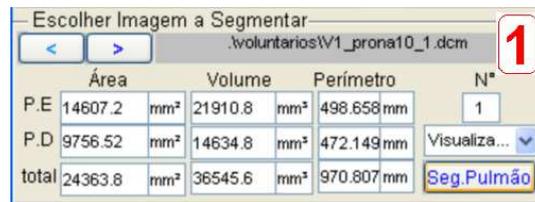


Figura 4.9: recorte da parte 1 da interface do sistema SDEP.

Na parte 2, estão concentradas todas as informações referentes aos cálculos e às visualizações dos histogramas por faixa e acumulados, bem como, das medidas de densidade pulmonar média e 15 pontos percentuais ou Perc15. Nos campos “ValorMin” e “ValorMax” devem ser digitados os valores que são desejados para a faixa do histograma. No campo “Selecionar Faixa”, o operador deve escolher entre 5, 10, 20, 25 e 50, que são os números de divisões para as faixas. Já no campo “Selecionar Imagem”, o operador deve escolher entre as imagens dos pulmões, das regiões ventral, medial e dorsal do pulmão esquerdo ou do pulmão direito, para realizar o cálculo do histograma. Para visualizar os resultado, basta selecionar as opções no campo “Ver Resultados”, conforme é mostrado na Figura 4.10.

Na parte 3 é realizado a segmentação por pseudo-cores, através da máscara colorida, conforme Figura 4.11. Nos campos “Valor Min” e “Valor Max” são digitados os valores das faixas a serem segmentadas. No campo “Selecionar Imagem”, deve-se selecionar a imagem à qual se deseja aplicar a máscara de cores, podendo ser: imagem dos pulmões segmentados, dos pulmões divididos em regiões ventral, medial e dorsal. Já no campo “Selecionar Cor”, o operador deve selecionar a cor a ser utilizada. O



Figura 4.10: recorte da parte 2 da interface do sistema SDEP.

campo “Resultados dos Pulmões”, apresenta cada cor que é utilizada na segmentação e os valores daquela cor em: área, % da imagem e % do pulmão direito e do pulmão esquerdo. Para o campo de “Resultados das Regiões” a diferença é que para cada uma das regiões ventral, medial e dorsal dos pulmões esquerdo e direito, são mostrados os resultados, que são apresentados em “Resultados dos Pulmões”.



Figura 4.11: recorte da parte 3 da interface do sistema SDEP.

4.7 Utilizando o sistema SDEP

A segmentação dos pulmões usando o sistema SDEP é um processo simples de ser realizado, sendo necessário os seguintes passos:

1. abrir a imagem através da barra de ferramenta “Arquivo” e selecionar a opção

“abrir”;

2. selecionar a imagem na barra “escolher imagem a segmentar”;
3. selecionar o número de divisões (caso deseje dividir os pulmões em regiões ventral, medial e dorsal);
4. clicar no botão “Seg.Pulmões”.

Para realizar os cálculos dos histogramas é preciso realizar os passos a seguir:

1. selecionar a faixa desejada no campo “selecionar faixa”;
2. selecionar a imagem no campo “selecionar imagem”;
3. clicar no botão “calcular”.

Já para fazer uma segmentação com a máscara colorida é preciso executar alguns passos, que são descritos em seguida:

1. selecionar a imagem no campo “selecionar imagem”;
2. selecionar a cor no campo “selecionar cor”;
3. digitar os valores de mínimo e máximo, para a faixa de densidade nos campos “ValorMin e ValorMax”;
4. clicar no botão “Aplicar Cores”.

A partir destas descrições de execução das operações do sistema SDEP, percebe-se que este utiliza processo rápidos e simples para sua aplicação rotineira.

4.8 Conclusão do Capítulo

Neste Capítulo as características do sistema SDEP e os passos necessários para realizar a utilização do algoritmo de segmentação, cálculos dos histogramas e a segmentação com a máscara colorida são apresentados. E também a descrição do sistema Osiris e dos algoritmos SC e SAB. No Capítulo 5 é vista uma comparação com os resultados obtidos com os sistemas Osiris e SDEP, e os algoritmos SC e SAB.

Capítulo 5

Resultados e Discussões

O sistema de Visão Computacional para detecção e quantificação de enfisema pulmonar (SDEP) proposto neste trabalho, realiza a segmentação dos pulmões, identificando as áreas normais e enfisematosas. Neste Capítulo são apresentados os resultados e as comparações das técnicas propostas para segmentação dos pulmões, detecção e quantificação do enfisema pulmonar, bem como uma comparação destes resultados com o sistema Osiris versão 4 e o algoritmo SC proposto por Silva e Carvalho (SILVA; CARVALHO, 2002) e o algoritmo SAB apresentado por Shojaii, Alirezaie e Babyn (SHOJAII; ALIREZAIE; BABYN, 2005).

5.1 Resultados

Nesta Seção são apresentados os resultados de todos os pontos que são considerados relevantes para uma comparação entre o algoritmo SC, algoritmo SAB, o sistema Osiris e o SDEP. São mostrados os resultados de cada algoritmo de segmentação descrito na Subseção 4.4, e as comparações das medidas apresentadas na Seção 4.2, entre o programa Osiris e o sistema SDEP.

Das 102 imagens dos voluntários saudáveis e das 141 imagens dos pacientes com DPOC, são selecionados um voluntário sadio e um paciente com DPOC de forma

aleatória e utilizadas 4 (quatro) imagens de cada para representar as segmentações obtidas com os algoritmos.

Para a comparação das medidas entre o programa Osiris e o sistema SDEP foram utilizadas as mesmas 8 (oito) imagens, 4 (quatro) de um voluntário sadio e 4 (quatro) de um paciente com DPOC. E para representar o resultado da máscara colorida é utilizada apenas uma imagem dentre as 8 (oito) imagens já selecionadas.

5.1.1 Resultados dos algoritmos de segmentação

Os resultados das segmentações são classificados em: a) segmentação correta - ocorre quando todo o contorno do tecido pulmonar é segmentado sem perdas ou acréscimo de estruturas; b) sobre-segmentação - ocorre um acréscimo de outras estruturas que não fazem parte do tecido pulmonar, como o hilo, e a união entre os pulmões; c) segmentação com perdas - ocorre quando há perda de parte do tecido pulmonar, que tenha relevância representativa para sua análise; d) segmentação errada - quando nenhum dos pulmões ou somente o esquerdo e/ou o direito são segmentados.

Os resultados de segmentação correta, sobre-segmentação, segmentação com perdas e segmentação errada, para os algoritmos SC e SAB, e os algoritmos de segmentação do sistema Osiris e do SDEP são apresentados na Tabela 5.1.

As imagens originais dos pulmões de um voluntário saudável são apresentadas nas Figuras de 5.1(a) a 5.1(g), e nas Figuras de 5.1(b) a 5.1(h), são mostradas as imagens dos pulmões de um paciente com DPOC, obtidas a partir da TCAR (Apêndice A). As Figuras 5.1(g) e 5.1(h) estão na posição prona, as demais estão na posição supina nos seguintes níveis de cortes: as Figuras 5.1(a) e 5.1(b) em ápice, as Figuras 5.1(c) e 5.1(d) em base e as Figuras 5.1(e) e 5.1(f) em hilo.

Os resultados das segmentação das imagens dos voluntários saudáveis e dos pacientes com DPOC para os algoritmos SC e SAB, sistema Osiris e o SDEP, são apresentados nas Figuras 5.2 e 5.3. Os resultados dos algoritmos SC e SAB são representados pela mesma imagem, em virtude, destes apresentarem os mesmos resultados



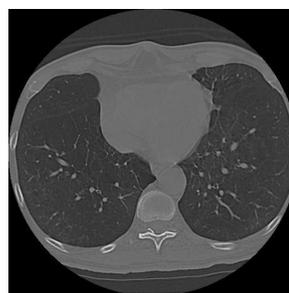
(a)



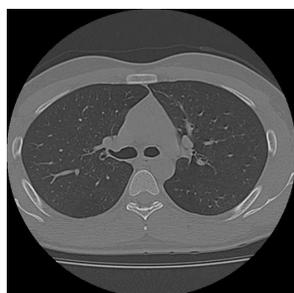
(b)



(c)



(d)



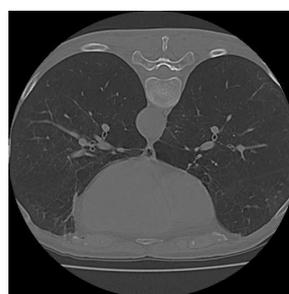
(e)



(f)



(g)



(h)

Figura 5.1: imagens de TCAR dos pulmões. Na coluna da esquerda os voluntários sadios e na coluna da direita os pacientes com DPOC.

	Imagens	Segmentação correta	Sobre- segmentação	Segmentação com perdas	Segmentação errada
Osiris	voluntário	61,76%	0,00%	38,24%	0,00%
	paciente	52,48%	0,71%	46,81%	0,00%
SC	voluntário	48,04%	46,08%	1,96%	3,92%
	paciente	67,38%	24,11%	1,42%	7,09%
SAB	voluntário	68,63%	28,43%	1,96%	0,98%
	paciente	70,21%	21,98%	4,26%	3,55%
SDEP	voluntário	94,12%	4,90%	0,98%	0,00%
	paciente	90,78%	4,26%	4,96%	0,00%

Tabela 5.1: resultados de segmentação das 102 imagens de TCAR dos pulmões de voluntários sadios e das 141 imagens de TCAR dos pulmões de pacientes com DPOC.

para a maioria das imagens, tendo em vista que os erros nestes dois algoritmos estão no início dos seus processos de segmentação, ou seja, na binarização, na aplicação das operações de abertura e fechamento, na detecção de bordas e na eliminação dos objetos de contornos conectados.

As segmentações corretas são apresentadas nas Figuras 5.2(b), 5.2(c), 5.2(d), 5.2(f), 5.2(h), 5.2(i), 5.2(k) e 5.2(l). As regiões dentro dos círculos brancos nas imagens, representam alguns dos erros ocorridos durante os testes de segmentação. Nas Figuras 5.2(a), 5.2(g) e 5.3(g) estão representados os erros de sobre-segmentação, já as Figuras 5.2(j), 5.2(e), 5.3(k), 5.3(b), 5.3(h) e 5.3(g) mostram a segmentação com perdas e as Figuras 5.2(j) e 5.3(j) apresentam a segmentação errada.

Os resultados das medidas de área e DPM, adquiridos através dos sistemas Osiris e SDEP, para os voluntários sadios e os pacientes com DPOC, são apresentados na Tabela 5.2. Estes valores são comparados por serem relevantes para um auxílio ao diagnóstico. Entretanto, o SDEP esteja apto a realizar outras medidas importantes para o auxílio ao diagnóstico, tais como: perímetro, área, volume, DPM e Perc15.

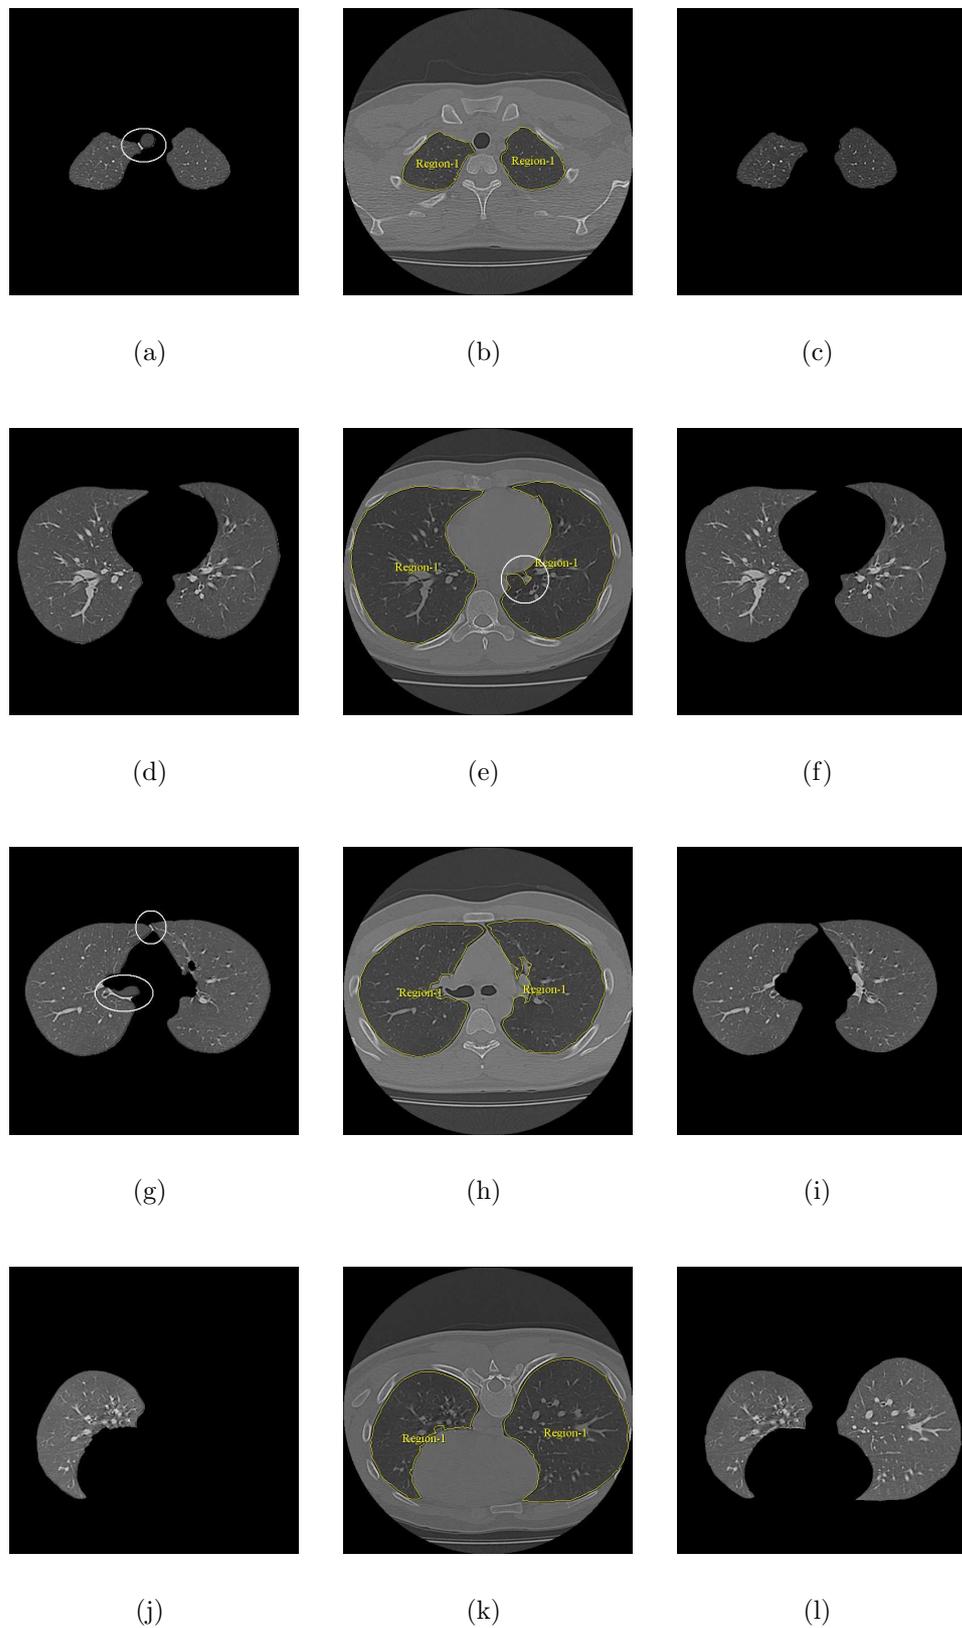


Figura 5.2: segmentação das imagens de TCAR dos pulmões de um voluntário sadio. Na coluna da esquerda dos algoritmos SC e SAB, na coluna central do sistema Osiris e na coluna da direita do SDEP.

