



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

Pedro Pedrosa Rebouças Filho

MÉTODOS DE CONTORNOS ATIVOS CRISP ADAPTATIVO
2D E 3D APLICADOS NA SEGMENTAÇÃO DOS PULMÕES
EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA
DO TÓRAX

FORTALEZA - CEARÁ
MAIO - 2013

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca de Pós-Graduação em Engenharia - BPGE

-
- R24m Rebouças Filho, Pedro Pedrosa.
 Métodos de contornos ativos Crisp adaptativo 2D e 3D aplicados na segmentação dos pulmões em
 imagens de tomografia computadorizada do tórax / Pedro Pedrosa Rebouças Filho. – 2013.
 180 f. : il. color., enc. ; 30 cm.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de
 Engenharia de Teleinformática, Programa de Pós-Graduação em Engenharia de Teleinformática,
 Fortaleza, 2013.
 Área de Concentração: Sinais e sistemas.
 Orientação: Prof. Dr. Paulo César Cortez.
 Coorientação: Prof. Dr. Marcelo Alcântara Holanda
1. Teleinformática. 2. Sistemas computacionais. 3. Diagnóstico por imagem. I. Título.

Pedro Pedrosa Rebouças Filho

MÉTODOS DE CONTORNOS ATIVOS CRISP ADAPTATIVO
2D E 3D APLICADOS NA SEGMENTAÇÃO DOS PULMÕES
EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA
DO TÓRAX

TESE

Tese submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática da **Universidade Federal do Ceará**, como requisito parcial para obtenção do grau de DOUTOR EM ENGENHARIA DE TELEINFORMÁTICA.

Área de concentração: Sinais e Sistemas

Prof. Dr. Paulo César Cortez
(Orientador)

Prof. Dr. Marcelo Alcantara Holanda
(Co-orientador)

FORTALEZA - CEARÁ

2013

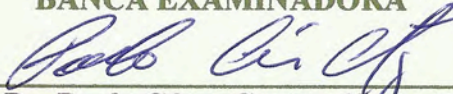
PEDRO PEDROSA REBOUÇAS FILHO

**MÉTODOS DE CONTORNOS ATIVOS CRISP ADAPTATIVO 2D E 3D APLICADOS
NA SEGMENTAÇÃO DOS PULMÕES EM IMAGENS DE TOMOGRAFIA
COMPUTADORIZADA DO TÓRAX**

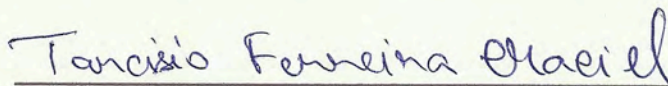
Tese submetida à Coordenação do Curso de Pós-Graduação em Engenharia de Teleinformática, da Universidade Federal do Ceará, como requisito parcial para a obtenção do grau de Doutor em Engenharia de Teleinformática, área de concentração Sinais e Sistemas.

Aprovada em 03/05/2013.

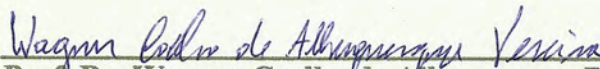
BANCA EXAMINADORA




Prof. Dr. Paulo César Cortez (Orientador)
Universidade Federal do Ceará - UFC




Prof. Dr. Tarcísio Ferreira Maciel (PPGETI/UFC)
Universidade Federal do Ceará - UFC



Prof. Dr. Wagner Coelho de Albuquerque Pereira
Universidade Federal do Rio de Janeiro- UFRJ



Prof. Dr. John Hebert da Silva Felix
Universidade de Integração Internacional da Lusofonia Afro-Brasileira - UNILAB



Prof. Dr. Marcelo Alcântara Holanda
Universidade Federal do Ceará - UFC



Prof. Dr. José Daniel Vieira de Castro
Universidade Federal do Ceará - UFC

Sumário

Lista de Figuras	vii
Lista de Tabelas	xv
Lista de Siglas	xvii
1 Introdução	1
1.1 Motivação	3
1.2 Estado da arte	5
1.3 Objetivos	7
1.3.1 Objetivos específicos	7
1.4 Contribuições	8
1.5 Produção Científica	9
1.6 Organização da tese	10
2 Fundamentação teórica	11
2.1 Segmentação	11
2.1.1 Segmentação por similaridade	12
2.1.2 Segmentação por descontinuidade	14
2.2 Métodos de Contornos Ativos (MCAs)	15
2.2.1 MCA Tradicional	16
2.2.2 MCA Balão	20
2.2.3 MCA <i>Gradient Vector Flow</i>	23
2.2.4 MCA <i>Vector Field Convolution</i> (VFC)	27
2.2.5 MCAs baseados na Transformada de Hilbert Radial (THR)	28
2.2.6 MCA Crisp	30
2.3 Medidas de avaliação da segmentação	34
2.3.1 Medidas de avaliação quantitativa de ajuste	35
2.3.2 Medidas de avaliação qualitativa	36
2.3.3 Medidas de avaliação inter e intra observador	38
2.4 Rede Neural Artificial	39
2.4.1 Perceptron Simples	39
2.4.2 Rede Neural Perceptron Multicamada - MLP	41
2.5 Conclusão do Capítulo	43
3 Metodologia	44
3.1 Aquisição de Imagens Médicas	44
3.2 MCA Crisp Adaptativo 2D	45

3.2.1	Energia interna adaptativa 2D	46
3.2.2	Energia externa Crisp Adaptativa 2D	51
3.2.3	Inicialização automática do MCA Crisp Adaptativo 2D	56
3.2.4	Adição e Remoção de pontos do MCA Crisp Adaptativo 2D	58
3.2.5	Segmentação automática dos pulmões em imagens de TC do tórax através do MCA Crisp Adaptativo 2D	63
3.3	MCA Crisp Adaptativo 3D	65
3.3.1	Energia interna Adaptativa 3D	66
3.3.2	Energia Externa Crisp Adaptativa 3D	71
3.3.3	Visualização 3D	76
3.3.4	Inicialização do modelo 3D	79
3.3.5	Inicialização automática do MCA Crisp Adaptativo 3D	81
3.3.6	Locomoção, Adição e Remoção de pontos dos MCA Crisp Adapta- tivo 3D	82
3.3.7	Segmentação automática dos pulmões em exames de TC do tórax através do MCA Crisp Adaptativo 3D	86
4	Resultados e Discussões	89
4.1	Aquisição de Imagens Médicas	89
4.2	Resultados do MCA Crisp Adaptativo 2D	91
4.2.1	Avaliação das medidas de ajuste de posição	102
4.2.2	Avaliação das medidas de ajuste de intensidade	103
4.2.3	Avaliação das medidas de ajuste de tamanho	105
4.2.4	Avaliação das medidas de ajuste de forma	106
4.2.5	Tempo médio de processamento	108
4.2.6	Avaliação geral dos métodos	108
4.3	Resultados do MCA Crisp Adaptativo 3D	111
4.3.1	Avaliação Qualitativa por médicos pneumologistas	115
4.3.2	Avaliação do tempo de processamento	125
5	Conclusões, Contribuições e Trabalhos Futuros	127
	Referências Bibliográficas	130
	Apêndice	143
A	Aplicações no auxílio ao diagnóstico médico dos pulmões	143
A.1	Visualização por cortes da reconstrução 3D	144
A.2	Aplicação de máscara colorida	146
A.3	Deteção de doenças e estruturas internas do pulmão utilizando máscara colorida	147
A.3.1	Deteção e análise de enfisema	147
A.3.2	Deteção dos vasos pulmonares	149
A.4	Deteção de estruturas do corpo humano em exames de TC do tórax . . .	151
A.4.1	Deteção e análise da região óssea	151
A.5	Deteção e análise das vias aéreas	152
	Apêndice	153

B Tomografia Computadorizada do tórax	153
B.1 Visualização dos pulmões e suas estruturas internas em exames de TC do tórax no plano axial	155

Lista de Figuras

2.1	exemplo de aplicação da técnica de CR: a) imagem original com a semente em vermelho; b) resultado da segmentação em vermelho.	13
2.2	ilustração da aplicação do Crescimento de Regiões 3D. a) determinação do <i>voxel</i> semente em destaque vermelho, b) primeira iteração do Crescimento de Regiões 3D analisando a vizinhança do <i>voxel</i> semente e c) resultado final da segmentação (RIBEIRO, 2013).	14
2.3	exemplo dos vizinhos considerados no cálculo da energia.	17
2.4	exemplo da atuação da força balão repulsando um ponto $c(s)$ em direção contrária do baricentro $T(x_t, y_t)$	21
2.5	mapa típico da força balão agindo sobre a curva (em vermelho) no sentido de expansão (CAVALCANTE, 2010).	22
2.6	resultado do MCA Balão com a curva em vermelho, a) inicialização da curva; b) e c) são resultados das iterações intermediárias; e d) resultado final da segmentação pelo MCA Balão (REBOUÇAS FILHO, 2010).	22
2.7	aplicação do MCA Balão, desde a) inicialização da curva, b) e c) iterações intermediárias d) resultado final da segmentação (REBOUÇAS FILHO, 2010).	23
2.8	a) convergência do <i>snake</i> , b) campo de vetores gradiente, c) ampliação da concavidade do campo de gradiente (Xu and Price, 1997).	24
2.9	fluxo Gradiente obtido com a) 100 iterações, b) 200 iterações, e c) 400 iterações.	25
2.10	primeira limitação do MCA Tradicional superada pelo MCA GVF, a) inicialização da curva; b) e c) iterações intermediárias; d) resultado final da segmentação.	25
2.11	segunda limitação do MCA Tradicional, corrigida pelo MCA GVF, a) inicialização da curva; b) e c) iterações intermediárias; d) resultado final da segmentação pelo MCA GVF.	26