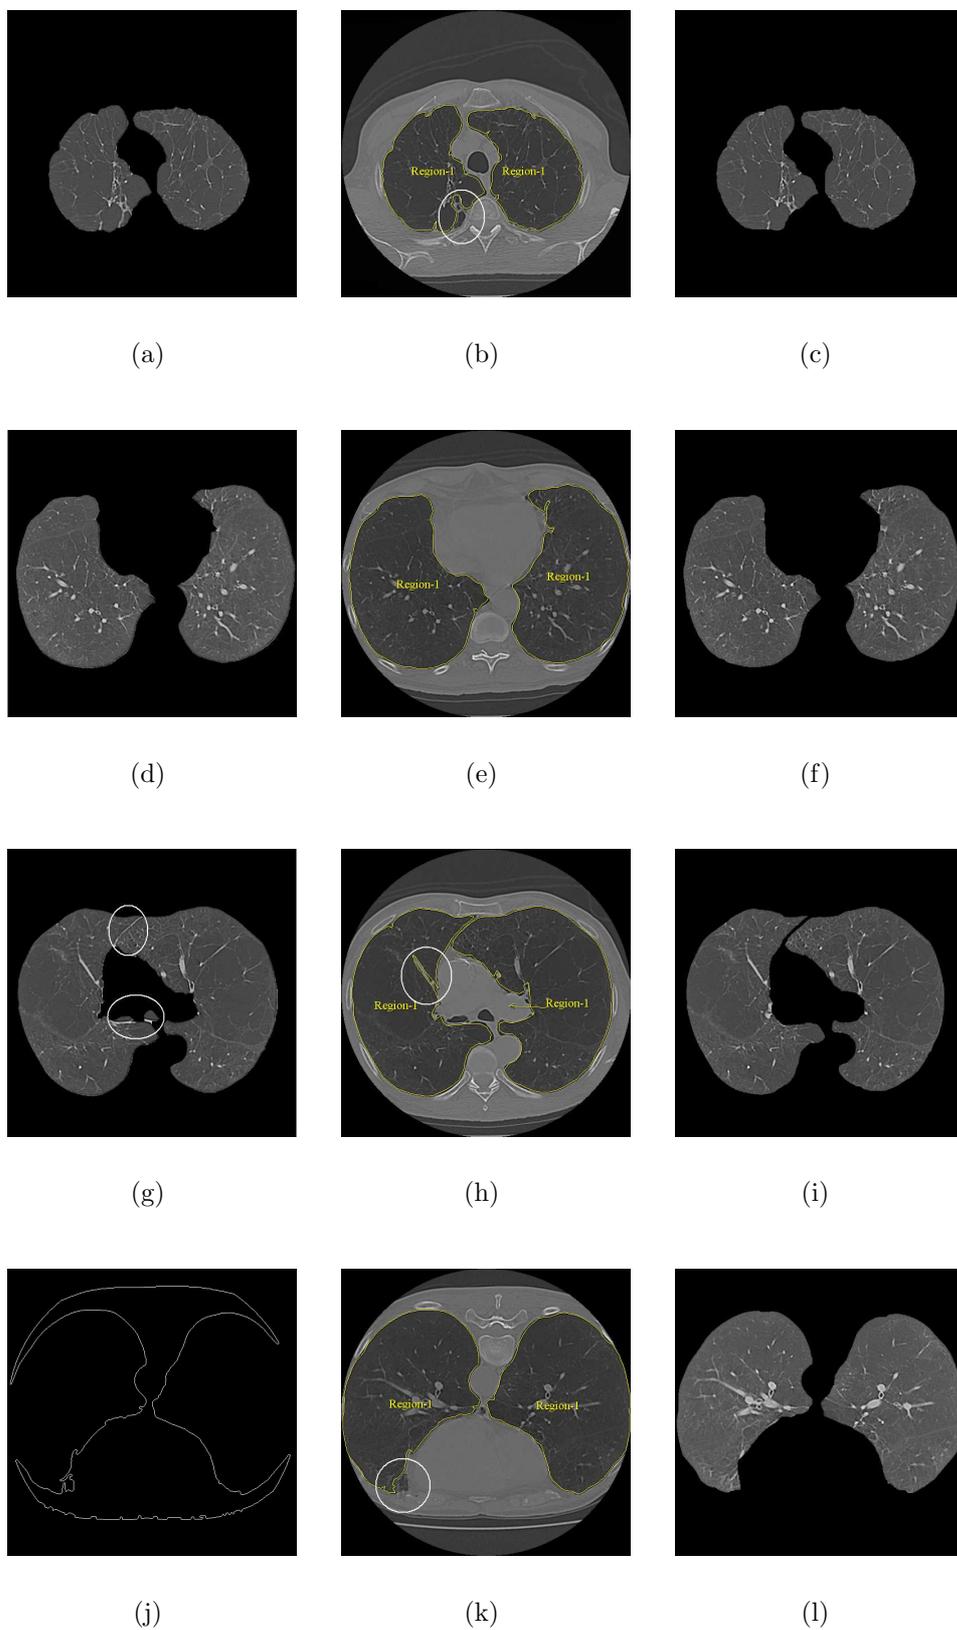


Figura 5.3: segmentação das imagens de TCAR dos pulmões de um paciente com DPOC. Na coluna da esquerda dos algoritmos SC e SAB, na coluna central do sistema Osiris e na coluna da direita do SDEP.

	Área (mm^2)				DPM (UH)	
	Pulmão Esquerdo		Pulmão Direito		Osiris	SDEP
	Osiris	SDEP	Osiris	SDEP		
Figura 5.1(a)	15.515	15.305,40	11.511	11.522,15	-828,23	-827,46
Figura 5.1(c)	2.872	2.733,89	2.911	2.830,75	-817,17	-822,16
Figura 5.1(e)	11.401	11.629,30	10.737	11.210,40	-830	-832,80
Figura 5.1(g)	7.648	7.857,38	13.395	13.446,70	-754,91	-758,62
Figura 5.1(b)	16.631	16.637,80	18.738	18.648,90	-941,25	-939,30
Figura 5.1(d)	8.728	8.871,80	9.684	9.651,79	-949,35	-952,83
Figura 5.1(f)	16.894	16.639,50	15.993	15.838,30	-880,30	-885,86
Figura 5.1(h)	17.357	17.363,70	18.187	17.973,90	-888,36	-892,90

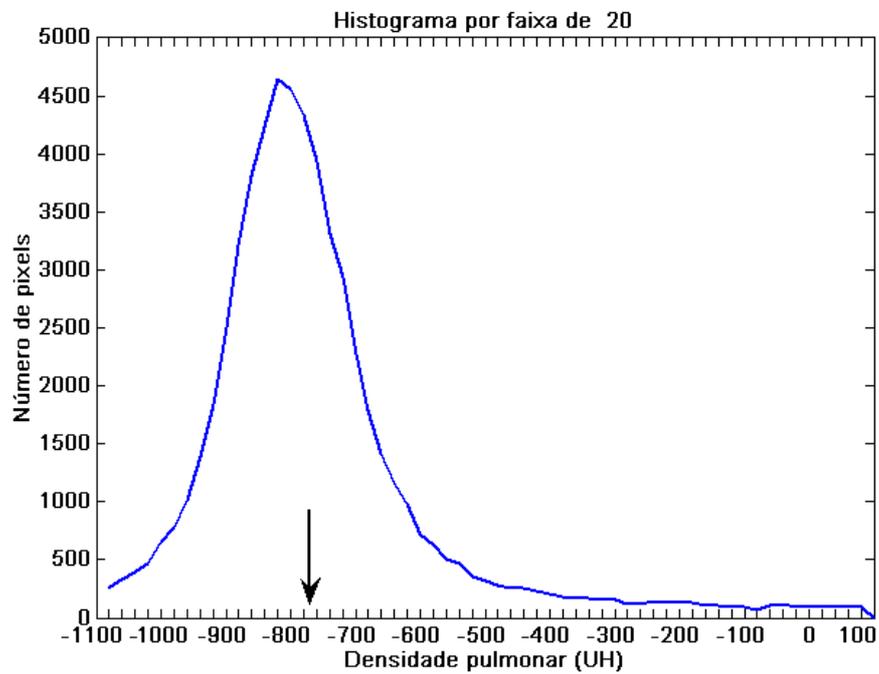
Tabela 5.2: comparação dos resultados dos sistemas Osiris e SDEP para as medidas de área e DPM de um voluntário sadio e de um paciente com DPOC.

5.1.2 Resultados dos histogramas por faixa de densidade e histograma acumulado

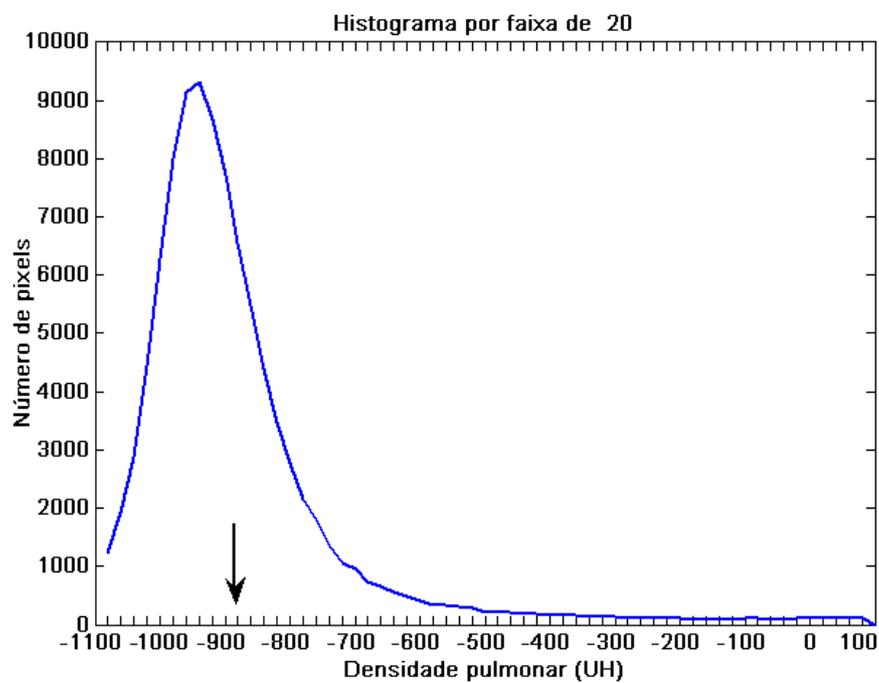
A variação dos tons de cinza no tecido dos pulmões dos pacientes com DPOC, possibilita evidenciar a evolução do enfisema. Para isto, nota-se que, o pico do gráfico do histograma por faixa de um voluntário sadio está mais para a direita ou no centro do histograma, enquanto que nos pulmões de um paciente com DPOC, o pico do gráfico é deslocado para esquerda. Nas Figuras 5.4(a) e 5.5(b), são apresentados os histogramas por faixas e seus respectivos valores das DPM de -758,62 UH e de -858 UH, indicados pelas setas.

O histograma acumulado possibilita que seja extraída a medida dos 15 pontos percentuais ou Perc15. Esta é também considerada como uma importante medida de auxílio à caracterização da evolução do enfisema pulmonar.

As curvas dos gráficos dos histogramas acumulados de um voluntário sadio e de um paciente com DPOC, calculados a partir dos histogramas por faixas, referentes às Figuras 5.4(a) e 5.5(b), e com os valores de -893 e -971 UH para o Perc15, indicados pelas setas, são mostradas nas Figura 5.5(a) e 5.5(b).

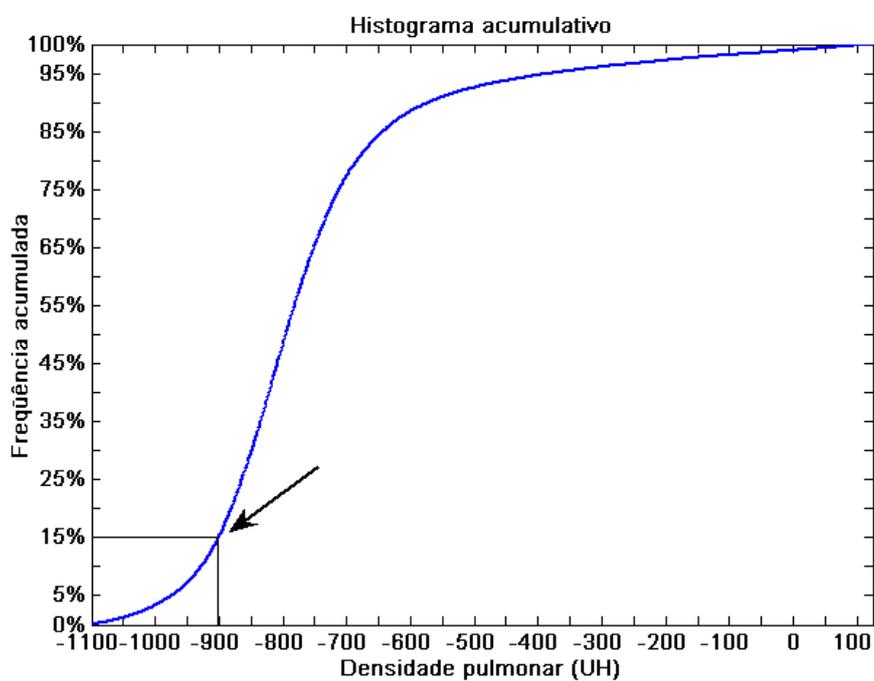


(a)

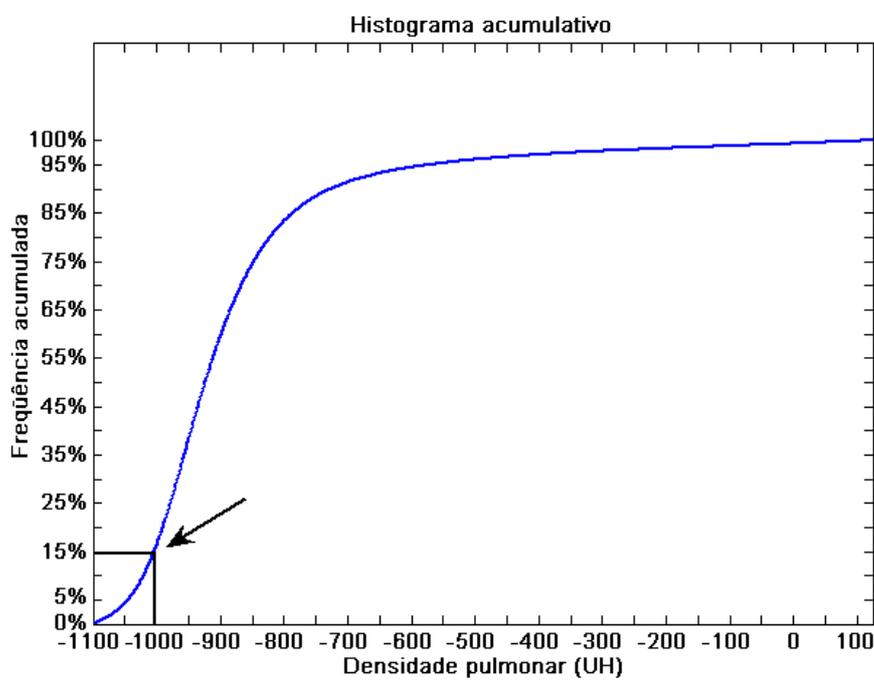


(b)

Figura 5.4: histograma por faixa de 20 em 20 (a) voluntário sadio mostrado na Figura 5.1(g) e (b) paciente com DPOC apresentado na Figura 5.1(h).