2.12	limitação dos MCAs Tradicional, Balão e GVF, a) inicialização da curva; b) e c) iterações intermediárias; e d) resultado final da segmentação pelo método GVF.	27
2.13	imagens dos pulmões em TCAR de um voluntário sadio, (a) corte em nível de ápice; (b) corte em nível de hilo; e (c) corte em nível de base.	31
2.14	imagens de TCAR dos pulmões, (a) original, (b) gradiente de Sobel e (c) energia Crisp (REBOUÇAS FILHO, 2010).	32
2.15	demonstração das regiões, em vermelho, utilizadas para encontrar os pontos para as inicializações, em amarelo, dos contornos dos pulmões esquerdo e direito, em azul (REBOUÇAS FILHO, 2010).	33
2.16	exemplo de avaliação qualitativa de segmentação dos pulmões em imagens de TC: a) imagem original, b) segmentação ótima, c) segmentação aceitável, d) segmentação razoável, e) segmentação ruim e f) segmentação péssima (REBOUÇAS FILHO, 2010).	37
2.17	representação de um perceptron.	40
2.18	representação de uma rede MLP com uma camada oculta.	41
3.1	imagem de TC dos pulmões obtida na posição axial, a) obtida com TC multidetectora; b) representação das faixas de densidades (REBOUÇAS FILHO, 2010).	45
3.2	exemplos de cálculo da força Balão Adaptativa.	48
3.3	demonstração da Força Balão Adaptativa, em verde, dos pontos, em azul, de curvas nas formas: a) quadrada; e b) convexos/côncavos.	49
3.4	exemplo da segmentação obtida pelo MCA Balão Adaptativo 2D, em que os pontos são apresentados em azul, o contorno em vermelho e a direção da força Balão Adaptativa 2D de cada ponto é apresentada em verde, a) inicialização; b) até h) passo a passo do método; e i) resultado da segmentação.	50
3.5	imagem de TC dos pulmões, a) original; b) gradiente Sobel; e c) resultado da classificação gerada pela força externa do MCA Crisp (REBOUÇAS FILHO, 2010).	51
3.6	demonstração de falhas da força Crisp proposta por REBOUÇAS FILHO (2010) na detecção das bordas pulmonares em imagens de TC do tórax.	52
3.7	resultados da análise da origem das bordas em uma imagem de TC do tórax através dos métodos, a) Crisp; e b) Crisp Adaptativo, com as diferenças apresentadas por regiões, em que o Crisp Adaptativo apresenta os resultados corretos.	54

3.8	etapas para obtenção da energia externa Crisp Adaptativa, a), e) e i) imagens originais de pacientes com DPOC, Fibrose e voluntários Sadios, respectivamente; b), f) e g) rerepresentação da energia externa Tradicional em uma imagem; c), g) e k) classificação da MLP para determinar origem das bordas; e d), h) e l) representação da energia externa Crisp Adaptativa em uma imagem.	55
3.9	regiões utilizadas para encontrar os pontos para as inicializações da curva nos pulmões esquerdo e direito, nas posições, a) ápice; b) hilo; e c) base. . .	56
3.10	inicialização automática da curva nos pulmões esquerdo e direito, em que as imagens estão na posição, a) ápice; b) hilo; e c) base.	57
3.11	modelo para cálculo do ângulo entre um ponto e seus vizinhos.	59
3.12	demonstração da reordenação dos pontos apagando o ponto I.	59
3.13	demonstração do método de adição de pontos do MCA Crisp Adaptativo. .	61
3.14	demonstração do método de adição de pontos do MCA Crisp Adaptativo atuando em imagens de TC do tórax.	62
3.15	demonstração do fluxograma de execução do método MCA Crisp Adaptativo 2D.	64
3.16	exemplo de evolução de duas curvas aplicando o MCA Crisp Adaptativo na segmentação dos pulmões em imagens de TC do tórax, a) inicialização; b) até e) evolução do movimento da curva; e f) resultado da segmentação. .	65
3.17	demonstração das distâncias utilizadas no cálculo da Força de Continuidade 3D, sendo as verdes as utilizadas em $F_{cont_{3D_i}}$ e as vermelhas em $F_{cont_{3D_{i-1}}}$ e $F_{cont_{3D_{i+1}}}$, em que i é a posição da curva no eixo z	68
3.18	demonstração das parcelas da Força Balão Adaptativa 3D $F_{M_{B_i D_i}}$, $F_{C_{i-1}}$ e $F_{C_{i+1}}$ provenientes das camadas i , $i - 1$ e $i + 1$, respectivamente, em que i é a posição da curva no eixo z	70
3.19	vizinhança de um ponto central analisada para compor a energia externa 3D de um ponto $m(s)$, apresentado em vermelho.	73
3.20	demonstração da base da estrutura de dados em 3D, em que cada plano possui uma curva, apresentada em verde, gerada a partir de pontos, mostrados em vermelho.	77
3.21	estrutura de dados 3D, em que seus pontos conectam-se aos pontos mais próximos da camada superior através de linhas, apresentadas em vermelho, e aos pontos da mesma camada com linhas impressas em verde.	78
3.22	superfície 3D de um objeto.	78

3.23	etapas de renderização, a) sobreposição de curvas presentes em cada imagem; b) conexão de pontos de camadas distintas gerando triângulos; e c) superfície renderizada.	79
3.24	definições de variáveis do modelo 3D de inicialização.	80
3.25	inicialização do modelo 3D, a) 7 camadas e $R = 30$ e b) 11 camadas e $R = 50$	81
3.26	inicialização automática do modelo 3D dentro dos pulmões, a) inicialização de ambos os pulmões e b) um dos modelos ampliado.	82
3.27	Demonstração da análise de uma vizinhança 3×3 para movimentar um ponto $c(s)$ pertencente a camada i , em que as camadas $i - 1$ e $i + 1$ apenas são utilizadas para cálculo do deslocamento, adição e remoção de pontos.	83
3.28	adição de camadas no modelo 3D, a) modelo 3D com área maior que a configurada na primeira e na última fatia; b) vista da camada superior de a); c) modelo 3D com novas camadas; e d) vista da camada superior de c).	84
3.29	demonstração dos parâmetros para cálculo do ângulo formado entre um ponto da camada i com os seus mais próximo nas camadas $i - 1$ e $i + 1$, em que a) e b) demonstram a formação dos ângulos θ_1 e θ_2 , respectivamente.	85
3.30	fluxograma de execução do método MCA Crisp Adaptativo 3D.	87
3.31	evolução de dois modelos 3D aplicando o MCA Crisp Adaptativo 3D na segmentação dos pulmões em um exame de TC do tórax, a) inicialização automática do modelo 3D; b) até e) evolução do modelo 3D; e f) resultado da segmentação.	88
4.1	exemplos de segmentação dos pulmões em imagens de TC do tórax de voluntários sadios obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo 2D, apresentadas em cada linha de cima para baixo, respectivamente.	93
4.2	ajuste de posição obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	94
4.3	ajuste de intensidade obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	94

4.4	ajuste de tamanho obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	95
4.5	ajuste de forma obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	95
4.6	exemplos de segmentação dos pulmões em imagens de TC do tórax de pacientes com DPOC obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo, apresentadas em cada linha de cima para baixo, respectivamente.	96
4.7	ajuste de posição obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	97
4.8	ajuste de intensidade obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	97
4.9	ajuste de tamanho obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	98
4.10	ajuste de forma obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	98
4.11	exemplos de segmentação dos pulmões em imagens de TC do tórax de pacientes com Fibrose obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo, apresentadas em cada linha de cima para baixo, respectivamente.	99
4.12	ajuste de posição obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	100
4.13	ajuste de intensidade obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	100

4.14	ajuste de tamanho obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRM _{Mod} , THRM _{Multi} , GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	101
4.15	ajuste de forma obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRM _{Mod} , THRM _{Multi} , GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.	101
4.16	exemplo das etapas para obtenção da energia externa do MCA Crisp Adaptativo 2D, a) imagem de TC original; b) gradiente Sobel de a); c) análise do MCA Crisp Adaptativo 2D apresentando as bordas internas do pulmão em vermelho e as externas em verde; e d) representação da energia externa do MCA Crisp Adaptativo 2D.	109
4.17	exemplo das etapas de aplicação do MCA Crisp Adaptativo 2D, sobre a representação da energia externa deste método e apresentando a direção da energia interna Balão Adaptativa em verde, a) inicialização; b) até e) passo a passo da evolução da curva; e f) resultado da segmentação.	111
4.18	exemplo da evolução dos métodos MCA Crisp Adaptativo 3D (rosa) e Crescimento de Regiões 3D (Azul) na segmentação dos pulmões em exames de TC do tórax utilizando a mesma inicialização apresentadas em a) e b), respectivamente. A evolução do MCA 3D em c) e e) até se estabilizar, conforme ilustrado em g). A evolução do CR 3D em d) e f) até se estabilizar, conforme ilustrado em h).	113
4.19	segmentação dos pulmões em exames de TC pelos métodos, a), d) e g) MCA Crisp Adaptativo 3D; b), e) e h) Crescimento de Regiões 3D; e c), f) e i) ambos métodos anteriores, retirando os efeitos de luz e transparência do CR 3D para realçar as diferenças.	114
4.20	regiões do pulmão consideradas na seleção das imagens em cada exame de TC do tórax para a análise qualitativa dos métodos de segmentação 3D dos pulmões.	115
4.21	exemplo de imagens das regiões presentes na Figura 4.20, a),b) e c) exemplos da região 1; d),e) e f) exemplos da região 2; g),h) e i) exemplos da região 3 e j),k) e l) exemplos da região 4.	117

4.22	exemplos de segmentação dos pulmões em imagens de TC em que ambos os médicos avaliaram a segmentação como ótima nos dois pulmões, obtendo avaliação 5. a) e d) imagens originais; b) e e) resultado utilizando Crescimento de Regiões 3D; e c) e f) resultado utilizando o MCA Crisp Adaptativo 3D.	121
4.23	exemplos de segmentação dos pulmões em imagens de TC, sendo a) e d)imagens originais. O hilo é agregado à região pulmonar pelo Crescimento de Regiões 3D conforme apresentado em b) e e), o que não acontece utilizando o MCA Crisp Adaptativo 3D, cujo os resultados são apresentados em c) e f).	122
4.24	exemplos de segmentação dos pulmões em imagens de TC com Fibrose, sendo a) e d)imagens originais. As regiões do pulmão com Fibrose são excluídas da região pulmonar no método Crescimento de Regiões 3D conforme apresentado em b) e e), o que não acontece utilizando o MCA Crisp Adaptativo 3D, cujo os resultados são apresentados em c) e f).	123
4.25	exemplos de segmentação dos pulmões em imagens de TC, sendo a) e d)imagens originais. As regiões do pulmão esquerdo e direito se confundem no método Crescimento de Regiões 3D conforme apresentado em b) e e), o que não acontece utilizando o MCA Crisp Adaptativo 3D, cujo os resultados são apresentados em c) e f).	124
4.26	gráfico do tempo de processamento versus quantidade de fatias do exame de TC aplicados em 11 exames.	125
A.1	exemplo de segmentação dos pulmões em imagens de TC realizada manualmente por médicos especialistas.	143
A.2	exemplo de visualização dos pulmões em 3D, sendo a)reconstrução dos pulmões e b)modelo transparente de a).	144
A.3	modelos 3D apresentado juntamente com os planos de corte axial, sagital e coronal auxiliando na visualização dos pulmões.	145
A.4	exemplo de resultado da aplicação da máscara colorida utilizando o sistemas SISDEP (FELIX, 2007), sendo a)imagem original e b)resultado da máscara colorida aplicada em a).	146
A.5	exemplo de resultado da aplicação da máscara colorida em sub-áreas utilizando o sistemas SISDEP (FELIX, 2007).	147
A.6	exemplo de detecção de região hiperaerada em uma imagem de TC do tórax.148	