(a)



(b)

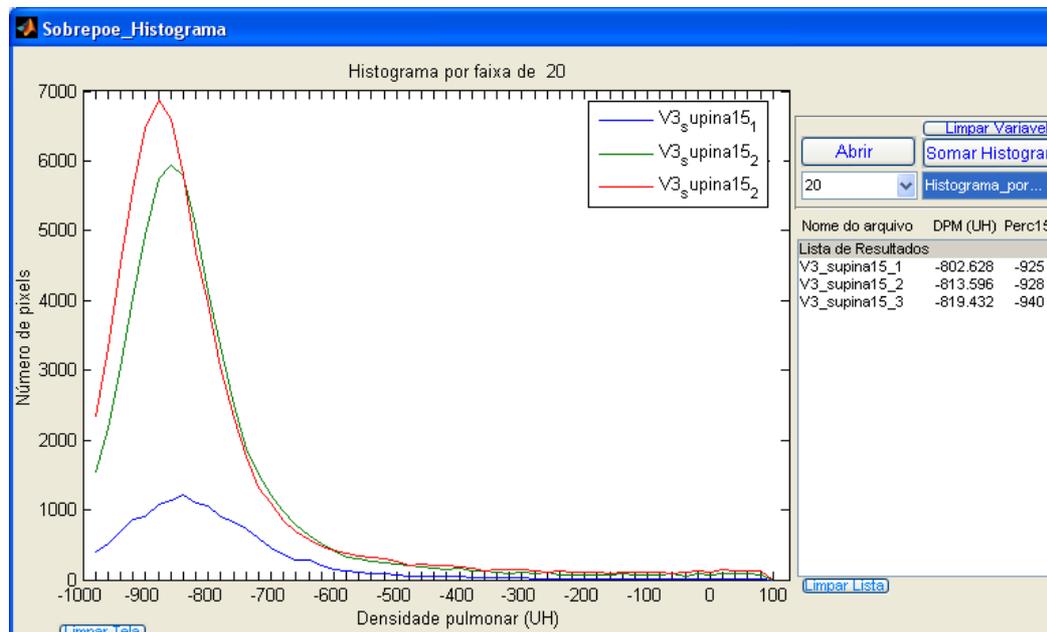
Figura 5.5: histograma acumulado (a) voluntário sadio mostrado na Figura 5.1(g) e (b) paciente com DPOC apresentado na Figura 5.1(h).

A janela do sistema SDEP responsável pela sobreposição dos histogramas é mostrada na Figura 5.6. Esta permite uma análise dos histogramas por faixa de densidade do histograma acumulado, juntamente com a visualização dos valores de DPM e Perc15. Também é possível com esta janela, realizar a soma dos histogramas de cada fatia dos pulmões de um mesmo paciente e gerar um único histograma por faixa com as informações de todas as fatias, construindo um gráfico completo da imagem dos pulmões. Nas Figuras 5.6(a) e 5.6(b) são apresentadas as sobreposições dos histogramas por faixa e do histograma acumulado de um voluntário sadio e, as medidas de DPM e Perc15 localizados na direita destas Figuras.

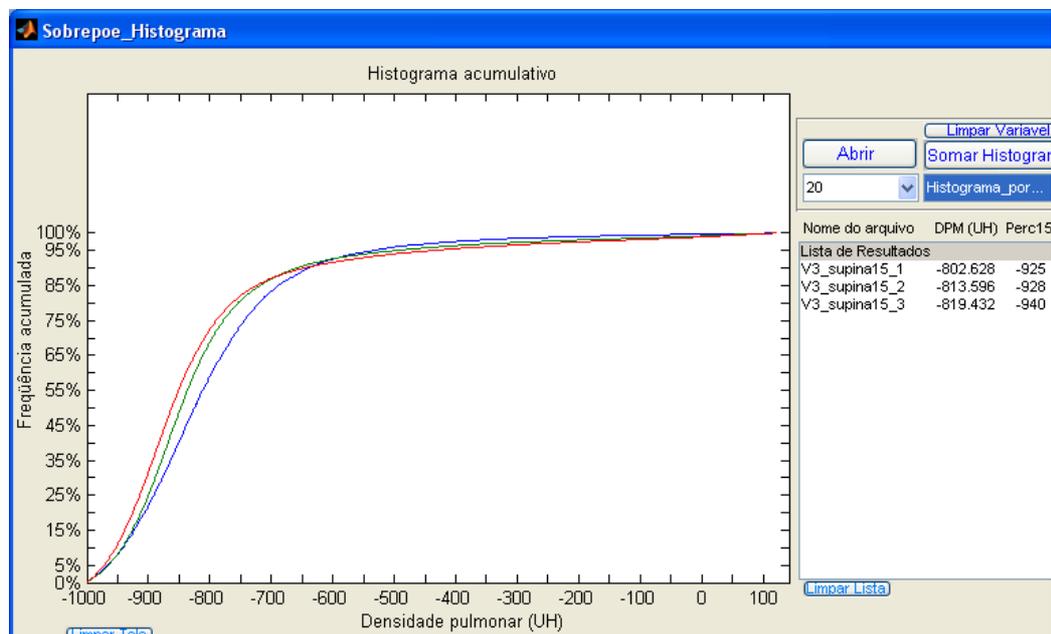
5.2 Resultados da segmentação através da máscara colorida (pseudo-cores)

A segmentação através da máscara colorida (pseudo-cores) para o programa Osiris é mostrada nas Figuras 5.7(a), 5.7(b), 5.7(c) e 5.7(d). Nesta segmentação, todo o parênquima pulmonar é segmentado pela cor verde e azul (Figuras 5.7(a) e 5.7(b)), causando uma sobre-segmentação da região que deveria compreender apenas os pulmões, e não os pixels que representam o ar fora do paciente, localizados na parte inferior e superior destas imagens. A segmentação deste programa é representada em 4 imagens, devido a este não realizar a operação de sobreposição das cores numa mesma imagem.

Na segmentação da máscara colorida do sistema SDEP (Figura 5.7(e)), somente o tecido pulmonar é segmentado, podendo ser utilizadas, ao mesmo tempo, várias pseudo-cores na mesma imagem, uma cor para cada faixa de densidade pulmonar que são: área hiperaerada de -1000 a -950 UH (verde claro), normalmente aerada -950 a -500 UH (azul), pouco aerada de -500 a -100 UH (magenta) e não-aerada de -100 a +100 UH (vermelho escuro). As densidades que estão na área hiperaerada são consideradas regiões enfisematosas (GEVENOIS et al., 1996; VIEIRA et al., 1998).



(a)



(b)

Figura 5.6: janela de sobreposição dos histogramas (a) sobreposição dos histogramas por faixas e (b) sobreposição dos histogramas acumulados.

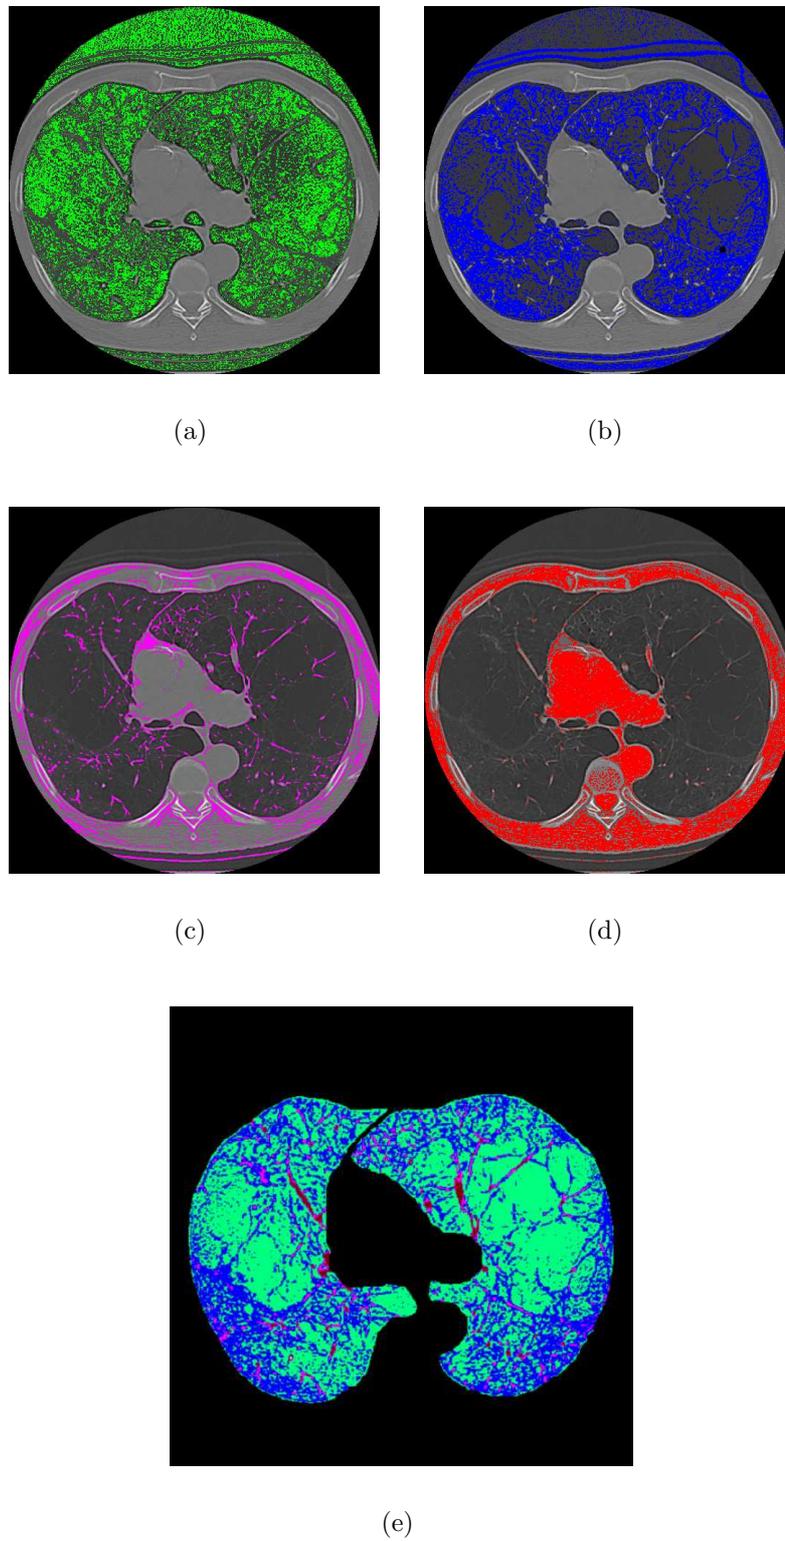


Figura 5.7: segmentação das faixas de densidade do tecido pulmonar. Do sistema Osiris de (a) -1000 a -950, (b) -949 a -700, (c) -699 a -100 até (d) -99 a +100. Do sistema SDEP (e) estão todas as faixas de densidade da Tabela 5.3.

Os resultados obtidos através da segmentação com a máscara colorida, referentes as faixas de densidade pulmonar para a Figura 5.7 são apresentados na Tabela 5.3. As faixas de densidade do sistema Osiris são ligeiramente diferentes, pelo fato do operador ter dificuldades para conseguir acertar estes valores. Esta operação é realizada automaticamente pelo SDEP, constituindo-se uma vantagem do mesmo sobre o sistema Osiris.

	Faixas	Cores	Área (mm^2)	(%) na imagem
Osiris	abaixo de -951	verde	38.121,00	42,00%
	De -951 a -495	azul	10.343,00	11,00%
	De -495 a -93	magenta	4.410,00	4,00%
	De -93 a +107	vermelho	11.802,00	13,00%
SDEP	abaixo de -950	verde claro	20.713,85	58,70%
	De -950 a -500	azul	13.800,91	39,11%
	De -500 a -100	magenta	500,67	1,42%
	De -100 a +100	vermelho escuro	146,472	0,42%

Tabela 5.3: resultados obtidos através da máscara colorida dos sistemas Osiris e SDEP para as faixas de densidade pulmonar da Figura 5.1(f) de um paciente com DPOC.

O sistema SDEP, também através da segmentação com a máscara colorida, fornece as medidas de área e porcentagem da região segmentada na imagem, para cada pulmão e para as regiões ventral (1), medial (2) e dorsal (3) dos pulmões esquerdo e direito, conforme é mostrado na Figura 5.8.

5.3 Limitações dos algoritmos de segmentação

Os diversos algoritmos apresentados, apesar de mostrarem resultados satisfatórios, possuem determinadas limitações que são intrínsecas às técnicas utilizadas nos seus desenvolvimentos. Na Figura 5.9 é apresentada uma seqüência de imagens que descrevem o processo de segmentação inicial dos algoritmos SC e SAB (SILVA; CARVALHO, 2002; SHOJAI; ALIREZAIE; BABYN, 2005), respectivamente.

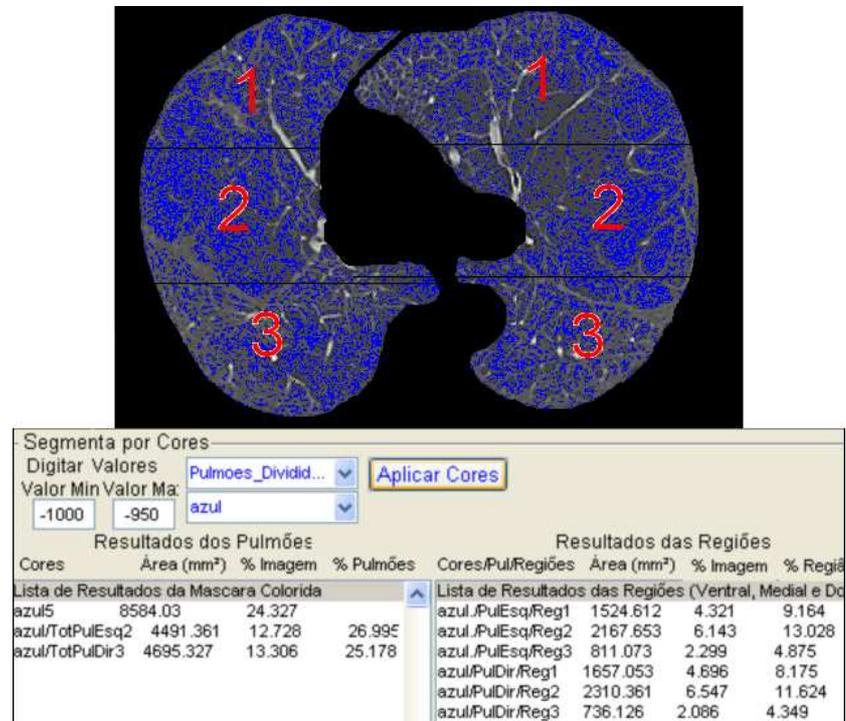


Figura 5.8: resultados em área e em porcentagem da segmentação pela máscara colorida do tecido pulmonar, para as regiões ventral (1), medial (2) e dorsal (3).