- A.7 exemplo de modelo 3D com detecção de região hiperaerada em um exame completo de TC tórax. 148
- A.8 exemplos da segmentação dos vasos sanguíneos internos ao pulmão obtidos por Ribeiro (2013), sendo a) e c) imagens originais e b) e d) vasos sanguíneos encontrados em a) e c), respectivamente. 149
- A.9 exemplo de visualização dos vasos presentes em um exame de TC do tórax, sendo a) vasos sanguíneos e b) os pulmões e os vasos apresentados em a). . . 150
- A.10 exemplos de visualização 3D da segmentação dos vasos sanguíneos internos ao pulmão obtidos por Ribeiro (2013). 150
- A.11 exemplo de imagem de TC do tórax com a região óssea apresentada em vermelho, obtida através de limiar da faixa 600 a 2000 UH. 151
- A.12 exemplo de reconstrução 3D da região óssea de um exame de TC do tórax obtida através de Crescimento de Regiões 3D, sendo a) reconstrução óssea 3D e b) reconstrução do pulmão 3D juntamente com região óssea de a). . . 151
- A.13 exemplo dos resultados obtidos por Cavalcante (2010) na detecção das vias aéreas, apresentadas em vermelho, em imagens de TC do tórax, sendo a) corte axial e b) corte coronal. 152
- A.14 exemplo de segmentação das vias aéreas obtida aplicando crescimento de regiões 3D com a semente inicial na traquéia, inicializando de forma manual. 152
- B.1 reconstruções das imagens de seções dos pulmões de TC, adaptada de Sluimer (2005). (a) planos de cortes no corpo, (b) seção sagital, (c) seção axial, (d) seção coronal. 154
- B.2 representação de um elemento de volume *voxel* no lado esquerdo e de um pixel no lado direito, adaptada de Bontrager (2000). 155
- B.3 arranjo esquemático de uma TC (lado esquerdo) e de uma TC com múltiplos detectores (lado direito) , adaptada de Jan (2006). 155
- B.4 posições de cortes dos pulmões em imagens de TC do tórax. (a) anatomia do pulmão, (b) posição ápice, (c) posição hilo, (d) posição base. 156
- B.5 posições de cortes dos pulmões em imagens de TC do tórax. (a) anatomia do pulmão, (b) posição ápice, (c) posição hilo, (d) posição base. 157

Lista de Tabelas

2.1	<i>critério de avaliação qualitativa de segmentação de imagens.</i>	36
2.2	<i>representação matemática de uma matriz de confusão (Adaptada de Figueiredo e Vieira (2007)).</i>	38
2.3	<i>índice Kappa e o correspondente desempenho da classificação (CONGALTON; GREEN, 1999).</i>	39
4.1	<i>descrição dos exames completos utilizados para avaliação dos algoritmos 2D e 3D.</i>	90
4.2	<i>descrição das amostras de imagens utilizadas para avaliação dos algoritmos 2D.</i>	90
4.3	<i>média (μ) e desvio-padrão (σ) dos índices de ajuste de posição obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.</i>	102
4.4	<i>média (μ) e desvio-padrão (σ) dos índices de ajuste de intensidade obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.</i>	104
4.5	<i>média (μ) e desvio-padrão (σ) dos índices de ajuste de tamanho obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.</i>	105
4.6	<i>média (μ) e desvio-padrão (σ) dos índices de ajuste de forma obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.</i>	107
4.7	<i>tempo médio de processamento de cada método analisado.</i>	108
4.8	<i>avaliação qualitativa dos médicos M1 e M2 dos resultados obtidos pelo método Crescimento de Regiões 3D.</i>	118
4.9	<i>avaliação qualitativa dos médicos M1 e M2 dos resultados obtidos pelo método Crisp Adaptativo 3D.</i>	118

4.10	<i>avaliação qualitativa dos médicos M1 e M2 dos resultados obtidos pelos métodos Crescimento de Regiões 3D e MCA Crisp Adaptativo 3D.</i>	119
A.1	<i>análise estatística do resultados apresentados na Figura A.4 obtidos através da máscara colorida utilizando o SISDEP (FELIX, 2007).</i>	146
A.2	<i>análise estatística do resultados apresentados na Figura A.5 obtidos através da máscara colorida por sub-áreas utilizando o SISDEP (FELIX, 2007). . .</i>	147

Lista de Siglas

ADP	Análise das Densidades Pulmonares
CR	Crescimento de Região
CRAD	Crisp Adaptativo
DICOM	Comunicação de Imagens Digitais em Medicina (<i>Digital Imaging and Communications in Medicine</i>)
DPOC	Doença Pulmonar Obstrutiva Crônica
GVF	Fluxo de Vetor Gradiente (<i>Gradient Vector Flow</i>)
GGVF	Fluxo de Vetor Gradiente Generalizado (<i>Generalized Gradient Vector Flow</i>)
IA	Inteligência Artificial
LIX	Limite Inferior no Eixo das Abscissas
LSX	Limite Superior no Eixo das Abscissas
LIY	Limite Inferior no Eixo das Ordenadas
LSY	Limite Superior no Eixo das Ordenadas
MCA	Método de Contornos Ativos
MLP	Perceptron multi camadas (<i>Multi Layer Perceptron</i>)
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagens
PS	Perceptron Simples
RNA	Redes Neurais Artificiais
RP	Reconhecimento de Padrões
SNR	Relação Sinal Ruído (<i>Signal-to-Noise Ratio</i>)
SISDEP	Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar
SVC	Sistema de Visão Computacional
TC	Tomografias Computadorizadas

TCAR	Tomografias Computadorizadas de Alta Resolução
TF	Transformada de Fourier
TFI	Transformada de Fourier Inversa
TFD	Transformada de Fourier Discreta
TFDI	Transformada de Fourier Discreta Inversa
TH	Transformada de Hilbert
THD	Transformada de Hilbert Discreta
THR	Transformada de Hilbert Radial
THRG	Transformada de Hilbert Radial Generalizada
THRGD	Transformada de Hilbert Radial Generalizada Discreta
THRMult	Transformada de Hilbert Radial Multidirecional
THRMod	Transformada de Hilbert Radial Multidirecional Modular
UH	Unidades Hounsfield
VC	Visão Computacional
VFC	Convolução de Campo de Vetor (<i>Vector Field Convolution</i>)

Resumo

Sistemas computacionais vêm desempenhando papel importante em várias áreas da medicina, notadamente no auxílio ao diagnóstico médico por imagem. Neste sentido, estudos na área de Visão Computacional são realizados para desenvolver técnicas e sistemas capazes de detectar automaticamente diversas doenças. Dentre os exames existentes que permitem o auxílio ao diagnóstico e a aplicação de sistemas computacionais em conjunto, destaca-se a Tomografia Computadorizada (TC) que possibilita a visualização de órgãos internos, como por exemplo, o pulmão e suas estruturas. Sistemas de Visão Computacional utilizam estas imagens obtidas por exames de TC para extrair informação por meio de técnicas com a finalidade de segmentar, reconhecer e identificar detalhes da região de interesse nestas imagens. Este trabalho centraliza seus esforços na etapa de segmentação dos pulmões a partir de imagens de TC, empregando-se, para tanto, técnicas baseadas em Método de Contorno Ativo (MCA), também conhecido como *snake*. Este método consiste em traçar uma curva inicial, em torno ou dentro de um objeto de interesse, deformando-a conforme algumas forças que atuam sobre a mesma, deslocando-a até as bordas do objeto. Este processo é realizado por iterações sucessivas de minimização de uma dada função energia, associada à curva. Neste contexto, esta tese propõe um novo método para a segmentação dos pulmões em imagens de TC do tórax denominado Método de Contorno Ativo Crisp Adaptativo. Este MCA é o aperfeiçoamento do MCA Crisp desenvolvido em um estudo anterior, que visa aumentar a precisão, diminuir o tempo de análise e reduzir a subjetividade na segmentação e análise dos pulmões dessas imagens pelos médicos especialistas. Este método é proposto para a segmentação de uma imagem isolada ou do exame completo, sendo primeiramente em 2D e expandido para 3D. O MCA Crisp Adaptativo 2D é comparado com os MCAs THRMulti, THRMod, GVF, VFC, Crisp e também com o sistema SISDEP, sendo esta avaliação realizada utilizando como referência 36 imagens segmentadas manualmente por um pneumologista. Já o MCA Crisp Adaptativo 3D é aplicado na segmentação dos pulmões em exames de TC e comparado com o método Crescimento de Regiões 3D, cujos resultados das segmentações são avaliados por 2 médicos pneumologistas. Os resultados obtidos demonstram que os métodos propostos

são superiores aos demais na segmentação dos pulmões em imagens de TC do tórax, tanto em uma imagem pelo MCA Crisp Adaptativo 2D, como em exames completos pelo MCA Crisp Adaptativo 3D. Deste modo, pode-se concluir que estes métodos podem integrar sistemas de auxílio ao diagnóstico médico na área de Pneumologia.

Palavras-chaves: métodos de contornos ativos, imagens de TC do tórax, segmentação de pulmões.

Abstract

Computer systems have been playing a very important role in many areas of medicine, particularly, on medical diagnosis through image processing. Therefore, studies on the field of Computer Vision are made to develop techniques and systems to perform automatic detection of several diseases. Among the existing tests that enable the diagnosis and the application of computational system together, there is the Computed Tomography (CT), which allows the visualization of internal organs, such as the lung and its structures. Image analysis techniques applied to CT scans are able to extract important information to segment and recognize details on regions of interest on these images. This work focuses its efforts on the stage of lungs segmentation through CT images, using techniques based on Active Contour Method (ACM), also known as snake. This method consists in tracing an initial curve, around or inside the object of interest, which deforms itself according to forces that act over the same, shifting to the object edge. This process is performed by successive iterations of minimization of a given energy, associated to the curve. In this context, this work proposes a new approach for lung segmentation of chest CT images, which is called Adaptive Crisp Active Contour Method. This ACM is an improvement of the previous developed Crisp ACM. The purpose of this new ACM is to increase accuracy, decrease analysis time and reduce segmentation subjectivity in the manual analysis of specialized doctors. This method is proposed to isolated images segmentation or the complete exam, being first in 2D, then expanding to 3D. The 2D Adaptive Crisp ACM is compared to ACMs THRMulti, THRMod, GVF, VFC, Crisp and also with the system SISDEP, being this evaluation performed by using a set of 36 manually segmented images by one pulmonologist. The 3D Adaptive Crisp ACM is applied on lung segmentation in CT exams and compared with the 3D Region Growing method, which segmentation results were evaluated by two pulmonologists. The obtained results shows that the proposed methods are superior to the other methods on lung segmentation in chest CT images, both as in one image by 2D Adaptive Crisp ACM as in full exam by the 3D Adaptive Crisp ACM. Thus, it is possible to conclude that these method can integrate systems to aid medical diagnosis in the field of pulmonology.

Palavras-chaves: active contour methods, Chest CT images, lungs segmentation.

Agradecimentos

À Deus;

Aos meus pais, Pedro Pedrosa e Maria Walmira, pela oportunidade de estudar, e pelo carinho, amor e apoio ao longo da minha formação como homem;

À minha amada e grande amiga Elizângela Rebouças pelo apoio, carinho, atenção e incentivo no constante aprendizado dos caminhos da vida;

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

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

Às minhas irmãs, primos, tios e familiares em geral, pelo carinho, apoio e incentivo;

Aos amigos Auzuir, John, Carlos, Tarique, Alyson e Thomaz pelo apoio durante o curso de doutorado;

Aos amigos e amigas, que ajudaram de forma direta ou indireta, com apoio e incentivo;

Aos colegas e amigos da área da Indústria do IFCE de Maracanaú pelo apoio, incentivo e paciência.

Ao Laboratório de Teleinformática (LATIN/LESC);

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

Ao Dr. Coelho pela disponibilidade em gerar o padrão ouro;

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

*“Se podemos sonhar,
também podemos tornar nossos sonhos realidade.”*

Walt Disney

Capítulo 1

Introdução

O desenvolvimento de sistemas computacionais combinado ao conhecimento médico, tem possibilitado a construção de equipamentos importantes para o diagnóstico de doenças e acompanhamento de seus tratamentos. Dentre as áreas promissoras para este fim, destaca-se o uso do Processamento Digital de Imagens aplicado na análise de imagens médicas (CAVALCANTE, 2010; FELIX, 2011; RIBEIRO, 2013).

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. Dentre os equipamentos de aquisição destas imagens ressalta-se a Tomografia Computadorizada (TC) (HERMAN, 2009).

A TC consiste em se obter um mapeamento adequado do coeficiente de atenuação dos raios-X que atravessa o corpo em análise e, a partir destes dados, reconstruir um modelo deste corpo que represente a forma anatômica mais próxima do real. O tomógrafo, equipamento que realiza a TC, foi desenvolvido por Godfrey Hounsfield, permitindo computar imagens em seções cruzadas de alta qualidade, possibilitando processar um número muito grande de medidas com operações matemáticas bastante complexas, e ainda adquirir um resultado com grande exatidão (KALENDER, 2006).

A imagem obtida a partir de uma TC é digital, em que o valor de cada *voxel* corresponde ao coeficiente de atenuação da intensidade dos raios-X, expresso em Unidades Hounsfield (UH). Este coeficiente de atenuação possui valores específicos para cada tecido ou estrutura do corpo humano, por exemplo, o tecido ósseo está entre 600 e 2000 UH (GEVENOIS; YERNAULT, 1995; FORTALEZA, 2006; KALENDER, 2006).

As informações obtidas a partir de imagens médicas são provenientes de processos computacionais, realizado através de Processamento Digital de Imagem (PDI), Reconhecimento de Padrões (RP), Inteligência Artificial (IA), entre 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 (VC) para aplicações como detecção, reconhecimento e classificação de objetos, estimativa de parâmetros, análise de formas e descrição de cenas (GONZALEZ; WOODS, 2010).

Desse modo, o tomógrafo é capaz de adquirir imagens de órgãos e suas estruturas internas para que o médico possa realizar a detecção, bem como o acompanhamento de doenças. Além disso, sistemas de VC, em geral, reduzem o tempo de análise de exames médicos por imagem e, ao mesmo tempo, aumenta-se a acurácia no diagnóstico, auxiliando o médico especialista em suas interpretações (SILVA, 2004; LI; LIU; FOX, 2005; FELIX; CORTEZ; HOLANDA, 2010).

Sistemas de VC utilizam várias técnicas com a finalidade de segmentar, reconhecer e identificar detalhes de regiões de interesse na imagem. Estes sistemas são divididos basicamente em cinco etapas consecutivas: aquisição, pré-processamento, segmentação, às vezes pós-processamento, extração de atributos, reconhecimento e interpretação (GONZALEZ; WOODS, 2010).

A etapa de aquisição consiste no processo de captura da imagem. Geralmente são utilizados, na aquisição de imagens médicas, equipamentos de raios-X, Doppler colorido, tomógrafos, ultrassonografia, dentre outros. A aferição e ajuste dos dispositivos de aquisição são de fundamental importância nesta etapa (SONKA; HLAVAC; BOYLE, 2008).

O pré-processamento é necessário para condicionar a imagem para etapa de segmentação e, normalmente, são utilizadas técnicas de PDI para extrair ruídos e efetuar operações de restauração ou realce (ALEXANDRIA, 2005; GONZALEZ; WOODS, 2010).

A segmentação é a etapa responsável por dividir a imagem em regiões de interesse, tendo fundamental importância em um sistema de VC, em que o desempenho destes sistemas depende essencialmente da qualidade desta etapa. Em seguida, a etapa de extração de atributos, identifica informações que caracterizam os objetos segmentados previamente (NIXON; AGUADO, 2002).

Por fim, a etapa de reconhecimento e interpretação classifica os objetos utilizando normalmente técnicas de RP e IA, que empregam os atributos extraídos previamente (SONKA; HLAVAC; BOYLE, 2008).

Esta tese centraliza seus esforços na etapa de segmentação de pulmões em imagens de TC. Neste sentido, técnicas de segmentação dos pulmões são propostas e analisadas para acelerar e melhorar a análise dos pulmões em imagens de TC. Esta etapa é primordial em

um sistema de VC na área da Pneumologia, visto que, uma vez realizada a segmentação dos pulmões, é importante que esta seja precisa, com mínimos erros possíveis, seja por adição de regiões que não fazem parte dos pulmões, ou por remoção de partes destes.

Erros na etapa de segmentação dos pulmões podem alterar a análise do médico especialista, resultando em um diagnóstico impreciso. Atualmente, este processo é manual e subjetivo, envolvendo uma grande variabilidade intra e interindividual por parte dos médicos pneumologistas. Além disto, esta segmentação manual demanda muito tempo, visto que exames completos do pulmão podem chegar até a 1000 imagens.

Uma maneira de acelerar este processo é utilizar algumas ferramentas que podem ser instaladas na *workstation* do tomógrafo ou em estações comuns de consultórios. Estas ferramentas podem ser utilizadas por especialistas para obter a segmentação dos pulmões em imagens de TC do tórax. Em geral, este processo é realizado de forma manual utilizando técnicas simples de PDI, como filtros e segmentação por Crescimento de Regiões, na qual o especialista segmenta de forma manual os objetos de interesse, selecionando os pontos iniciais e delimitando as regiões em que os objetos poderão ser detectados. Esta operação é realizada para selecionar os objetos que devem permanecer na imagem, e, às vezes, é aplicada a mesma operação para excluir os objetos indesejados. Este processo é demorado e torna-se mais complexo quando os pulmões apresentam alguma doença ou anomalia morfológica.

Com a finalidade de atenuar os problemas citados, é importante desenvolver um método que possibilite uma segmentação correta, automática e precisa dos pulmões em imagens de TC, considerando apenas uma imagem ou o exame completo. Isto se faz necessário para que a análise dos pulmões, de suas estruturas internas e de suas doenças seja realizada com sucesso, reduzindo o tempo de avaliação dos exames e aumentando sua acurácia, bem como auxiliando o médico pneumologista em suas interpretações.

Além disto, faz-se necessário transferir este processo da *workstation*, pois este equipamento possui valor elevado e não está presente no consultório do médico especialista.

1.1 Motivação

Dentre as doenças que afetam a população mundial, grande parte acontece nos pulmões. Deste modo, as pesquisas na área de Pneumologia tem grande importância na saúde, em que destaca-se a preocupação com a asma, bronquiectasia e a Doença Pulmonar Obstrutiva Crônica (WINKELER, 2006; FORTALEZA, 2006).

A Organização Mundial de Saúde (OMS) estima que existam 300 milhões de pessoas que sofrem de asma, e que esta doença causa cerca de 250 mil mortes por ano em todo mundo (CAMPOS; LEMOS, 2009). Além disto, a OMS estima que 210 milhões de pessoas tinham DPOC em todo o mundo, causando a morte de mais de 300 milhões de pessoas em 2005 (OMS, 2008). Estudos recentes revelam que a DPOC está presente no grupo etário de 20 a 45 anos, embora caracterize-se por ser uma doença de pessoas com idade superior a 50 anos. Neste sentido, a OMS estima que o número de mortes por DPOC deve aumentar 30% até 2015, e que em 2030 a DPOC seja a terceira causa de morte em todo o mundo (MARCO et al., 2004).

No período de 1992 até 2006, 15% de todas as hospitalizações financiadas pelo Sistema Único de Saúde no Brasil foram causadas por doenças respiratórias, em que a asma e a DPOC somadas geraram 562.016 hospitalizações (CAMPOS; LEMOS, 2009).