Em virtude da imagem do pulmão direito, apresentado na Figura 5.1(g), não ter parte da parede da cavidade pulmonar, o processo de segmentação dos algoritmos SC e SAB, já está comprometido, não conseguindo segmentar este pulmão. A binarização da imagem evidencia este fato, como mostrado na região dentro do círculo branco da Figura 5.9(a). O espaço na parede da cavidade pulmonar torna-se maior com a aplicação da operação de abertura, cuja diferença pode ser visualizada dentro da circunferência branca nas Figuras 5.9(a) e 5.9(b). Quando realizada a detecção das bordas, mostrada na Figura 5.9(c), são gerados objetos com contornos conectados e desconectados, dentre os quais o pulmão direito está inserido.

Desta forma, quando for realizada a eliminação dos objetos, o pulmão direito também é eliminado, resultando na imagem apresentada na Figura 5.9(d), o resultado

final desta segmentação é mostrado na Figura 5.2(j). Este mesmo processo de erro dos algoritmos SC e SAB ocorre para a sobre-segmentação, como é mostrada nas Figuras 5.2(a), 5.2(g) e 5.3(g), em que a parede de determinada estrutura é eliminada, unindo-a ao pulmão mais próximo. Isto ocorre principalmente na região dos hilos pulmonares.

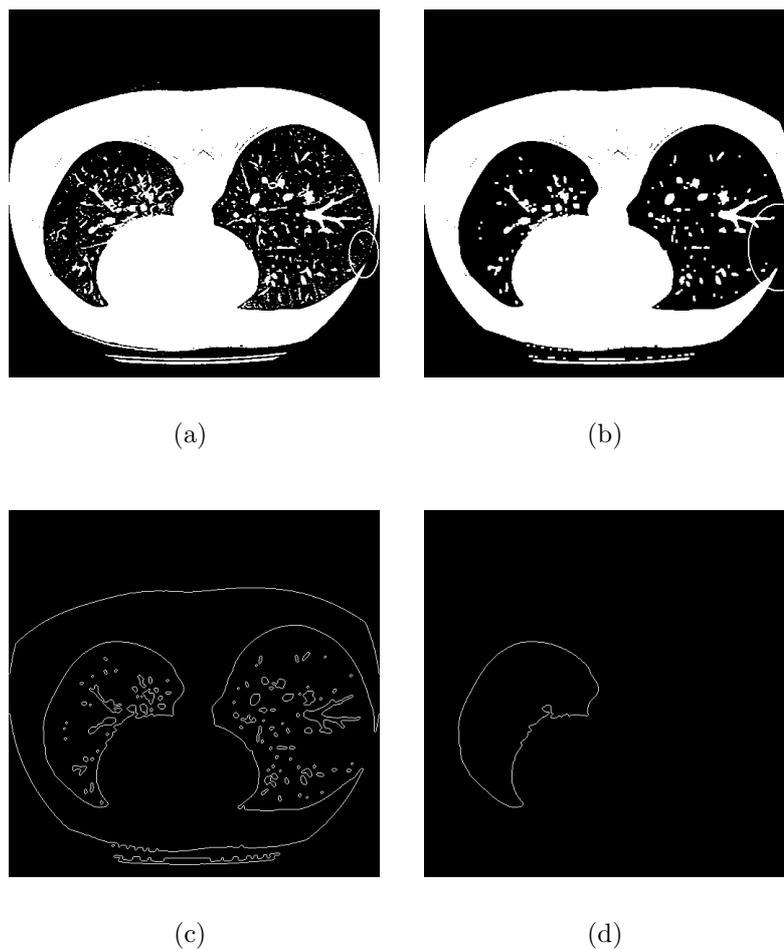


Figura 5.9: início da segmentação dos algoritmos SC e SAB, (a) imagem binarizada, (b) imagem da operação de abertura, (c) imagem da detecção de bordas e (d) imagem após a eliminação dos objetos com contornos conectados e desconectados.

Para os sistemas Osiris e SDEP, a limitação está ligada com o crescimento da semente que, dependendo do obstáculo anatômico encontrado, não consegue propagar o seu desenvolvimento. Na Figura 5.10 é mostrada esta limitação do algoritmo de

CR para estes dois sistemas.

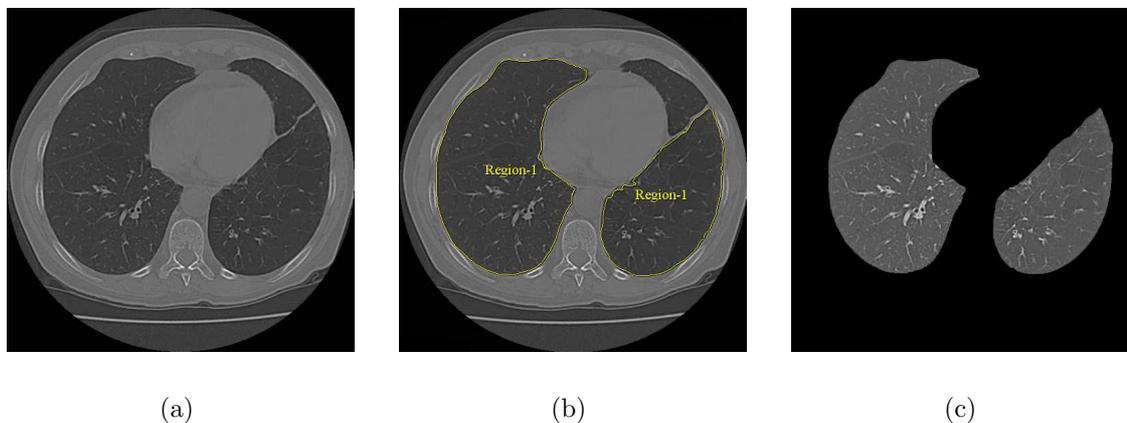


Figura 5.10: limitação da segmentação com a técnica de CR (a) imagem dos pulmões de um paciente com DPOC, (b) segmentação com perdas do sistema Osiris e (c) segmentação com perdas do sistema SDEP.

5.4 Discussões

A segmentação realizada pelo sistema SDEP apresenta resultados satisfatórios. Como é mostrado na Tabela 5.1, o sistema SDEP tem valores menores para todos os erros de segmentação, comparado com os algoritmos SC e SAB. Em relação ao sistema Osiris, na coluna de segmentação com perdas desta tabela, o sistema SDEP tem erro menor, e erro maior na coluna de sobre-segmentação e os dois sistemas são iguais na coluna de segmentação errada. O sistema SDEP tem um ajuste detalhado e preciso das bordas pulmonares, como apresentado na coluna direita das Figuras 5.3 e 5.2, e com menores erros de segmentação conforme Tabela 5.1.

Já o sistema Osiris, representa a segmentação através de um polígono fechado de cor amarela, que circunscribe a borda pulmonar. A precisão desta segmentação depende do ajuste dos parâmetros de segmentação. Na coluna central das Figuras 5.2 e 5.3, são mostradas as imagens segmentadas utilizando a configuração padrão

de segmentação do programa Osiris. Na Figura 5.2(e) é mostrado um exemplo da segmentação com perdas deste programa, que tem o maior valor, de acordo com a Tabela 5.1.

É importante salientar que o sistema Osiris apresenta resultados de segmentação com perdas em número bem superior aos demais algoritmos, devido ao uso da configuração padrão dos parâmetros de ajuste da técnica de CR, disponibilizada pelo mesmo. Com um ajuste mais adequado destes parâmetros, os valores dos resultados na coluna de segmentação com perdas podem ser reduzidos consideravelmente. Como a segmentação do programa Osiris, depende de cada operador, as imagens neste trabalho são segmentadas utilizando a configuração padrão disponibilizado pelo mesmo.

Os algoritmos SC e SAB apesar de produzirem uma segmentação detalhada das bordas pulmonares, mostram-se bastantes sensíveis à variações de espessura das paredes pulmonares. Isto compromete a segmentação, produzindo mais erros de sobre segmentação (ver Tabela 5.1), além de não serem capazes de segmentar as imagens cujo o campo de visualização dos pulmões não mostram parte das paredes laterais da cavidade pulmonar, conforme é mostrado na Figura 5.1(h). Este fato é confirmado pelo primeiro passo da segmentação com estes dois algoritmos, que consiste na binarização da imagem, conforme é ilustrado na Figura 5.9.

Os valores das medidas da área dos sistemas SDEP e Osiris são diferentes, devido ao programa Osiris segmentar com imprecisão os pulmões, de acordo com o especialista da área médica consultado. As medidas de DPM deste programa são ligeiramente diferentes devido a este não incluir densidades de estruturas que não são segmentadas. Isto elimina vasos e partes do tecido pulmonar, gerando valores maiores ou menores para a DPM, dependendo da parte do tecido não segmentado. Além disso, o fato deste incluir densidades foras das faixas do tecido pulmonar, contribui para alteração da DPM, ou seja, são usados os menores e os maiores valores encontrados na imagem, isto é, abaixo de -1000 UH e acima de +200 UH (SIEMENS, 2004; SLUIMER, 2005).

Já no sistema SDEP, para evitar este tipo de erro, as faixas são escolhidas pelo

operador ou então se utiliza a faixa padrão deste, que é de -1000 UH até +100 UH. Os resultados de sobreposições dos histogramas por faixas de densidades e dos histogramas acumulados, revelam que esta ferramenta do SDEP, apesar de simples, é de grande importância para uma avaliação da evolução do enfisema pulmonar. Desta forma, é possível fazer um acompanhamento de cada paciente, e identificar se está ocorrendo uma evolução ou estabilização da doença, através da análise comparativa entre os histogramas anteriores e atuais de um mesmo paciente.

A segmentação através da máscara colorida do sistema SDEP é mais eficiente, principalmente por ser automática e permitir a identificação e quantificação de forma precisa das faixas de densidades pulmonar hiperaerada, normalmente aerada, pouco aerada e não-aerada, aplicando várias cores em uma única imagem. Já o programa Osiris 4 utiliza uma pseudo-cor por vez, possibilitando apenas a análise de uma faixa de densidade pulmonar. Esta pseudo-cor é aplicada em toda a imagem dos pulmões, segmentando com a mesma pseudo-cor diferentes áreas que não fazem parte do tecido pulmonar. Por isso, ocorre um aumento das regiões segmentadas, interferindo na precisão dos resultados.

A seleção das faixas no programa Osiris 4 é realizada manualmente, através do *mouse* do computador, dificultando a precisão na escolha das faixas. O sistema SDEP por sua vez, pode utilizar mais de uma pseudo-cor sobre a mesma imagem, e a seleção das faixas são obtidas digitando os valores desejados em dois campos, denominados de “ValorMin” e “ValorMax”, destinados para esta finalidade, dando precisão na escolha das faixas (ver Figura 5.8). Isto também possibilita ao médico e pesquisador, investigar entre as faixas adotadas.

5.5 Conclusão do Capítulo

Neste capítulo são apresentados os resultados obtidos com os algoritmos SC e SAB e os sistemas Osiris e SDEP, bem como a comparação entre eles e suas limitações. No Capítulo 6 são mostradas as conclusões, contribuições e trabalhos futuros.

Capítulo 6

Conclusões, Contribuições e Trabalhos Futuros

Esta dissertação descreve um protótipo de um sistema de Visão Computacional implementado em Matlab para a segmentação automática dos pulmões, bem como para identificação e quantificação do enfisema pulmonar. Utiliza, para isto, um conjunto de imagens de Tomografia Computadorizada. São usadas imagens de TCAR de voluntários saudáveis e pacientes com DPOC. Realiza também uma comparação com o sistema Osiris e os algoritmos SC e SAB. Estes algoritmos também são implementados em ambiente de simulação.

O sistema SDEP revelou-se uma técnica de segmentação dos pulmões bastante eficiente, sendo mais satisfatório do que os outros métodos comparados neste trabalho. Além disso, o sistema SDEP constitui uma ferramenta que realiza a detecção e quantificação do enfisema pulmonar através da segmentação pela máscara colorida. Este também segmenta, na mesma imagem, diferentes faixas de densidades com várias pseudo-cores ao mesmo tempo, tarefa que o sistema Osiris não faz.

Desta forma, pode-se afirmar que o sistema SDEP é uma ferramenta útil tanto para o auxílio ao diagnóstico como para a pesquisa, pois disponibiliza informações

essenciais para a identificação das medidas pulmonares, bem como do enfisema pulmonar, e também aplica-se para o acompanhamento da evolução ou estabilização do enfisema pulmonar através, da sobreposição de histogramas e de medidas pulmonares como perímetro, área, volume, DPM e Perc15. O sistema SDEP é a maior contribuição deste trabalho.

Outras contribuições relevantes neste trabalho são a detecção e quantificação do enfisema pulmonar e das faixas de densidade através da máscara colorida. A principal vantagem desta técnica é segmentar com diferentes cores uma mesma imagem. Outra contribuição deste trabalho é a ferramenta de sobreposição dos histogramas, que contribui para uma análise visual mais detalhada dos histogramas dos pacientes.

Outros trabalhos futuros podem ser desenvolvidos a partir deste, ou as técnicas apresentadas podem ser utilizadas em outras aplicações. Para que o sistema SDEP tenha uma evolução gradual, outros desenvolvimentos são propostos a seguir:

- migrar para a linguagem C/C++, para maior portabilidade;
- segmentar em 3D, usando contornos ativos;
- estudar, comparar e implementar outros algoritmos de segmentação, como contornos ativos e *wavelets*;
- estudar, comparar e implementar outros algoritmos que usam texturas e fractais;
- implementar classificadores estatísticos e neuro-fuzzy;
- validar os resultados com radiologista e um Phantom.

Referências Bibliográficas

ALEXANDRIA, A. R. de. *Sistema de Reconhecimento Óptico de Algarismos para Medidores Convencionais de Energia*. Dissertação (Mestrado) — Univesidade Federal do Ceará, Fortaleza, junho 2005.

ANTONELLI, M.; LAZZERINI, B.; MARCELLONI, F. Segmentation and reconstruction of the lung volume. *ACM Symposium on Applied Computing*, Santa Fe, New Mexico, USA., p. 255–259, março 2005.

ARAÚJO, R. T. S. *Detecção de Manchas de Óleo na Superfície do Mar em Imagens de Radar de Abertura Sintética*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2004.

ARCHER, D. C. et al. Automated in vivo quantification of emphysema. *Radiology*, n. 188, p. 835–838, 1993.

BALLARD, D. H.; BROWN, C. M. *Computer Vision*. New Jersey: Prentice-Hall, 1982.

BANON, G. J. F.; BARRERA, J. *Bases da Morfologia Matemática para a análise de imagens binárias*. 2. ed. São José dos Campos: INPE, 1998.

BATRA, P. Role of high-resolution ct in the diagnosis and evaluation of pulmonary sarcoidosis. *Sarcoidosis*, v. 10, n. 2, p. 95–97, setembro 1993.

- BLECHSCHMIDT, R. A.; WERTHSCHÜTZKY, R.; LÖRCHER, U. Automated ct image evaluation of the lung: A morphology-based concept. *IEEE Transactions on Medical Imaging*, v. 20, n. 5, p. 434–442, fevereiro 2001.
- BONTRAGER, K. L. *Tratado de Técnica Radiológica e Base Anatômica*. 5. ed. Rio de Janeiro: Guanabara Koogan, 2000.
- BOVIK, A. *Handbook of Image and Video Processing*. San Diego, CA: Academic Press, 2000. ISBN 0-12-119790-5.
- BOYD, D. P.; LIPTON, M. J. Cardiac computed tomography. *Proceedings of the IEEE*, v. 71, n. 3, p. 298–307, março 1983.
- BRONZINO, J. D. *Biomedical Engineering Fundamentals*. 3. ed. Hartford, Connecticut, U.S.A: CRC Press, 2006.
- BROWN, M. S.; MCNITT-GRAY, M. F.; MANKOVICH, N. J. Method for segmenting chest ct image data using an anatomical model: Preliminary results. *IEEE Transactions on Medical Imaging*, v. 16, n. 6, p. 828–839, dezembro 1997.
- BUSAYARAT, S.; ZRIMEC, T. Automatic detection of pulmonary arteries and assessment of bronchial dilatation in hrct images of the lungs. *Proceedings of the ICSC Congress on Computational Intelligence Methods and Applications*, p. 1–5, dezembro 2005.
- BUTEAU, M.; MAKRAM-EBEID, S. A computer vision approach to emphysema detection and quantification. *Proceedings of the 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Amsterdam, p. 1089–1090, 1996.
- CELLI, B.; MACNEE, W. Standards for the diagnosis and treatment of patients with copd: a summary of the ats/ers position paper. *European Respiratory Journal*, v. 23, p. 932–946, 2004.

- CELLI, B. R. Standards for the optimal management of copd: A summary. *CHEST*, v. 113, p. 283–287, abril 1998.
- CHABAT, F.; YANG, G.-Z.; HANSELL, D. M. Obstructive lung diseases: Texture classification for differentiation at ct. *Radiology*, n. 228, p. 871–877, janeiro 2003.
- CHEN, S. et al. Automatic segmentation of lung fields from radiographic images of sars patients using a new graph cuts algorithm. *Proceedings of the 18th International Conference on Pattern Recognition (ICPR'06)*, v. 1, p. 271–274, 2006.
- CORCORAN, H. L.; RENNER, W. R.; MILSTEIN, M. Review of high-resolution ct of the lung. *RadioGraphics*, n. 12, p. 917–939, 1992.
- COXSON, H. O. et al. A quantification of the lung surface area in emphysema using computed tomography. *American Journal of Respiratory and Critical Care Medicine*, v. 159, p. 851–856, 1999.
- DRUMMOND, G. B. Computed tomography and pulmonary measurements. *British Journal of Anaesthesia*, Edinburgh-Royal Infirmary, v. 80, p. 665–671, 1998.
- EPSTEIN, C. L. *The Mathematics of Medical Imaging*. Philadelphia: University of Pennsylvania, 2001.
- FACON, J. *Morfologia Matemática: Teorias e Exemplos*. Curitiba: Editora Universitária Champagnat da Pontifícia Universidade Católica do Paraná, 1996.
- FELIX, J. H. S. et al. Lung and chest wall structures segmentation in ct images. *Proceedings of VIPIMAGE-First Eccomas Thematic Conference on Computational Vision and Medical Image Processing*, Porto, Portugal, v. 1, p. 291–294, outubro 2007.
- FIGUEROA, P. A. U. et al. Perfil radiológico do candidato ideal à cirurgia redutora de volume pulmonar no enfisema: uma revisão sistemática. *Jornal Brasileiro de Pneumologia*, v. 31, n. 3, p. 197–204, maio 2005.

FILHO, O. M.; NETO, H. V. *Processamento Digital de Imagens*. Rio de Janeiro: BRASPORT Livros e Multimídia Ltda, 1999.

FORTALEZA, S. C. B. *Efeitos da Administração de Pressão Positiva Contínua em Vias Aéreas de Modo não Invasivo Sobre a Aeração do Parênquima Pulmonar em Pacientes com Doença Pulmonar Obstrutiva Crônica*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, setembro 2006.

FRIMAN, O. et al. Recognizing emphysema - a neural network approach. *Proceedings. 16th International Conference on Pattern Recognition*, Quebec, Canada, v. 1, p. 512–515, agosto 2002.

GARNAVI, R. et al. A new segmentation method for lung hrct images. *Proceedings Digital Image Computing: Techniques and Applications DICTA*, v. 1, p. 357–364, dezembro 2005.

GEVENOIS, P. A. et al. Comparison of computed density and microscopic morphometry in pulmonary emphysema. *American Journal of Respiratory and Critical Care Medicine*, v. 154, n. 1, p. 187–192, julho 1996.

GEVENOIS, P. A.; YERNAULT, J. C. Can computed tomography quantify pulmonary emphysema. *European Respiratory Journal*, n. 5, p. 843–848, janeiro 1995.

GIRARD, C. et al. *Osiris-user manual*. 3.1. ed. Suíça, 1996.

GONZALEZ, R. C.; WOODS, R. *Digital Image Processing*. 2a. ed. EUA: Prentice Hall, 2002.

GOTWAY, M. B. et al. High-resolution ct of the lung: Patterns of disease and differential diagnoses. *Radiologic Clinics of North America*, n. 43, p. 513–542, 2005.

GUO, J. et al. Integrated system for ct-based for assessment of parenchymal lung disease. *Proceedings. IEEE International Symposium on Biomedical Imaging*, v. 1, p. 871–874, julho 2002.

HARALICK, R. M. *Computer and Robot Vision*. New York: Addison-Wesley, 1972.

HAYASHI, K. et al. Radiographic and ct appearances of the major fissures. *RadioGraphics*, v. 21, n. 4, p. 861–874, agosto 2001.

HAYHURST, M. D.; FLENLEY, C. D.; MCLEAN, A. Diagnosis of pulmonary emphysema by computerized tomography. *Lancet*, v. 2, n. 8398, p. 320–322, 1984.

HEARD, B. E. et al. The morphology of emphysema, chronic bronchitis, and bronchiectasis: Definition, nomenclature, and classification. *Journal of Clinical Pathology*, v. 32, n. 9, p. 882–892, setembro 1979.

HENDEE, W. R.; RITENOUR, E. R. *Medical Imaging Physics*. 4. ed. New York: Wiley-Liss, 2002.

HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. description of system. *British Journal of Radiology*, v. 46, n. 552, p. 1016–1022, dezembro 1973.

_____. Nobel award address: Computed medical imaging. *Med Phys*, v. 7, n. 4, p. 283–290, agosto 1980.

HU, S.; HOFFMAN, E. A.; REINHARDT, J. M. Automatic lung segmentation for accurate quantitation of volumetric x-ray ct images. *IEEE Transactions on Medical Imaging*, v. 20, n. 6, p. 490–498, junho 2001.

ITAI, Y. et al. Automatic segmentation of lung areas based on snakes and extraction of abnormal areas. *Proceedings of the 17th IEEE International Conference on Tools with Artificial Intelligence ICTAI*, 2005.

JAN, J. *Medical Image Processing Reconstruction and Restoration: Concepts and Methods*. Danvers, MA, U.S.A: CRC Press, 2006.

- JARDIM, J. R.; OLIVEIRA, J. A. de; NASCIMENTO, O. Revisão de alguns aspectos de epidemiologia e tratamento da doença estavel. *Sociedade brasileira de pneumologia e fisiologia*, 2006.
- JHA, P.; CHALOUPKA, F. J. *Curbing the epidemic: governments and the economics of tobacco control*. Washington, D.C. 20433: British Medical Journal, 1999. ISBN 0-8213-4519-2.
- KALENDER, W. A. Review: X-ray computed tomography. *Physics in Medicine and Biology*, v. 51, n. 13, p. 29–43, junho 2006.
- KALENDER, W. A. et al. Spiral volumetric ct with single-breath-hold technique, continuous transport, and continuous scanner rotation. *Radiology*, v. 176, n. 1, p. 181–183, março 1990.
- KHAWAJA, M. A.; AZIZ, M. Z.; IQBAL, N. Effectual lung segmentation for cad systems using ct scan images. *Proceedings of INMIC 8th International Multitopic Conference*, p. 49–54, dezembro 2004.
- KLEIN, J. S. et al. High-resolution ct diagnosis of emphysema in symptomatic patients with normal chest radiographs and isolated low diffusing capacity. *Radiology*, v. 182, n. 3, p. 817–821, março 1992.
- KUBO, M. et al. Extraction of pulmonary fissures from thin-section ct images using calculation of surface-curvatures and morphology filters. *Proceedings. International Conference on Image Processing*, v. 2, p. 637–640, setembro 2000.
- KUHNIGK, J.-M. et al. Lung lobe segmentation by anatomy-guided 3d watershed transform. *Proceedings of the SPIE International Society for Optical Engineering*, v. 5032, p. 1482–1490, maio 2003.
- KURASHIMA, K. et al. High resolution ct and bronchial reversibility test for diagnosing copd. *Respirology*, v. 10, n. 3, p. 316–322, junho 2005.

LOPES, A. J. et al. A tomografia computadorizada de alta resolução na sarcoidose pulmonar. *Pulmão Rj*, v. 14, n. 2, p. 109–114, abril-maio-junho 2005.

MADANI, A.; KEYZER, C.; GEVENOIS, P. A. Quantitative computed tomography assessment of lung structure and function in pulmonary emphysema. *European Respiratory Journal*, v. 18, n. 8, p. 720–730, outubro 2001.

MADANI, A. et al. Pulmonary emphysema: Objective quantification at multi-detector row ct-comparison with macroscopic and microscopic morphometry. *Radiology*, v. 238, n. 3, p. 1036–1043, março 2006.

MAHESH, M. The aapm/rsna physics tutorial for residents: Search for isotropic resolution in ct from conventional through multiple-row detector. *RadioGraphics*, v. 22, n. 4, p. 949–962, julho-agosto 2002.

MATHERON, G. *Random sets and integral geometry*. New York: Wiley, 1975.

MAYO, J. R. et al. High-resolution ct of the lungs: An optimal approach. *Radiology*, v. 163, n. 2, p. 507–510, maio 1987.

MISHIMA, M. et al. Complexity of terminal airspace geometry assessed by lung computed tomography in normal subjects and patients with chronic obstructive pulmonary disease. *Proceedings of the National Academy of Sciences of the United States of America PNAS*, v. 96, n. 16, p. 8829–8834, agosto 1999.

MORI, K. et al. Automated anatomical labeling of the bronchial branch and its application to the virtual bronchoscopy system. *IEEE Transactions on Medical Imaging*, v. 19, n. 2, p. 103–114, fevereiro 2000.

MULLER, N. L. et al. Density mask. an objective method to quantitate emphysema using computed tomography. *Chest*, v. 94, n. 4, p. 782–787, outubro 1988.

MURATA, K. et al. Centrilobular lesions of the lung: Demonstration by high-resolution ct and pathologic correlation. *Radiology*, v. 161, n. 3, p. 641–645, dezembro 1986.

- NAKANO, Y. et al. Computed tomographic measurements of airway dimensions and emphysema in smokers. *American Journal of Respiratory and Critical Care Medicine*, v. 162, n. 3, p. 1102–1108, setembro 2000.
- NEMA. *Digital Imaging and Communications in Medicine*. Rosslyn, Virginia USA, 2007. Disponível em: <ftp://medical.nema.org/medical/dicom/>. Acesso em: 3 outubro de 2007.
- NISHIMURA, K. et al. Diffuse panbronchiolitis: Correlation of high-resolution ct and pathologic findings. *Radiology*, v. 184, n. 3, p. 779–785, setembro 1992.
- NIXON, M. S.; AGUADO, A. S. *Feature Extraction and Image Processing*. 1. ed. Woburn, Massachusetts: Newnes, 2002. ISBN 0750650788.
- O'DONELL, D. E.; WEBB, K. A. Exertional breathlessness in patients with chronic airflow limitation: the role of lung hyperinflation. *Am Rev Respir Dis*, v. 148, n. 5, p. 1351–1357, novembro 1993.
- OTSU, N. A threshold selection method from gray-level histograms. *IEEE Trans. Systems, Man and Cybernetics*, v. 9, n. 1, p. 62–66, 1979.
- PARK, K. J.; BERGIN, C. J.; CLAUSEN, J. L. Quantitation of emphysema with three-dimensional ct densitometry: Comparison with two-dimensional analysis, visual emphysema score, and pulmonary function test results. *Radiology*, v. 211, n. 2, p. 541–547, maio 1999.
- PARK, W.; HOFFMAN, E. A.; SONKA, M. Segmentation of intrathoracic airway trees: A fuzzy logic approach. *IEEE Transactions on Medical Imaging*, v. 17, n. 4, p. 489–497, agosto 1998.
- PRASAD, M. N.; SOWMYA, A.; KOCH, I. Feature subset selection using ica for classifying emphysema in hrct images. *Proceedings of the 17th International Conference on Pattern Recognition ICPR*, v. 4, p. 515–518, agosto 2004.

- PRATT, W. K. *Digital Image Processing*. 3. ed. New York: John Wiley and Sons, Inc, 2001. ISBN 0-471-22132-5.
- PUGATCH, R. D.; FALING, L. J. Computed tomography of the thorax: a status report. *Chest*, v. 80, n. 5, p. 618–626, novembro 1981.
- SCHILHAM, A. M. R. et al. Local noise weighted filtering for emphysema scoring of low-dose ct images. *IEEE Transactions on Medical Imaging*, v. 25, n. 4, p. 451–463, abril 2006.
- SERRA, J. *Image analysis and mathematical morphology*. London: Academic Press, 1982.
- SHOJAI, R.; ALIREZAIE, J.; BABYN, P. Automatic lung segmentation in ct images using watershed transform. *IEEE International Conference on Image Processing ICIP*, v. 2, n. 1270-1273, setembro 2005.
- SIEMENS. *Computed Tomography: Its History and Technology*. Alemanha, setembro 2004. Disponível em: <www.SiemensMedical.com>. Acesso em: 21 maio de 2007.
- SILVA, A. et al. Fast pulmonary contour extraction in x-ray ct images: A methodology and quality assessment. *Physiology and Function from Multidimensional Images*, v. 4321, p. 216–224, 2001.
- SILVA, A. C. *Algoritmos para Diagnóstico Assistido de Nódulos Pulmonares Solitários em Imagens de Tomografia Computadorizada*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro - PUC - RIO, Rio de Janeiro, Brasil, fevereiro 2004.
- SILVA, A. C.; CARVALHO, P. C. P. Sistema de análise de nódulo pulmonar. *II Workshop de informática aplicada a Saúde*, Universidade de Itajai, 2002.
- SILVA, J. S. S. da. *Segmentação Pulmonar em Estudos de Tomografia Axial Computadorizada*. Dissertação (Mestrado) — Universidade de Aveiro, 2005.

SILVA, V. L. da Costa e; DAVID, A. *Building blocks for tobacco control: a handbook*. Geneva, Suíça: World Health Organization, 2004. ISBN 9241546581.

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.

SLUIMER, I. C. *Automated image analysis of the pathological lung in CT*. Tese (Doutorado) — University Medical Center Utrecht, Utrecht, Netherlands, 2005.

SNIDER, G. L. et al. The definition of emphysema: report of a national heart, lung and blood institute, division of lung diseases, workshop. *Am Rev Respir Dis*, n. 132, p. 182–185, 1985.

SONKA, M.; PARK, W.; HOFFMAN, E. A. Rule-based detection of intrathoracic airway trees. *IEEE Transactions on Medical Imaging*, v. 15, n. 3, p. 314–326, junho 1996.

STERGIOPOULOS, S. *Advanced signal processing handbook : theory and implementation for radar, sonar, and medical imaging real-time systems*. Boca Raton, Florida 33431: CRC Press LLC, 2001. ISBN 0-8493-3691-0/01.

STOEL, B. C.; STOLK, J. Optimization and standardization of lung densitometry in the assessment of pulmonary emphysema. *Investigative Radiology*, v. 39, n. 11, p. 681–688, novembro 2004.