Neste contexto, é de fundamental importância para saúde pública realizar e determinar diagnósticos precoces e corretos para detectar os estágios reais das doenças pulmonares. O auxílio ao diagnóstico mostra-se importante tanto do ponto de vista clínico quanto em pesquisa. Dentre os fatores que contribuem para isto, pode-se citar o aumento da precisão do diagnóstico do médico especialista à medida que aumenta o número de informações sobre o estado do paciente. Deste modo, certas doenças podem ser detectadas precocemente, inclusive salvando vidas em alguns casos. Além disto, algumas técnicas desenvolvidas permitem que o quadro clínico evolutivo da doença seja devidamente acompanhado (FELIX et al., 2007a; LIANG et al., 2008).

Considerando um sistema de VC na área de Pneumologia, constata-se que a etapa de segmentação é essencial para o auxílio ao diagnóstico médico correto e preciso, visto que esta etapa delimita a área dos pulmões em imagens de TC do tórax que deve ser analisada pelo sistema ou pelo médico especialista.

Neste sentido, o Apêndice A apresenta alguns exemplos de auxílio ao diagnóstico médico na área da Pneumologia a partir da segmentação dos pulmões, bem como de suas estruturas internas e doenças.

A segmentação de objetos ou estruturas em imagens médicas é um processo que, em geral, é mais complexo se comparado com a segmentação de outros tipos de imagens. Isto ocorre devido à variabilidade das formas de estruturas e/ou órgãos internos, dependendo inclusive do plano de visualização destas imagens. Além disso, há a possibilidade de doenças afetarem estes órgãos, contribuindo para aumentar a dificuldade no desenvolvimento de técnicas eficientes de segmentação de imagens médicas (FELIX, 2011). O Apêndice B apresenta uma introdução à anatomia do pulmão apresentada em imagens de

TC do tórax, inclusive apresentando os planos e as posições de corte usadas nesta tese.

Neste contexto, a solução proposta nesta tese é um novo MCA denominado Método de Contorno Ativo Crisp Adaptativo. Este MCA é o aperfeiçoamento do MCA Crisp desenvolvido previamente pelo autor REBOUÇAS FILHO (2010). O MCA proposto nesta tese visa aumentar a acurácia, diminuir o tempo de análise e reduzir a subjetividade na segmentação e análise dos pulmões em imagens médicas nos exames de TC do tórax pelos médicos especialistas. Este método é proposto para a segmentação apenas de uma imagem ou do exame completo, devido este ser proposto primeiramente em 2D para segmentação dos pulmões em apenas uma imagem de TC, e expandido para 3D, em seguida, visando segmentar os pulmões em um exame completo de TC do tórax.

1.2 Estado da arte

Uma imagem de TC dos pulmões representa uma fatia da caixa torácica onde encontra-se diversas estruturas, como vasos, artérias, vias aéreas, pleura e parênquima pulmonar, possuindo cada uma, informações específicas. Assim, para a análise e o auxílio ao diagnóstico de doenças pulmonares, é necessária a segmentação dos pulmões como ponto de partida.

Neste sentido, técnicas de segmentação dos pulmões são desenvolvidas buscando otimizar esta etapa. Dentre estas, Sluimer, Prokop e Ginneken (2005) e Felix et al. (2007a) obtêm a segmentação dos pulmões em imagens de TC através de crescimento de região.

Já Felix et al. (2007b), Hu, Hoffman e Reinhardt (2001), Silva et al. (2006) combinam morfologia matemática, crescimento de região, limiarização e detecção de bordas para obter resultados mais precisos.

Silva (2005) e Itai, Kim e Ishikawa (2007) utilizam técnicas de MCA Tradicionais para segmentar os pulmões, enquanto Shojaii, Alirezaie e Babyn (2005) utilizam transformada *watershed* para obter a segmentação dos pulmões.

Os métodos tradicionais de segmentação baseados em Limiarização, Crescimento de Regiões, detecção de bordas, Watershed não costumam apresentar resultados consistentes em imagens de TC do tórax (REBOUÇAS FILHO, 2010; FELIX, 2011). Isto acontece, no primeiro caso, pela imprecisão na detecção das bordas dos pulmões geradas pelas estruturas internas, como veias, artérias e vias áreas (CAVALCANTE, 2010). Já no segundo caso, doenças pulmonares ou ruídos podem distorcer as densidades radiológicas expressas em UH dos pulmões (FELIX, 2011). Além disso, técnicas de segmentação que utilizam as

informações de bordas ou características de regiões separadamente, em geral, apresentam resultados insuficientes e são adequados somente para casos específicos (FELIX, 2011). Este fato ocorre, devido a estas técnicas incluírem estruturas que não fazem parte do tecido pulmonar, o qual se deseja analisar, tais como: a traquéia, o hilo e parte da cavidade do tórax (HU; HOFFMAN; REINHARDT, 2001; SILVA et al., 2001, 2006; FELIX; CORTEZ; HOLANDA, 2008).

Com o objetivo de contornar restrições de técnicas anteriormente mencionadas, destacam-se as técnicas de segmentação desenvolvida no Sistema de Detecção de Enfisema Pulmonar (SISDEP) (FELIX, 2007), o Método de Contorno Ativo Crisp (REBOUÇAS FILHO, 2010) e os métodos de Contornos Ativos Hilbert 2D (FELIX, 2011). O sistema SISDEP faz a segmentação automática dos pulmões através da técnica de Crescimento de Região associadas com as operações morfológicas de fechamento e erosão (FELIX, 2007).

Os MCAs tem sido amplamente aplicados na segmentação de estruturas ou objetos em diversos tipos de imagens médicas, como por exemplo, em imagens de ressonância magnética do coração e do cérebro (PLUEMPITIWIRIYAJEJ; SOTTHIVIRAT, 2005; LIANG; DING; WU, 2008; SOUZA, 2003), em imagens de ecocardiografia (TAUBER; BATATIA; AYACHE, 2005; SILVA JUNIOR et al., 2010) e em imagens de TC de abdomens e tórax (SHEN; KASSIM, 2007; ITAI; KIM; ISHIKAWA, 2007; REBOUÇAS FILHO, 2010; CAVALCANTE et al., 2010), dentre outras.

O MCA Crisp é um método automático de segmentação especificamente dos pulmões em imagens de TC do tórax. Este método é baseado nos MCAs Tradicionais e nas densidades radiológicas dos pulmões, obtendo resultados promissores na segmentação dos pulmões. Entretanto, este método possui algumas falhas na distinção de bordas do pulmão das bordas de suas estruturas internas, bem como apresenta erros na segmentação de regiões côncavas (REBOUÇAS FILHO, 2010).

Um conceito de Modelo de Contorno Ativo 3D é proposto por Shen et al. (2009), em que este modelo é considerado um sólido elástico, sendo chamado de Modelo de Volume Ativo. Este modelo deforma-se através de um sistema linear auxiliado por algoritmos genéticos para codificar uma região de interesse de forma binária. Este método é aplicado na segmentação de imagens médicas de forma genérica, e não soluciona os problemas encontrados na segmentação dos pulmões que são as doenças e anatomias diferentes, além de necessitar uma inicialização manual próxima ao objeto de interesse (SHEN; LI; HUANG, 2011).

Entretanto, Shang et al. (2011) propõe um MCA 3D denominado Contorno Ativo Vascular, tendo sua aplicação voltada para segmentação dos vasos pulmonares. Este

método aplica Crescimento de Regiões 3D para encontrar os cilindros grossos da árvore de vasos, em seguida cria um campo vetorial que parte do centro destes vasos grossos para os vasos finos utilizando a matriz Hessiana da imagem. Entretanto, este MCA 3D não aplica-se na segmentação dos pulmões visto que sua forma não é tubular como os vasos.

Outra metodologia adotada na segmentação dos pulmões é o Crescimento de Regiões 3D, sendo aplicado na segmentação dos pulmões e de suas estruturas internas, como, por exemplo, os vasos e vias aéreas (BORN et al., 2009; IRVING; TAYLOR; TODD-POKROPEK, 2009; TSCHIRREN; YAVARNA; REINHARDT, 2009; MATSUOKA et al., 2010). Este método funciona semelhante ao Crescimento de Regiões em 2D, sendo sua região inicializada por uma semente, e esta se expande pelos seus vizinhos, obedecendo uma regra de agregação. Dentre as causas dos problemas deste método na segmentação dos pulmões, resalta-se as estruturas internas e as doenças pulmonares, pois estas causam erros na inicialização e na adesão de regiões à região de interesse.

Neste sentido, esta tese propõe o MCA Crisp Adaptativo 2D visando reduzir os erros e o tempo de processamento na segmentação dos pulmões em imagens de TC. Este método é avaliado e comparado com os MCAs Tradicionais, Crisp e os baseados na transformada de Hilbert quanto à qualidade e eficiência na segmentação dos pulmões em imagens de TC do tórax. Esta tese também expande este método para três dimensões, propondo o MCA Crisp Adaptativo 3D para segmentar os pulmões em exames completos de TC do tórax. Este método é avaliado e comparado com o Crescimento de Regiões 3D quanto à qualidade da segmentação dos pulmões em exames de TC do tórax.

1.3 Objetivos

O principal objetivo desta tese é desenvolver novos Métodos de Contornos Ativos baseados em Redes Neurais Artificiais e nas densidades radiológicas dos pulmões para segmentar automaticamente os pulmões em imagens de TC do tórax em duas (2D) e três dimensões (3D).

1.3.1 Objetivos específicos

Os objetivos específicos que devem ser alcançados neste trabalho são:

- propor um novo método de inicialização automática de contornos ativos;
- aplicar e avaliar o novo MCA Crisp Adaptativo 2D na segmentação dos pulmões em

imagens de TC do tórax, comparando-o com o sistema SISDEP e com os métodos de segmentação Crisp, GVF, VFC e os MCAs baseados na transformada de Hilbert quanto à qualidade, precisão e velocidade de segmentação;

- comparar a exatidão dos algoritmos na segmentação das imagens de TC dos pulmões em relação a um padrão-ouro obtido junto a especialistas médicos;
- aplicar e avaliar o novo MCA Crisp Adaptativo 3D em exames de TC dos pulmões e comparar com o Crescimento de Regiões 3D de forma qualitativa junto a especialistas médicos;
- implementar a visualização 3D dos pulmões;
- produzir trabalhos científicos e/ou tecnológicos.