SWENSEN, S. J. et al. High-resolution ct of the lungs: Findings in various pulmonary diseases. *American Journal of Roentgenology*, v. 158, n. 5, p. 971–979, maio 1992.

TOSHIBA. *Manual de operação do sistema: tomógrafo computadorizado de raio-x para corpo inteiro: Aquisição de dados de calibração*. São Paulo, 1997.

UPPALURI, R. et al. Computer recognition of regional lung disease patterns. *American Journal of Respiratory and Critical Care Medicine*, v. 160, n. 2, p. 648–654, janeiro 1999.

_____. Quantification of pulmonary emphysema from lung computed tomography images. *American Journal of Respiratory and Critical Care Medicine*, v. 156, n. 1, p. 248–254, março 1997.

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, n. 5, p. 1571–1577, novembro 1998.

VINCENTE, L.; SOILLE, P. Watersheds in digital spaces: An efficient algorithm based on immersion simulations. *IEEE Transaction on Pattern analyse and machine intelligence*, v. 13, n. 6, p. 583–598, junho 1991.

WEBB, W. R.; MÜLLER, N. L.; NAIDICH, D. P. *High resolution CT of the lung*. 3. ed. Philadelphia: Lippincott Williams and Wilkins, 2001.

WEBB, W. R. et al. Normal and diseased isolated lungs: high-resolution ct. *Radiology*, v. 166, n. 1, p. 81–87, janeiro 1988.

WEI, Q. et al. Segmentation of lung lobes in volumetric ct images for surgical planning of treating lung cancer. *Proceedings of the 28th Annual International Conference of the IEEE Engineering in Medicine and Biology Society EMBS*, p. 4869–4872, agosto 2006.

WINKELER, G. F. P. *Efeitos Agudos da Administração de Pressão Positiva Contínua em Vias Aéreas de Modo não Invasivo Sobre o Parênquima Pulmonar de Voluntários Sadios nas Posições Supina e Prona: Alterações na Tomografia Computadorizada de Alta Resolução*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2006.

WRIGHT, J. L.; CHURG, A. Review: Advances in the pathology of copd. *Histopathology*, Vancouver, Canada, v. 49, n. 1, p. 1–9, julho 2006.

XU, Y. et al. Mdct-based 3-d texture classification of emphysema and early smoking related lung pathologies. *IEEE Transactions on Medical Imaging*, v. 25, n. 4, p. 464–475, abril 2006.

YILDIZ, A. et al. Hrcet evaluation of the accessory fissures of the lung. *European Journal of Radiology*, v. 49, n. 3, p. 245–249, março 2004.

ZHANG, L.; HOFFMAN, E. A.; REINHARDT, J. M. Atlas-driven lung lobe segmentation in volumetric x-ray ct images. *IEEE Transactions on Medical Imaging*, v. 25, n. 1, p. 1–16, janeiro 2006.

Apêndices

Apêndice A

Tomografia Computadorizada

A Tomografia Computadorizada (TC) foi desenvolvida ao longo de décadas, com a descoberta dos raios-X em 1885 pelo físico Wilhelm Conrad Röntgen, permitindo realizar radiografias do corpo humano e representar imagens de duas dimensões (2D), apresentando poucas informações sobre o objeto radiografado. Para o desenvolvimento da TC era necessário a criação de uma descrição matemática que permitisse quantificar um corpo de forma física real ou mais próxima da realidade. A teoria matemática de reconstrução de imagens foi então formulada independentemente em 1905 por Hendrik Antoon Lorentz e, em 1917 por, Johan Radon (SLUIMER, 2005).

A partir destas teorias matemáticas, Alan McLeod Cormack e Godfrey M. Hounsfield idealizaram a representação matemática usada para inferir uma estrutura anatômica tridimensional (3D) para uma grande coleção de informações de diferentes projeções bidimensionais (2D) (EPSTEIN, 2001). Cormack desenvolveu em 1956 a teoria matemática dos múltiplos raios projetados sobre o corpo, em diferentes ângulos, mas em um único plano, nos quais forneceriam uma imagem melhor do que um raio único, usado na radiografia. No início da década de 70, foi desenvolvida por Hounsfield uma máquina de tomografia que permite computar imagens em seções cruzadas de alta qualidade e processar um número muito grande de medidas com operações

matemáticas complexas, e ainda adquirir uma imagem com grande precisão (KALENDER, 2006).

A.1 Primeira geração da TC

A primeira geração da TC inventada por Hounsfield foi introduzida comercialmente em 1973, chamada de EMI Mark (HOUNSFIELD, 1973). Esta TC usava uma geometria de raios cilíndricos paralelos, em que a aquisição dos dados era feita por meio de raios cilíndricos colimados (finos) de diâmetro na faixa de 0,5 a 10 mm, direcionado a um único detector no outro lado do paciente. O detector e a fonte de raios-X eram alinhados em uma estrutura de escaneamento. Uma única projeção era adquirida rotacionando a fonte e o detector de raios-X sobre o centro do paciente por aproximadamente 1 grau, e transladando na outra direção. Este processo de rotação e translação era repetido em 180 ou 240 graus. Na Figura A.1 é apresentado um diagrama esquemático da TC de primeira geração (JAN, 2006; BRONZINO, 2006).

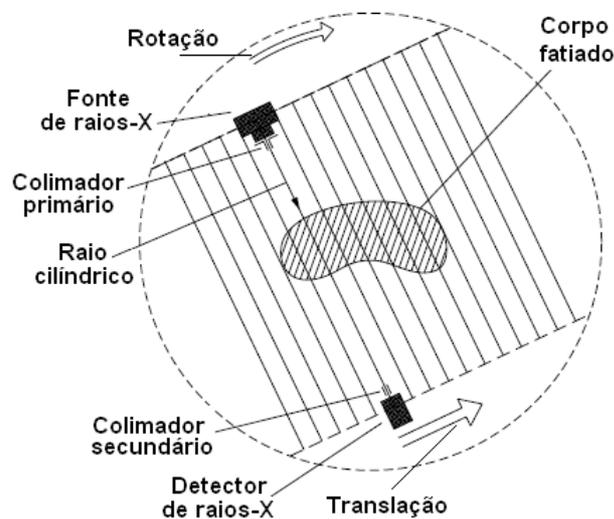


Figura A.1: desenho esquemático da primeira geração, adaptada de (JAN, 2006).

Os raios cilíndricos, altamente colimados, provêm uma excelente rejeição de espalhamento da radiação no paciente. Entretanto, o movimento complexo do escaneamento resulta em longos tempos (aproximadamente 5 minutos) para escanear, fazendo que uma grande radiação de raios-X sejam emitidas no paciente. Embora a resolução de contraste de estruturas internas eram sem precedentes, as imagens reconstruídas tinham baixa resolução de espaço (na ordem de 3 mm para um campo de visão de 25 cm e matriz 80×80) e uma resolução muito pobre também para o eixo z (13 mm de espessura por seção ou fatia) (MAHESH, 2002; JAN, 2006).

A.2 Segunda geração da TC

Na segunda geração o tempo de escaneamento das imagens obtidas a partir da TC foi reduzido em relação à primeira geração. A redução deste tempo deveu-se ao uso de um leque de raios-X cilíndricos e um vetor de detectores lineares ao invés de apenas um detector. Desta forma, várias projeções podiam ser obtidas em uma única translação através da soma do deslocamento angular do vetor de detectores. Conseqüentemente, um sistema que usava quatro detectores podia rotacionar 4° para a próxima projeção ao invés de 1° , reduzindo o tempo de escaneamento por um fator de 4, fazendo então 45 translações em vez de 180 para adquirir uma seção. Na Figura A.2 é mostrado o diagrama de uma TC de segunda geração (MAHESH, 2002; JAN, 2006).

Os modelos da segunda geração tiveram até 53 detectores, que eram rápidos o bastante, cerca de 10 segundos, para permitir a aquisição durante uma parada de respiração, sendo este o primeiro modelo que permitiu o escaneamento do tórax. Os algoritmos de reconstruções são ligeiramente mais complicados, comparados com os algoritmos da primeira geração, porque têm que controlar os dados de projeções dos leques de raios-X cilíndricos (MAHESH, 2002; BRONZINO, 2006).

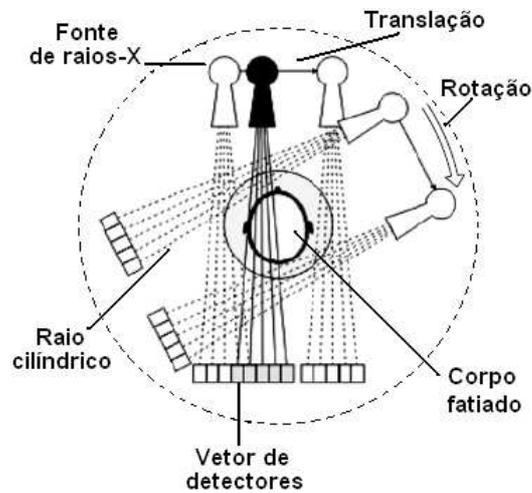


Figura A.2: desenho esquemático da segunda geração, adaptada de (KALENDER, 2006).

A.3 Terceira geração da TC

Uma das características mais proeminentes da terceira geração é o uso somente de rotações e a construção de seções com espessuras de 1 a 10 mm. Para isto, um leque de raios-X cilíndricos deve ser largo o bastante (30° a 60°) para cobrir completamente a fatia do corpo (objeto) (JAN, 2006). O paciente é localizado no centro da TC, enquanto que os detectores e a fonte de raios-X, encontram-se nas extremidades da estrutura cilíndrica, como é mostrado na Figura A.3.

Nesta geração, o vetor de detectores são curvados em um segmento circular com o foco da radiação no centro. Os detectores são espaçados igualmente e unidos à fonte de raios-X, ambos giram juntos, realizando um único movimento de rotação para escanear cada seção. O formato da terceira geração permite que seja colocado um fino septo (divisor) de tungstênio entre os detectores do vetor, focalizados na fonte de raios-X para rejeitar a radiação espalhada (MAHESH, 2002; BRONZINO, 2006).

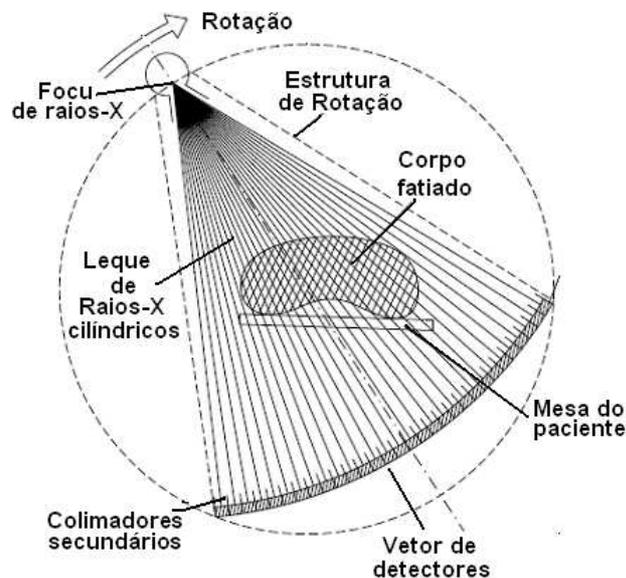


Figura A.3: desenho esquemático da terceira geração, adaptada de (JAN, 2006).

A.4 Quarta geração da TC

Na quarta geração a fonte de raios-X é posicionado, para girar sobre o paciente dentro do espaço entre o paciente e o anel de detectores, como é apresentado na Figura A.4. Esta apresenta um formato em anel com detectores de tamanho menor, com nível de desempenho semelhante ao da terceira geração, bem como a redução no tempo de escaneamento das imagens. A quarta geração difere principalmente da geração anterior, porque a fonte de raios-X gira sobre o centro do corpo, enquanto o anel de detectores permanece estacionária (MAHESH, 2002; JAN, 2006).

A desvantagem desta geração é um uso menos eficiente dos detectores com relação a terceira geração, pois apenas um quarto dos detectores são usados em qualquer ponto durante o escaneamento. Outra desvantagem é a ausência do septo (divisor) focalizado para rejeitar a radiação espalhada, tendo em vista que o anel de detectores não está fixado na fonte de raios-X, e o imageamento é menos favorável que o da terceira geração, porque os colimadores secundários não podem ser aplicados com

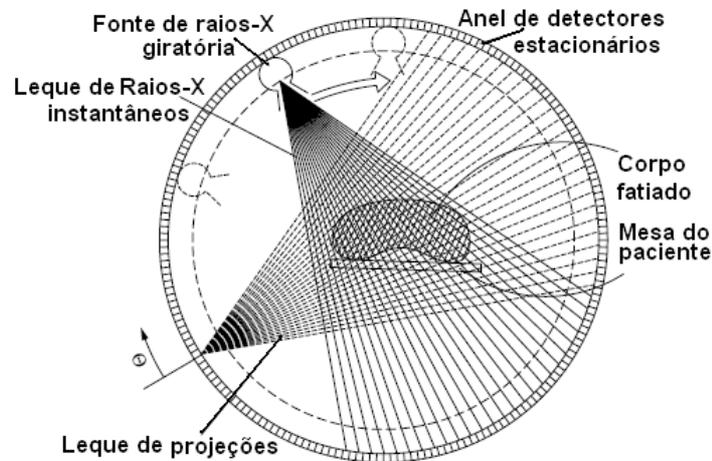


Figura A.4: desenho esquemático da quarta geração, adaptada de (JAN, 2006).

eficiência, e os detectores são atingidos pelos raios-X de diferentes ângulos, assim, a influência da radiação espalhada não é bem suprimida (JAN, 2006; BRONZINO, 2006).

A.5 Quinta geração da TC

Esta geração usa o mesmo arranjo de imageamento que a quarta geração, a única diferença é que a fonte de raios-X não é rotacionada mecanicamente e faz parte do modelo do sistema, como é mostrado na Figura A.5. Um grande ânodo metálico circular é situado no lugar da marca (trilha) da fonte de radiação e os raios-X cilíndricos são varridos eletronicamente para alcançar o ânodo na posição instantânea do foco desejado (JAN, 2006).

O algoritmo de reconstrução apresenta algumas modificações secundárias como, por exemplo, realizar mais interpolações provendo amostras equiangular do leque das projeções, para compensar a influência do espalhamento. Para remover as redundâncias provenientes das interpolações alguns sistemas fazem um deslocamento lateral do anel de detectores (JAN, 2006; BRONZINO, 2006). A projeção de dados pode

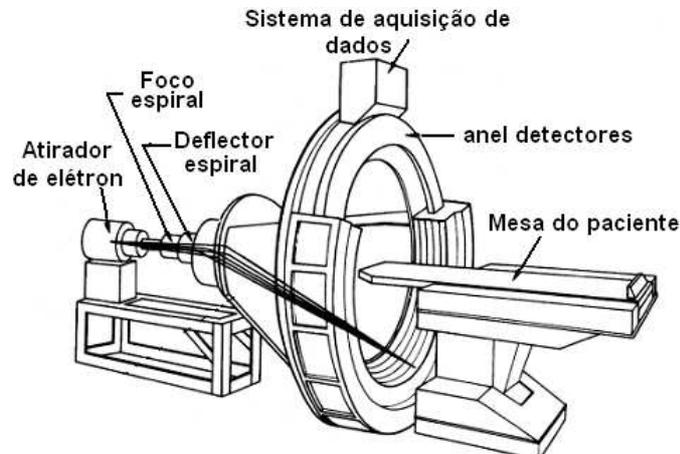


Figura A.5: desenho esquemático da quinta geração, adaptada de (BRONZINO, 2006).

ser adquirida em aproximadamente 50 ms, sendo um tempo bastante rápido até para escanear imagem de batimento cardíacos sem a interferência de artefatos ocasionados pelo movimento (BOYD; LIPTON, 1983).

A.6 TC espiral ou helicoidal

Para realizar fatiamentos em instantes de tempos mais rápidos, e em particular para escaneamento múltiplos para imageamento tridimensional, é desenvolvido um sistemas de escâner em espiral (helicoidal) (KALENDER et al., 1990). No escaneamento helicoidal, múltiplas imagens são adquiridas enquanto o paciente é transladado, ou seja, é deslocado no sentido axial pela estrutura do sistema em um movimento contínuo e suave, ao invés de parar e realizar a aquisição de cada fatiamento da imagem (BRONZINO, 2006), como é apresentado na Figura A.6.

Os dados de projeção para múltiplas imagens podem ser adquiridos em uma única respiração, a taxa de aproximadamente uma fatia por segundo. Os algoritmos de reconstrução são mais sofisticados, porquê eles ajustam o caminho do deslocamento helicoidal, traçado pela fonte de raios-X ao redor do paciente (JAN, 2006).

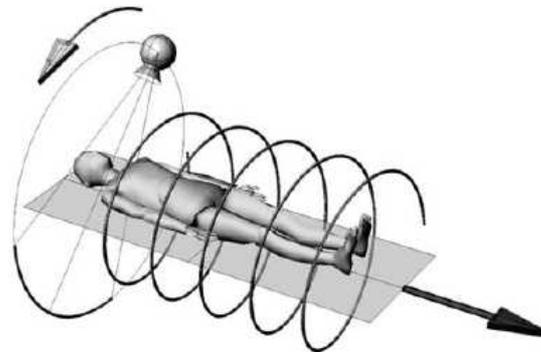


Figura A.6: princípio da TC helicoidal, adaptada de (JAN, 2006).

A.7 TC de múltiplos fatiamentos

Os sistemas de múltiplos fatiamentos (*multislice*) fornecem mais de uma fatia durante uma única rotação, geralmente quatro fatias por rotação, como é mostrado na Figura A.7. Usando um campo bidimensional de detectores, em vez de uma única linha, diversas linhas paralelas de detectores são usadas separadamente na direção z , de 0,5 a 2 mm aproximadamente. O princípio de múltiplos fatiamentos, fornece dados imediatamente tridimensionais em um volume limitado de quatro fatias; uma extensão maior ao longo do eixo- z , a linha central, pode ser conseguida pela exploração helicoidal, ou seja, através do deslocamento axial.

A.8 Princípios básicos da TC

A TC teve sua primeira aplicação clínica em Atkinson - Hospital de Morley, Wimbledon, Inglaterra, em outubro de 1971. A TC é aplicada para escanear a imagem do cérebro, em que a aquisição dos dados durou cerca de 5 minutos e a reconstrução da imagem tomográfica aproximadamente 20 minutos, e posteriormente é aplicada em todo o corpo (HOUNSFIELD, 1973, 1980; PUGATCH; FALING, 1981).

A mensuração da densidade radiográfica é feita de forma precisa através da TC.

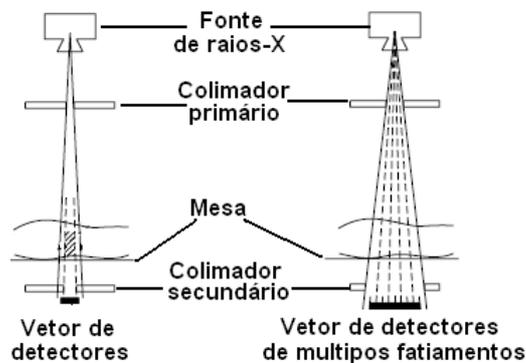


Figura A.7: visualização perpendicular da esquerda para a direita, princípio da TC helicoidal e da TC de múltiplos fatiamentos, adaptada de (JAN, 2006).

Para realizar esta tarefa a TC faz diversas medições de atenuação radiográfica, por meio de um plano de espessuras de tamanho finito em seções cruzadas. O sistema de aquisição de dados usa estas informações para reconstruir uma imagem digital da seção cruzada, em que cada *pixel* na imagem reconstruída representa a média da atenuação radiográfica de um elemento no formato de uma caixa (*voxel*), que estende-se pela espessura da seção. Um *voxel* ou elemento de volume, corresponde ao valor real de uma imagem em três dimensões com as seguintes medidas: largura (p) \times altura (p) \times profundidade (e) (HOUNSFIELD, 1973; MAHESH, 2002). A profundidade é representada pela espessura da fatia da seção, conforme é visto na Figura A.8.

A TC é um método de aquisição de imagens no plano axial, mas que permite uma visualização em outros planos de cortes (Figura A.9), através da reconstrução da imagem, cuja a tarefa fundamental do seu sistema é adquirir um número extremamente grande de medidas (aproximadamente 500,000), altamente precisas de transmissão de radiografia pelo corpo do paciente (ou parte do corpo) com geometria precisamente controlada (HENDEE; RITENOUR, 2002).

Na Figura A.10 é mostrado um sistema básico que consiste geralmente de um console de controle, computador, armação padrão constituído de fonte de emissão radiográfica, detectores radiográficos com sistema de aquisição de dados, uma mesa

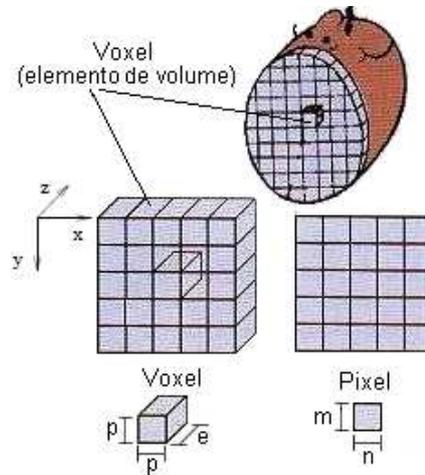


Figura A.8: representação de um elemento de volume *voxel* no lado esquerdo e de um pixel no lado direito, adaptada de (BONTRAGER, 2000).

para pacientes, apoio para cabeça e um imageador de laser (BRONZINO, 2006).

A propriedade que os materiais têm em absorver a radiação eletromagnética é chamada de atenuação radiográfica. Uma medida de atenuação quantifica a fração de radiação removida, em que uma determinada quantidade de radiação atravessa um material com espessura específica. A radiação é reduzida exponencialmente quando passa através do material, de forma que a intensidade do material ou corpo (I_c) após percorrer uma certa distância (x) pode ser expressa por

$$I_c = I_0 e^{-\mu x}, \quad (\text{A.1})$$

em que I_c é a medida da intensidade dos raios-X do corpo na trajetória do feixe dos raios-X, I_0 é a medida da intensidade dos raios-X sem o corpo na trajetória do feixe dos raios-X, μ é o coeficiente de atenuação linear específico do corpo, e x é a distancia percorrida pelos feixes de raios-X (DRUMMOND, 1998; MAHESH, 2002).

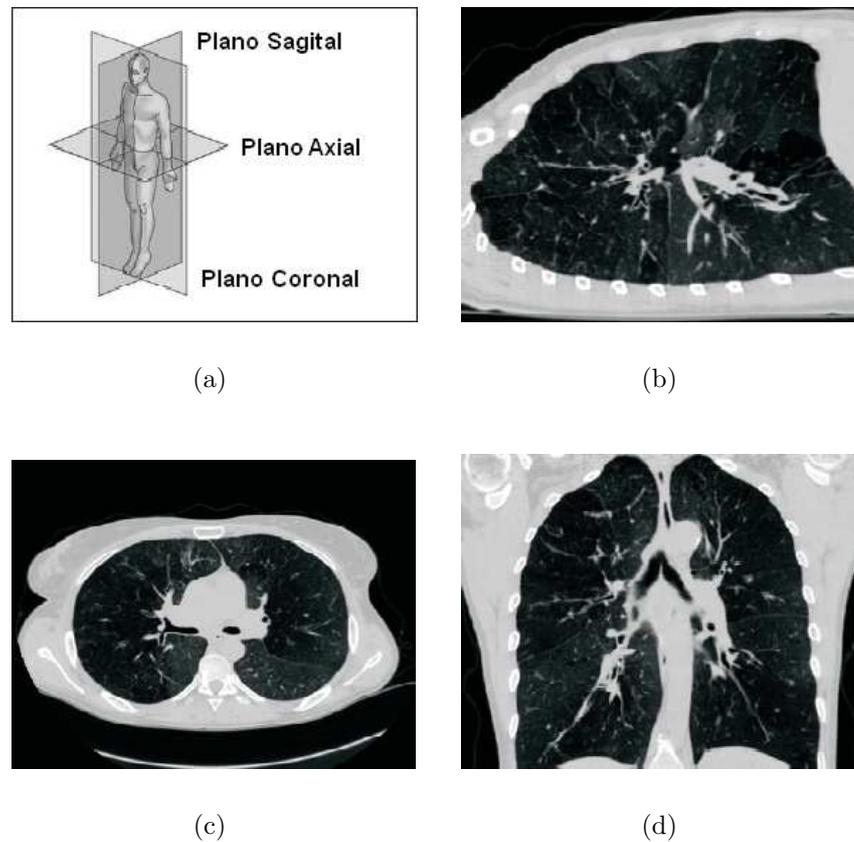


Figura A.9: imagens de seções do pulmão (a) planos de cortes no corpo, (b) seção sagital, (c) seção axial, (d) seção coronal, adaptada de (SLUIMER, 2005).

A.9 Princípios de Reconstrução da TC

A reconstrução tomográfica, consiste em obter um mapeamento adequado dos raios-X que ultrapassam o corpo em análise e, a partir destes dados, reconstruir uma imagem que represente a forma geométrica mais próximo do real. Esta é uma etapa bastante complicada, devido a grande quantidade de dados gerados, através dos múltiplos raios que incidem e atravessam o corpo, apresentando informações relevantes ou irrelevantes.

Desta forma, o algoritmo de reconstrução tem que ser robusto para rejeitar as informações espúrias e, combinar as informações mais adequadas em uma imagem

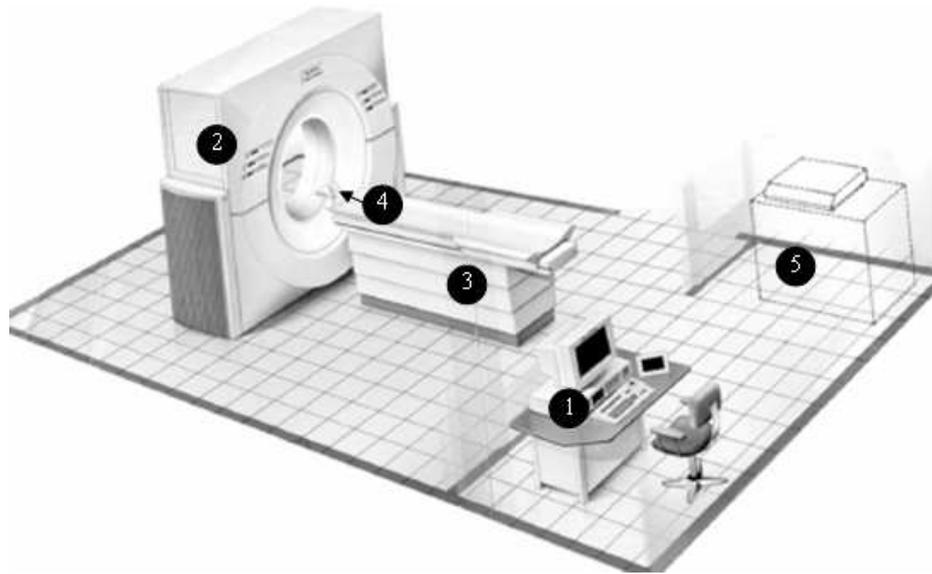


Figura A.10: desenho esquemático da instalação de uma típica TC. 1) console de controle, 2) armação padrão, 3) mesa para o paciente, 4) apoio para cabeça e 5) imageador de laser, adaptada de (BRONZINO, 2006).

representativa do corpo. Existem vários tipos de algoritmos de reconstrução aplicados a cada tipo de TC, a evolução destes ocorreram juntamente com as das TC vistas nas Seções A.1 a A.7.

Os algoritmos de reconstrução estão divididos em (HENDEE; RITENOUR, 2002; JAN, 2006):

1. *Retropropagação simples*: Neste método, cada caminho de transmissão dos raios-X pelo corpo é dividido em elementos igualmente espaçados, e é assumido que cada elemento contribui igualmente à atenuação total ao longo do caminho dos raios-X. Este reproduz imagens muito borradas e não são utilizados comercialmente nas TC;
2. *Reconstrução de projeção paralela por retropropagação filtrada*: Este algoritmo de reconstrução é frequentemente chamado de método de convolução e, usa

uma integral unidimensional para a reconstrução de uma imagem em duas dimensões. Neste é combinado uma função (filtro) para reduzir o borramento na imagem, removendo a maioria dos ruídos antes dos dados serem retropropagados. Uma das vantagens do método de convolução, é que a imagem pode ser construída enquanto estão sendo adquiridos os dados, sendo este o algoritmo de reconstrução mais utilizado nas TC;

3. *Reconstrução via domínio da frequência (transformada de Fourier)*: Este método é baseado no teorema de projeções de fatias, que formula a relação entre o espectro de duas-dimensões de uma imagem de duas-dimensões, e o espectro de uma-dimensão de uma projeção unidimensional desta imagem em baixo de um ângulo. O padrão de atenuação dos raios-X de cada orientação angular são separados em componentes de frequência de varias amplitudes através da transformada de Fourier e depois reconstruída pela transformada inversa de Fourier utilizando as componentes mais adequadas; Esta técnica é normalmente aplicada em imagens de ressonância magnética e raramente em TC;

4. *Expansão de séries*: Este apresenta três variações, a primeira é conhecido como Técnica de Reconstrução Algébrica, a segunda é a Técnica Interativa dos Mínimos Quadrados, e a terceira é a Técnica de Reconstrução Simultânea e Interativa. Os algoritmos da expansão de série (reconstrução interativa), não são usadas em TC comerciais, devido a repetição não pode ser começada até todos os dados de projeção forem adquiridos, causando uma demora na reconstrução da imagem.

Detalhes sobre os algoritmos de reconstrução como formulação matemática e equações podem ser visto em: (BRONZINO, 2006; EPSTEIN, 2001; HENDEE; RITENOUR, 2002; JAN, 2006).

A.10 Escala da TC em unidades Hounsfield

O coeficiente de atenuação ou absorção μ quantifica a tendência de um corpo absorver os raios-X. A representação matemática do coeficiente de atenuação pode ser determinada algebricamente, com o uso de várias equações que somam todos os raios que cruzam o *voxel*.

Porém, um método que apresenta uma fórmula matemática mais simplificada é utilizado para realizar o cálculo deste (EPSTEIN, 2001; MAHESH, 2002). Definido pela equação

$$UH_{tecido} = 1000 \times \frac{(\mu_{tecido} - \mu_{\acute{a}gua})}{\mu_{\acute{a}gua}}, \quad (\text{A.2})$$

em que μ_{tecido} é a medida do coeficiente de absorção do tecido em *voxel* e $\mu_{\acute{a}gua}$ é a medida do coeficiente de absorção da água.