1.4 Contribuições

As principais contribuições desta tese são:

- método de inicialização automática de contornos ativos 2D;
- método de inicialização automática de contornos ativos 3D;
- energia interna para Métodos de Contornos Ativos 2D para segmentação dos pulmões;
- energia externa para Métodos de Contornos Ativos 2D para segmentação dos pulmões;
- métodos de adição e remoção de pontos para MCAs 2D;
- MCA 2D para segmentação dos pulmões em imagens de TC;
- energia interna para Métodos de Contornos Ativos 3D para segmentação dos pulmões;
- energia externa para Métodos de Contornos Ativos 3D para segmentação dos pulmões;
- métodos de adição e remoção de pontos para MCAs 3D;
- MCA 3D para segmentação dos pulmões em exames de TC do tórax; e
- método de visualização dos pulmões em 3D.

1.5 Produção Científica

As produções científicas realizadas no período de desenvolvimento desta pesquisa.

- depósito de patentes:

CORTEZ, P.C.; REBOUÇAS FILHO, P.P.; FELIX, J.H.S.; HOLANDA, M.A.; CAVALCANTE, T.S. PATENTE SOB SIGILO - PROTOCOLO 013090001002, 2009.

- artigos publicados em revistas:

REBOUÇAS FILHO, P.P.; CORTEZ, P.C.; HOLANDA, M.A. Modelo de Contorno Ativo Crisp: nova técnica de segmentação dos pulmões em imagens de TC. Revista Brasileira de Engenharia Biomédica, vol. 27, págs. 259-272, 2011.

Produções com co-autorias na área de segmentação de imagens médicas:

- artigos publicados em congressos:

CAVALCANTE, T.S.; CORTEZ, P.C.; REBOUÇAS FILHO, P.P.; FELIX, J.H.S.; HOLANDA, M.A. ; MAIA FILHO, J.H. ADP e MLP como Métodos de Detecção Automática de Vias Aéreas em Imagens 2D de Tomografia Computadorizada do Tórax. In: V CLAIB 2011 - V Congresso Latino-Americano de Engenharia Biomédica, Havana- Cuba, 2011.

FELIX, J.H.S.; CORTEZ, P.C.; CAVALCANTE, T.S.; ALEXANDRIA, A.R.; REBOUÇAS FILHO, P.P.; HOLANDA, M.A. Method of Automatic Initialization of Active Contours Applied to Lungs in Computed Tomography Images. In: V CLAIB 2011 - V Congresso Latino-Americano de Engenharia Biomédica, Havana- Cuba, 2011.

FELIX, J.H.S.; CORTEZ, P.C.; ALEXANDRIA, A.R.; REBOUÇAS FILHO, P.P.; CAVALCANTE, T.S.; HOLANDA, M.A. Novo Método de Contornos Ativo Baseado na Transforma de Hilbert Radial. In: V CLAIB 2011 - V Congresso Latino-Americano de Engenharia Biomédica, Havana- Cuba, 2011.

ALEXANDRIA, A.R.; CORTEZ, P.C.; FELIX, J.H.S.; CAVALCANTE, T.S.; REBOUÇAS FILHO, P.P.; SILVA JUNIOR, J.A.C. Hilbertian Energy: a method for external energy calculation on radial active contours. In: IWSSIP 2010 - 17th International Conference on Systems, Signals and Image Processing, Rio de Janeiro, 2010.

CAVALCANTE, T.S.; CORTEZ, P.C.; REBOUÇAS FILHO, P.P.; FELIX, J.H.S.; ALEXANDRIA, A.R.; HOLANDA, M.A. Comparative analysis of segmentation

techniques of airways on images of chest computed tomography. In: IWSSIP 2010 - 17th International Conference on Systems, Signals and Image Processing, Rio de Janeiro, 2010.

CAVALCANTE, T.S.; CORTEZ, P.C.; REBOUÇAS FILHO, P.P.; ALMEIDA, T.M.; FELIX, J.H.S.; HOLANDA, M.A. Segmentação de Vias Aéreas em Imagens de Tomografia Computadorizada Por Métodos de Contornos Ativos. In: XXII Congresso Brasileiro de Engenharia Biomédica, Tiradentes, MG, 2010.

- depósito de patentes:

CORTEZ, P.C.; FELIX, J.H.S.; HOLANDA, M.A.; ALEXANDRIA, A.R.; REBOUÇAS FILHO, P.P.; CAVALCANTE, T.S. PATENTE SOB SIGILO - PROTOCOLO 013100000235, 2010.

CORTEZ, P.C.; FELIX, J.H.S.; HOLANDA, M.A.; ALEXANDRIA, A.R.; REBOUÇAS FILHO, P.P.; CAVALCANTE, T.S. PATENTE SOB SIGILO - PROTOCOLO 013090000954, 2009.

ALEXANDRIA, A.R.; CORTEZ, P.C.; FELIX, J.H.S.; REBOUÇAS FILHO, P.P.; CAVALCANTE, T.S.; SILVA JÚNIOR, J.C. PATENTE SOB SIGILO - PROTOCOLO 220907267030, 2009.

1.6 Organização da tese

Esta tese está organizada em 5 Capítulos. Uma revisão bibliográfica sobre técnicas de PDI, métodos de contornos ativos, medidas de avaliação de segmentação e Rede Neural Artificial é apresentada no Capítulo 2. No Capítulo 3, por sua vez, são abordadas as contribuições deste trabalho: métodos de contornos ativos 2D e 3D baseados nas densidades radiológicas e em Redes Neurais, além de suas generalizações para segmentação de objetos em imagens digitais diversas. No Capítulo 4 são mostrados os resultados obtidos e realizadas as suas discussões. No Capítulo 5, por fim, são apresentadas as conclusões e contribuições desta tese.

Capítulo 2

Fundamentação teórica

Neste Capítulo primeiramente é apresentado com detalhes o conceito e os tipos de segmentação de objetos em imagens digitais, bem como a teoria dos MCAs, suas vantagens e limitações. Em seguida, a teoria de Redes Neurais Artificiais utilizada nesta tese é posta. Por fim, as métricas de avaliação de segmentação adotadas são apresentadas.

2.1 Segmentação

A segmentação de imagens é um dos principais processos constituintes de um sistema de Visão Computacional, cujo objetivo é separar as regiões que compõem uma imagem para que seja possível a extração de atributos das mesmas. Deste modo, regiões disjuntas podem ser caracterizadas individualmente como áreas com semelhança de níveis de cinza, textura ou outra característica de interesse para aplicação. Portanto, a segmentação consiste em atribuir um rótulo a cada *pixel* da imagem, identificando a qual região este pertence, de acordo com suas propriedades (GONZALEZ; WOODS, 2010).

De acordo com Gonzalez e Woods (2010), as técnicas de segmentação de imagens geralmente são baseadas em duas propriedades básicas: similaridade e descontinuidade. A primeira categoria baseia-se na divisão da imagem em regiões similares, cujo o critério de semelhança é estabelecido previamente. A limiarização e o crescimento de regiões são exemplos de segmentação por similaridade. Já a segmentação por descontinuidade, separa as regiões de uma imagem baseada em mudanças bruscas nas características de *pixels* vizinhos, como a detecção de pontos, linhas e bordas na imagem.

2.1.1 Segmentação por similaridade

Segmentação por similaridade baseia-se na separação de objetos por possuírem valores próximos de uma dada características pré-estabelecida. Dentre os métodos que integram este tipo de segmentação, destacam-se a Limiarização e o Crescimento de Regiões.

Limiarização

A técnica de segmentação baseada na limiarização tem como princípio básico determinar um valor como limiar, geralmente em tom de cinza, que esteja dentro do intervalo de tonalidades da imagem. Por exemplo, em uma imagem com resolução de 8 *bits*, o limiar pode estar entre 0 e 255. Após estabelecer os limiares de cada região da imagem, é possível rotular cada *pixel*, associando-o à faixa de valores estabelecido em cada região. Quando só existem duas regiões para a classificação, uma destas regiões recebe rótulo 0 e a outra região recebe rótulo 1, sendo esta técnica, neste caso, denominada de binarização. Deste modo, a operação que resulta em uma imagem binarizada B por um limiar fixo L em uma imagem I é definida em cada pixel de coordenadas (x, y) pela equação (GONZALEZ; WOODS, 2010)

$$B(x, y) = \begin{cases} 1, & \text{se } I(x, y) > L \\ 0, & \text{caso contrário.} \end{cases} \quad (2.1)$$

Em uma mesma imagem pode ser estabelecido mais de um limiar, técnica esta denominada de multi-limiarização (PAPAMARKOS; STROUTHOPOULOS; ANDREADIS, 2000; ZAHARA; FAN; TSAI, 2005). Esta técnica subdivide a imagem em mais de duas regiões, estabelecendo os limites inferior e superior de cada região de interesse. Um exemplo de aplicação desta técnica, utilizando três regiões é

$$R(x, y) = \begin{cases} 0, & \text{para } 0 \leq I(x, y) < 86 \\ 1, & \text{para } 86 \leq I(x, y) < 171 \\ 2, & \text{para } 171 \leq I(x, y) < 256 \end{cases} \quad (2.2)$$

em que $R(x, y)$ classifica cada *pixel* da imagem por um índice i , determinado pelos limiares inferior e superior de cada região, assumindo valor 0 para intensidades de tom de cinza na faixa 0-85, 1 para a faixa 86-170 e 2 para a faixa 171-255.

As técnicas de limiarização possuem a limitação de ser dependente do valor de limiar definido, gerando resultados insatisfatórios quando as imagens possuem ruídos, imperfeições ou mudanças na tonalidade dos objetos de interesse. Neste sentido, diversos

trabalhos propõem técnicas para encontrar valores ótimos de limiar (BERNSEN, 1986; COCQUEREZ; PHILLIP, 1995; JOHANNSEN; BILLE, 1982), porém estes obtêm resultados satisfatórios apenas em aplicações específicas. Além disto, ao aplicar esta técnica em uma imagem que possui mais de um objeto de interesse, faz-se necessário o uso de outras técnicas para identificá-los, pois o uso exclusivo da técnica de limiarização não faz distinção entre tais objetos.

Crescimento de Região

O Crescimento de Região (CR) é uma técnica de segmentação de imagens usadas para unir as regiões de interesse. Esta técnica realiza o agrupamento de subgrupos ou grupos de *pixels* em uma região desejada. Isto é possível através da expansão de uma dada região que é inicializada por um *pixel*, denominado semente. Esta expansão ocorre pela agregação de *pixels* à região por iterações sucessivas de análise da vizinhança de uma dada região (GONZALEZ; WOODS, 2010).

Nesta técnica, para um *pixel* ser agregado à região é necessário que este esteja na vizinhança da mesma e que obedeça a um critério pré-estabelecido. Este, geralmente, baseia-se em parâmetros pré-definidos, como intensidade de tom de cinza, média de tom de cinza na região, entre outros.