A TC tem uma escala de densidade radiográfica específica para cada tipo de órgão e/ou tecido do corpo humano. Esta escala é representada em Unidades Hounsfield (UH). As anatomias das estruturas do corpo humano apresentam pequenas ou grandes variações, o mesmo acontece com o valor da densidade em UH. Desta forma, diferentes tipos de tecidos (órgão ou estruturas) apresentam valores ligeiramente diferentes de densidade, permitindo medir um valor de μ específicos para cada tipo de tecido, inclusive os patológicos (EPSTEIN, 2001).

Os valores em UH para determinados tipos de tecidos e órgãos do corpo humano são apresentados na Figura A.11. Os coeficientes de atenuação do ar e da água são usados como referência no processo de calibração por serem de fácil obtenção. As TC trabalham tipicamente em uma escala de -1024 UH a +3071 UH. Para o pulmão com todas as suas estruturas, esta escala é compreendida de -1000 UH a +200 UH (SIEMENS, 2004; SLUIMER, 2005).

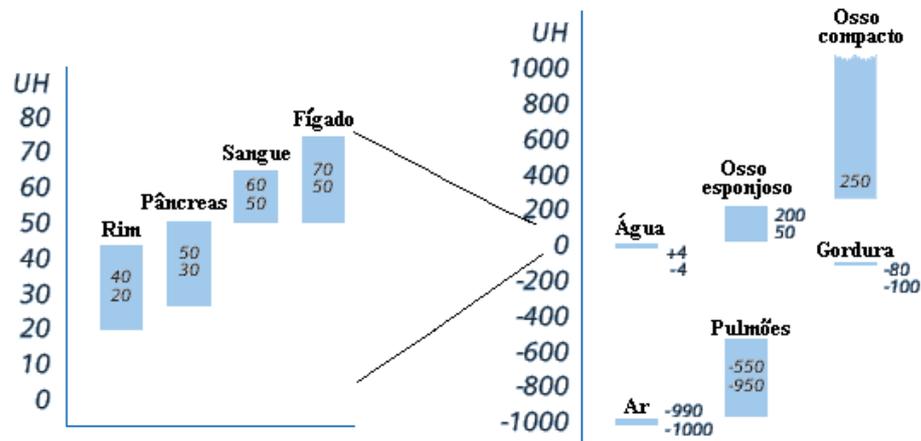


Figura A.11: escala em Unidades Hounsfield, adaptada de (SIEMENS, 2004).

A.11 Padrão de Leituras de Imagens Médicas (DICOM)

O padrão de leitura de imagens médicas DICOM do inglês (*Digital Imaging and Communications in Medicine*) é uma padronização detalhada que descreve um meio de formatar e trocar imagens médicas com informações associadas, dirigidas aos mecanismos de operação da interface usadas para transferir dados entre determinado dispositivo de imagens e redes (SILVA, 2005).

Este padrão é utilizado mundialmente e, foi padronizado pela comissão ACR-NEMA (*American College of Radiology - National Electrical Manufacturers Association*), devido a uma crescente aplicação dos computadores nas TC na década de 70 (NEMA, 2007).

Este comitê foi criado em 1983, para desenvolver um padrão que possibilite a comunicação da informação de imagem digital entre os diversos fabricantes de dispositivos na área médica, facilitando o desenvolvimento e a expansão de arquivamento em quadros e comunicação dos sistemas (*Picture Archiving and Communication Systems-PACS*), até conectar-se com outros sistemas de informação hospitalar e permita a

criação de bancos de dados de informações e diagnóstico (NEMA, 2007).

O padrão DICOM de 2007 disponibilizado pelo ACR-NEMA, está dividido em 18 partes, cujo o objetivo é facilitar a reedição destas. Cada parte descreve com detalhes um ou mais módulos. Os módulos agrupam dados que estão relacionados. Os módulos que definem a imagem DICOM, como dados do paciente (nome, idade, sexo) e dados das imagens, como frames, modalidades, formatos (de armazenamento, visualização e impressão), dimensões, espessura da fatia, regiões de interesse, etc.

As partes são (NEMA, 2007): introdução e visão geral, conformidade, informações e definições de objetos, especificações de classe de serviço, estrutura de dados e codificação, dicionário de dados, troca de mensagem, suporte de comunicação de rede para troca de Mensagem, tirar de circulação (suporte de comunicação ponto-a-ponto antigo para troca de mensagem), mídia de armazenamento e formato de arquivo para troca de dados, mídia de armazenamento aplicado a perfis, função de armazenamento e formatos de mídias para troca de dados, tirar de circulação (suporte de comunicação ponto-a-ponto antigo para gerenciar a impressão), função de exibição padrão em escala de cinza, segurança e perfis de gerência de sistema, recurso de mapeamento de conteúdo, informação explicativa e objeto DICOM de acesso persistente a Web.

A Figura A.12 mostra uma parte da estrutura que compõe uma imagem da TC no formato DICOM.

A.12 Tomografia Computadorizada de Alta Resolução - TCAR

A Tomografia Computadorizada de Alta Resolução (TCAR) é uma técnica aplicada a TC com a finalidade de maximizar a resolução espacial, através do algoritmo de reconstrução de alta resolução espacial, cortes finos e alto contraste, que simulam os tecidos moles e o ar nos pulmões. A TCAR permite realizar fatiamentos com espessura de 1 a 2 mm, enquanto que a TC possibilita fatias de 8 a 10 mm de espessura.

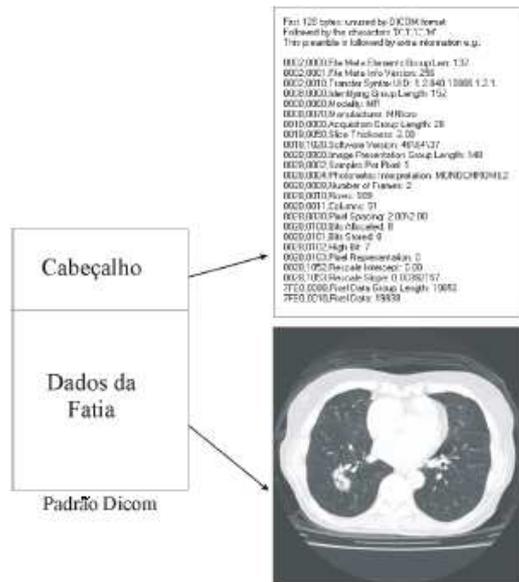


Figura A.12: estrutura de uma imagem no padrão DICOM (SILVA, 2005).

O algoritmo de reconstrução pode ser de altas ou baixas frequências, dependendo da informação que se deseja reproduzir na imagem final (MAYO et al., 1987; SWENSEN et al., 1992).

A TCAR é a ferramenta mais importante para a avaliação de pacientes com doenças pulmonares difusas como as pneumonias intersticiais idiopáticas, doenças pulmonares eosinofílica e doenças pulmonares obstrutivas. A TCAR em comparação com a TC possibilita uma melhor visualização de estruturas pulmonares menores entre 0.2 e 0.3 mm, como os vasos, brônquios e, principalmente, a identificação do lóbulo pulmonar secundário, local que apresenta as principais alterações pulmonares (MURATA et al., 1986; MAYO et al., 1987; BATRA, 1993).

De acordo com Webb, Müller e Naidich, a TCAR pode distinguir entre 4 categorias ou grupos de anormalidades presentes nos pulmões anormais (WEBB; MÜLLER; NAIDICH, 2001). São elas:

1. linear e opacidades reticulares;

2. nodular ou opacidades reticulonodulares;
3. opacificação do parênquima;
4. cistos e enfisemas.

As RI correspondente a cada uma das categorias de anormalidade detectadas através da TCAR são mostradas na Figura A.13. Em estudo mais recente realizado por Gotway *et al.* (GOTWAY *et al.*, 2005) apresentam a distinção de várias patologias pulmonares através da TCAR, aplicando fatiamentos de 1 mm de espessura. Os padrões de doenças encontrados pela TCAR neste trabalho estão classificados dentro da opacidade pulmonar crescente e da opacidade pulmonar decrescente.

A opacidade pulmonar crescente está nas faixas das altas densidades pulmonares, enquanto a opacidade pulmonar decrescente é localizada nas baixas densidades. As doenças presentes nestas duas classes são ainda subclassificadas. Na Tabela A.1 é mostrado estas doenças e suas principais componentes geradoras (subclasses) (GOTWAY *et al.*, 2005).

No trabalho realizado por Kurashima *et al.* (KURASHIMA *et al.*, 2005) mostram as limitações e a eficiência da TCAR na detecção da DPOC. Outros detalhes e estudos relacionados, que aplicam a TCAR para identificar enfisemas, DPOC e demais doenças que afetam o pulmão, podem ser visto nos autores já citados nesta seção, e em: (WEBB *et al.*, 1988; NISHIMURA *et al.*, 1992; KLEIN *et al.*, 1992; CORCORAN; RENNER; MILSTEIN, 1992; LOPES *et al.*, 2005)

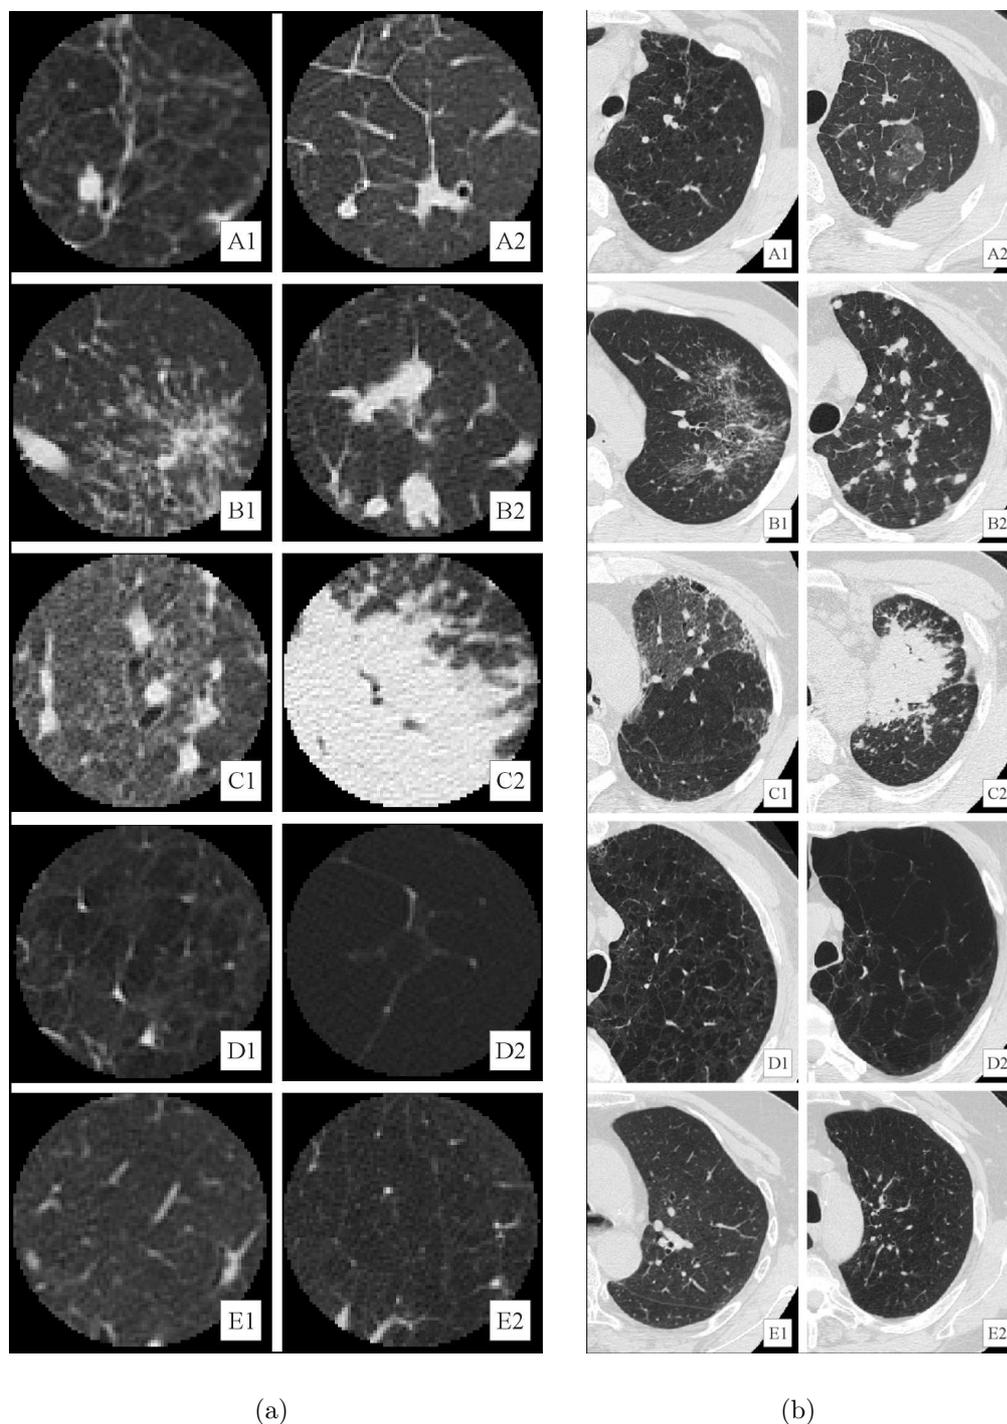


Figura A.13: RI dos pulmões obtidas através de uma TCAR (a) RI destaca na imagem, (b) os pulmões direitos usadas na seleção das RI. As imagens de A1 e A2 até D1 e D2 mostram os padrões patológicos escolhidos para representar cada um dos quatro grupos de pneumopatias: A) linear e opacidades reticulares, B) nodular ou opacidades reticulonodulares, C) opacificação do parênquima, D) cistos e enfisemas. O tecido pulmonar normal é visto nas imagens E1 e E2 (SLUIMER, 2005).

Doenças Perceptíveis pela TCAR	Subclassificações dos Padrões Perceptíveis	Doenças Frequentemente Relacionadas
Opacidade pulmonar crescente		
<i>Nódulos</i>	centrilobulares e perilistáticos aleatórios	bronquite, sarcoidose e infecção difusa hematogênica
<i>Anormalidades lineares</i>	septal interlobular, bandas de parênquima, linhas sub-pleurais	edema pulmonar, carcinoma linfangite
<i>Anormalidades reticulares</i>	reticulação fina ou grossa e espessamento intralobular intersticial	pneumonias intersticiais idiopáticas e pneumoconiose
<i>Opacidade em vidro despolido ou vidro fosco</i>	deve ser baseado no histórico clínico e associado com os achados da varredura	infecção oportunista, pneumonia intersticial idiopáticas e proteinose alveolar pulmonar
<i>Consolidação</i>	deve ser baseado no histórico clínico e associado com os achados da varredura	pneumonia, pneumonia criptogênica organizada, hemorragia pulmonar
Opacidade pulmonar decrescente		
<i>Áreas de atenuações decrescentes com paredes (aparência de cistos)</i>	forma do cisto, distribuição, espessura da parede e padrão de organização	histiocitose da célula de Langerhans, linfangioleiomiomatose, bronquictasia, enfisema paraseptal, pneumonias intersticiais idiopáticas
<i>Áreas de atenuações decrescentes fora das paredes</i>	enfisema, perfusão em mosaico	enfisema centrilobular ou panlobular, doenças que afetam as pequenas vias aéreas

Tabela A.1: doenças perceptíveis através da TCAR: opacidade pulmonar crescente e decrescente (GOTWAY et al., 2005).