Um exemplo de aplicação desta técnica é apresentado na Figura 2.1, em que a semente é mostrada em vermelho na Figura 2.1(a) e a regra de agrupamento é que a tonalidade de cinza seja igual à tonalidade da semente escolhida, resultando na segmentação apresentada na Figura 2.1(b).



Figura 2.1: exemplo de aplicação da técnica de CR: a) imagem original com a semente em vermelho; b) resultado da segmentação em vermelho.

A eficácia desse método depende diretamente da escolha da semente e da regra de agrupamento. Caso estas escolhas não sejam adequadas, a segmentação deve apresentar falhas. Essa técnica pode ser expandida para 3D, adotando a vizinhança de cada elemento a ser analisada considerando planos vizinhos. Essa técnica é comum na segmentação de objetos e imagens médicas, principalmente em imagens de TC, visto que as imagens provenientes deste exame obedecem o padrão citado, em que o conjunto de imagens de TC são ordenadas em uma sequência pré-definida (MATSUOKA et al., 2010; BORN et al., 2009). Nestes casos, o menor elemento é o *voxel* e a vizinhança passa a ser analisada nos eixos x , y e z . Um exemplo da evolução deste método é apresentado na Figura 2.2.




Figura 2.2: ilustração da aplicação do Crescimento de Regiões 3D. a) determinação do *voxel* semente em destaque vermelho, b) primeira iteração do Crescimento de Regiões 3D analisando a vizinhança do *voxel* semente e c) resultado final da segmentação (RIBEIRO, 2013).

2.1.2 Segmentação por descontinuidade

As técnicas de segmentação de imagens, baseadas na detecção de mudanças bruscas entre *pixels* vizinhos na imagem, são responsáveis pela detecção de: pontos, linhas e bordas. O resultado V da detecção de cada um destes métodos pode ser obtido por uma convolução bidimensional dada por

$$V = M_{3 \times 3} * I_{l \times c}, \quad (2.3)$$

em que $I_{l \times c}$ é a imagem analisada com l linhas e c colunas determinadas em números de *pixels*, $*$ é o operador convolução e $M_{3 \times 3}$ é uma matriz com dimensão 3×3 . A detecção de

pontos, linhas e bordas possui máscaras específicas para convolução (GONZALEZ; WOODS, 2010).

Outro modo de detectar pontos, linhas e bordas é a utilização de operadores gradiente na imagem, sendo os principais os operadores de Roberts, Prewitt e Sobel, consideradas variações do operador gradiente (SIEGWART; NOURBAKHS, 2004). Essas técnicas de detecção de bordas são muitas vezes agregadas à outras, gerando novos métodos de segmentação de imagens baseados nos critérios de descontinuidade. Dentre estes, destaca-se o Método de Contorno Ativo.

2.2 Métodos de Contornos Ativos (MCAs)

Diversos estudos são realizados sobre segmentação em imagens digitais, buscando superar as limitações de cada método em aplicações específicas. Deste modo, técnicas existentes são aperfeiçoadas, resultando no desenvolvimento de novos métodos.

Neste contexto, o MCA, também chamado de *snake*, foi introduzido em 1987 por Kass, Witkin e Terzopoulos (1987). Este método permite realizar a segmentação de objetos em imagens digitais por meio da detecção de bordas obtidas por informações da imagem, como exemplo, a intensidade dos níveis de cinza, superando as técnicas tradicionais, até então desenvolvidas.

Inicialmente este método foi aplicado na detecção de objetos em geral, principalmente nas aplicações de segmentação de bordas, detecção de movimento e utilização em visão estéreo (KASS; WITKIN; TERZOPOULOS, 1987; TERZOPOULOS et al., 1987). Posteriormente, é aplicado para resolver diversos problemas de Visão Computacional, abrangendo áreas como: Rastreamento (BARROS, 2010), Materiais para Construção Mecânica (ALBUQUERQUE; TAVARES; Rebouças Filho, 2008; REBOUÇAS FILHO et al., 2009), auxílio ao diagnóstico médico (ALEXANDRIA, 2005; ITAI; KIM; ISHIKAWA, 2007; CAVALCANTE et al., 2010a; FELIX, 2011), Reconhecimento de Padrões (CHEN et al., 2006), entre outros.

O MCA consiste em traçar uma curva inicial em torno ou dentro de um objeto de interesse. Esta curva se deforma, conforme algumas forças que atuam sobre a mesma, deslocando-a até as bordas do objeto. Este processo é realizado por iterações sucessivas de minimização de uma dada energia, associada à curva. De acordo com Souza Júnior (2006), a curva se comporta como uma fita elástica que, uma vez solta em volta de um objeto, molda sua forma para melhor se adaptar a este.

Segundo Pichumani (1997), as vantagens da utilização de MCA para a segmentação

de imagens digitais são:

- facilidade de manipulação, pois, as forças externas se comportam de uma forma intuitiva;
- autonomia e auto-adaptação na busca pelo estado de menor energia;
- baixa sensibilidade ao ruído.

Dentre os MCAs, primeiramente é analisado nesta tese o método Tradicional, detalhando suas forças internas e externas, discutindo sobre suas vantagens e limitações.

2.2.1 MCA Tradicional

Os contornos ativos são baseados em métodos variacionais, considerados modelos deformáveis, em que os pontos da curva são atualizados a cada nova iteração (BOUHOURS, 2006). Este modelo é chamado deformável porque está descrito por uma função de energia E definida por (KASS; WITKIN; TERZOPOULOS, 1987)

$$E = \sum_{s=0}^N (E_{int}[c(s)] + E_{ext}[c(s)])$$

em que o termo E_{int} representa as energias internas da curva, E_{ext} o termo da energia associado com as energias externas e c a curva, cuja parametrização geométrica 2D é dada por (KASS; WITKIN; TERZOPOULOS, 1987)

$$c(s) = [x(s), y(s)], \quad (2.4)$$

no qual a posição de cada ponto $c(s)$ na imagem é determinada pelas coordenadas $x(s)$ e $y(s)$. Uma discretização da equação 2.4 permite definir a energia de cada ponto da curva como

$$E[c(s)] = E_{int}[c(s)] + E_{ext}[c(s)], \quad (2.5)$$

em que E_{int} e E_{ext} são as energias interna e externa do ponto $[c(s)]$ da curva, respectivamente.

O objetivo do MCA é minimizar uma função que representa a energia E da curva, que é realizado atraindo ou repelindo a curva, deslocando-a até as bordas do objeto. Este processo é realizado por iterações sucessivas e, a cada iteração, a curva é atualizada ponto-a-ponto, através de uma minimização local de energia. Isto é possível analisando a vizinhança de cada ponto, calculando as energias envolvidas e movendo-o para a coordenada

que possuir a menor energia total E na vizinhança do ponto $c(s)$ (AMINI; WEYMOUTH; JAIN, 1990).

Neste sentido, tem-se que quanto maior a vizinhança analisada, maior a quantidade de soluções possíveis, porém maior a complexidade do algoritmo e seu tempo de processamento. Um exemplo de vizinhança é ilustrado na Figura 2.3, em que é mostrada a análise dos 8 vizinhos de um ponto $c(s)$.




Figura 2.3: exemplo dos vizinhos considerados no cálculo da energia.

Quanto às energias envolvidas, têm-se que a energia interna é proveniente das forças internas da curva, relativa apenas à sua geometria, relacionada com sua forma e a posição de seus pontos (KASS; WITKIN; TERZOPOULOS, 1987; ITAI et al., 2005). Já a energia externa é proveniente das características da imagem e está associada às informações obtidas a partir desta (KASS; WITKIN; TERZOPOULOS, 1987).

No modelo Tradicional (KASS; WITKIN; TERZOPOULOS, 1987), o termo E_{int} da equação 2.4, é dividido em dois termos, conhecidos como forças internas, conforme

$$E_{int}[c(s)] = \alpha(s) \left| \frac{d}{ds} c(s) \right|^2 + \beta(s) \left| \frac{d^2}{ds^2} c(s) \right|^2, \quad (2.6)$$

em que $\alpha(s)$ e $\beta(s)$ determinam a relevância de cada parcela da energia interna do ponto $c(s)$ (KASS; WITKIN; TERZOPOULOS, 1987). O primeiro termo, $\left| \frac{d}{ds} c(s) \right|^2$ desta equação, é a força ligada à elasticidade da curva ou resistência ao se esticar, denominada de Força de Elasticidade ou de Força de Continuidade. Esta força define a capacidade de um ponto da curva se distanciar ou se aproximar dos pontos vizinhos, atuando na curva deixando-o uniformemente espaçados (KASS; WITKIN; TERZOPOULOS, 1987).

O segundo termo, $\left| \frac{d^2}{ds^2} c(s) \right|$ da equação 2.6, é a Força de Curvatura. Esta é baseada nos ângulos internos da curva e tende a deixá-la contínua para mantê-la suave, em detrimento de trechos irregulares e pontiagudos (NIXON; AGUADO, 2002). Deste modo, favorecendo o coeficiente $\beta(s)$ durante a fase de minimização da energia da curva, esta é forçada a perder a sua curvatura, minimizando sua área interna.

Por outro lado, a energia externa é totalmente obtida a partir de informações da imagem, possuindo diversas formas para sua definição. Alguns autores consideram as informações referentes aos níveis de cinza dos *pixels*, outros consideram as bordas dos objetos da imagem, entre outros.

Para extrair falhas, imperfeições ou ruídos, técnicas de pré-processamento podem ser aplicadas antes do cálculo da energia externa (BOUHOURS, 2006; FELIX et al., 2011). Um exemplo disso é a utilização do filtro gaussiano que produz uma imagem suavizada J a partir de uma imagem I da forma

$$J = G_\sigma * I \quad (2.7)$$

em que G_σ é uma gaussiana e $*$ é o operador convolução.

Segundo Sonka, Hlavac e Boyle (2008) e Nixon e Aguado (2002) a energia externa é composta por

$$E_{externa}[c(s)] = w_{line}E_{line}[c(s)] + w_{grad}E_{grad}[c(s)] + w_{term}E_{term}[c(s)], \quad (2.8)$$

em que a energia E_{line} considera a energia proveniente das linhas, E_{grad} considera o gradiente da imagem e E_{term} é a energia relativa às terminações. Os termos w_{line} , w_{grad} e w_{term} são os pesos que determinam a importância de cada energia na energia externa total.

Para Nixon e Aguado (NIXON; AGUADO, 2002), o resultado de um operador gradiente, como o operador Sobel, na imagem já extrai informações de linhas, terminações e bordas dos objetos, podendo este ser utilizado como energia externa. Deste modo, o cálculo da energia externa é otimizado, sendo calculado apenas uma componente que já possui as três informações necessárias.

MCA Tradicional - método *Greedy*

O algoritmo MCA *Greedy* utiliza a definição de Kass, Witkin e Terzopoulos (1987) para implementar o MCA Tradicional, inserindo a equação 2.6 na equação 2.4, resultando em

$$E[c(s)] = \alpha(s) \left| \frac{dc(s)}{ds} \right|^2 + \beta(s) \left| \frac{d^2c(s)}{ds^2} \right|^2 + \gamma(s)E_{ext}[c(s)], \quad (2.9)$$

em que $\alpha(s)$, $\beta(s)$ e $\gamma(s)$ são os pesos relativos de cada uma das componentes da energia total $E(s)$. A primeira derivada desta equação, representada pelo termo $\frac{dc(s)}{ds}$, é denominada de Força de Continuidade F_{cont} . A implementação desta força é realizada pela aproximação desenvolvida por Euler-Langrage. Assim, assumindo que F_{cont} é determinada por $\frac{dc(s)}{ds}$ e aplicando a aproximação de Euler-Langrage, tem-se (KASS; WITKIN; TERZOPOULOS, 1987)

$$\left| \frac{dc(s)}{ds} \right|^2 \approx |c(s) - c(s-1)|^2 = [x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2, \quad (2.10)$$

em que $x(s)$ e $y(s)$ são as coordenadas de cada ponto da curva c (NIXON; AGUADO, 2002). Sendo assim, pode-se descrever F_{cont} como a diferença espacial entre dois pontos consecutivos da curva c , associando-a à distância euclidiana entre dois pontos da curva

$$F_{cont} = \sqrt{[x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2}. \quad (2.11)$$

Neste contexto, a força associada à distância surge para manter o espaçamento entre os pontos da curva uniformes. A distância média DM , entre os pontos da curva, deve ser considerada para calcular esta força, visto que esta tende a espaçar igualmente os pontos. Deste modo, DM pode ser calculado por

$$DM = \frac{\sum_{i=0}^{N-1} \sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2}}{N}, \quad (2.12)$$

em que N é a quantidade máxima de pontos e i é o índice de ordenação do ponto na curva. Então, inserindo DM no cálculo de F_{cont} , tem-se

$$F_{cont} = \left| DM - \sqrt{[x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2} \right|. \quad (2.13)$$

Esta outra formulação tende a deixar a curva igualmente espaçada, aproximando os pontos afastados e distanciando os pontos próximos, tendendo a deixar os pontos o mais equidistante possível.

A segunda derivada da equação 2.9 para cálculo das energias internas, representada pelo termo $\frac{d^2c(s)}{ds^2}$, denominada de Força de Curvatura F_{curv} , pode ser aproximado analogamente através da aproximação de Euler-Langrage por (NIXON; AGUADO, 2002)

$$\left| \frac{d^2c(s)}{ds^2} \right|^2 \approx |c(s-1) - 2c(s) + c(s+1)|^2, \quad (2.14)$$

resultando em

$$F_{curv} = \sqrt{[x(s-1) - 2x(s) + x(s+1)]^2 + [y(s-1) - 2y(s) + y(s+1)]^2}. \quad (2.15)$$

Percebe-se que, para o cálculo desta energia, são usados os seus dois vizinhos imediatos, $c(s-1)$ e $c(s+1)$. Deste modo, é possível calcular uma estimativa de curvatura do ponto $c(s)$ e de sua vizinhança, no qual esta energia tende a minimizar a curvatura entre três pontos consecutivos $c(s-1)$, $c(s)$ e $c(s+1)$ (NIXON; AGUADO, 2002).

Por fim, a energia externa E_{ext} é determinada pelo gradiente da imagem, geralmente utilizando o operador Sobel, visto que este é simétrico e muito empregado na literatura, obtendo resultados satisfatórios em diversas aplicações (NIXON; AGUADO, 2002).

Limitações do MCA Tradicional

Os MCAs são projetados para serem modelos iterativos, em que a imagem se altera ao longo do tempo (KASS; WITKIN; TERZOPOULOS, 1987). Em aplicações não iterativas (imagens estáticas), a curva deve ser inicializada em local próximo à estrutura de interesse para garantir um bom desempenho (COHEN, 1991; SOUZA, 2003; LV; GAO; ZOU, 2008; FELIX et al., 2011). Isto acontece devido o gradiente ser nulo em regiões homogêneas e quando o contorno é inicializado longe das bordas, o contorno sofre influência apenas da energia interna, que tende a deixá-lo mais uniforme e a minimizar sua área, resultando em seu colapso em um único ponto após iterações sucessivas (CAVALCANTE et al., 2010b).

Além disso, a parametrização inadequada da energia interna do MCA Tradicional pode limitar sua flexibilidade, impedindo a representação de formas tubulares, de saliências e bifurcações (MCINERNEY; TERZOPOULOS, 1996; BOUHOURS, 2006; CAVALCANTE, 2010). Outro ponto a ser ressaltado é que a topologia da estrutura de interesse deve ser previamente conhecida, pois, este modelo, é incapaz de executar alterações em sua topologia sem processamento adicional (MCINERNEY; TERZOPOULOS, 1996).

Para superar tais limitações, algumas técnicas de PDI são adicionados ao MCA Tradicional, gerando outros métodos. Este trabalho se concentra nos MCAs Balão, *Gradient Vector Flow* (GVF), Crisp, *Vector Field Convolution* (VFC) e nos MCAs baseados na Transformada de Hilbert (THR e THRG).

2.2.2 MCA Balão

Para solucionar a restrição de inicialização da curva afastada da borda, Cohen (1991) define uma força interna denominada Força Balão. Nesta abordagem, a energia externa se mantém igual ao MCA Tradicional, enquanto que a energia interna é definida como sendo a soma da Força de Continuidade e da Força Balão. A energia interna é então definida

por

$$E_{int}[c(s)] = w_{cont}F_{cont}[c(s)] + w_{bal}F_{bal}[c(s)]. \quad (2.16)$$

em que $F_{cont}[c(s)]$ é a mesma Força de Continuidade utilizada no MCA Tradicional, $F_{bal}[c(s)]$ é a Força Balão e os parâmetros w_{cont} e w_{bal} são pesos. Estes pesos são utilizados para ajustar a importância de cada um dos seus respectivos termos no cálculo da energia interna E_{int} .

A Força Balão age expandindo o contorno e é de fundamental importância para a curva quando esta se encontra em regiões homogêneas da imagem, pois, a força externa é nula e as únicas forças que interferem na curva são as forças internas. Deste modo, a força balão deforma o contorno para que este se aproxime das bordas. Assim, por iterações sucessivas, as forças internas deslocam o contorno até que alguma força externa seja detectada. Então, com uma correta parametrização, este método atinge as bordas do objeto (CAVALCANTE, 2010; FELIX, 2011).

Dentre as formas de implementação da Força Balão F_{bal} , Mackiewicz (1995) sugere uma que se baseia no centróide da curva. Considerando este centróide como o ponto central da curva, calculado por meio da média das coordenadas x e y de todos os pontos, a Força Balão atua como uma força elástica, afastando a curva do centróide. Na Figura 2.4 é ilustrada a Força Balão atuando no ponto $c(s)$ repulsando-o em direção oposta ao centróide T .




Figura 2.4: exemplo da atuação da força balão repulsando um ponto $c(s)$ em direção contrária do baricentro $T(x_t, y_t)$.

Numericamente, a força balão é determinada por (MACKIEWICH, 1995)

$$F_{bal}[c(s)] = \sqrt{E_x^2 + E_y^2}, \quad (2.17)$$

em que as componentes E_x e E_y são definidas por

$$E_x = |x(s) - x_t|, \quad (2.18)$$

e

$$E_y = |y(s) - y_t|, \quad (2.19)$$

em que $x(s)$ e $y(s)$ são as coordenadas do ponto $c(s)$ onde F_{bal} está sendo calculada, x_t e y_t são as coordenada do centróide T . Neste caso, a força balão atua atraindo a curva. Caso deseje-se expandir a curva, deve-se inverter o sinal da força. Um mapa típico da força balão de um curva, para uma imagem, no sentido de expansão é ilustrado na Figura 2.5.




Figura 2.5: mapa típico da força balão agindo sobre a curva (em vermelho) no sentido de expansão (CAVALCANTE, 2010).

Para analisar os resultados do MCA Balão são utilizadas duas inicializações dentro do objeto de interesse: uma centralizada e outra descentralizada. Na inicialização centralizada, obtém-se resultados satisfatórios de segmentação, conforme pode ser visto na Figura 2.6, em que a inicialização é mostrada na Figura 2.6(a).




Figura 2.6: resultado do MCA Balão com a curva em vermelho, a) inicialização da curva; b) e c) são resultados das iterações intermediárias; e d) resultado final da segmentação pelo MCA Balão (REBOUÇAS FILHO, 2010).

Já quando a inicialização é descentralizada em imagens com concavidades, conforme é apresentado na Figura 2.7(a), obtém-se resultados inadequados de segmentação, demonstrado por um retângulo azul, na Figura 2.7(d). Sabendo que a curva se expande utilizando uma direção baseada entre o ponto e o centróide, é constatado que nas regiões com concavidade, os pontos que se direcionam para a região não segmentada, param na barreira gerada pela concavidade, logo a curva não atinge esta região.




Figura 2.7: aplicação do MCA Balão, desde a) inicialização da curva, b) e c) iterações intermediárias d) resultado final da segmentação (REBOUÇAS FILHO, 2010).

Analisando as Figuras 2.6 e 2.7, conclui-se que este método elimina diversas limitações do método Tradicional, porém dependendo da inicialização, o problema da segmentação das concavidades continua.

2.2.3 MCA *Gradient Vector Flow*

Os principais problemas no uso do gradiente da imagem como uma força externa no MCA são (XU; PRINCE, 1997):

- o fluxo de gradiente é presente somente nas bordas, sendo nulo em regiões uniformes, conforme Figura 2.8(b);
- em regiões côncavas, ao calcular o gradiente, as bordas da concavidade se anulam, propiciando uma ausência de fluxo de gradiente nestas regiões, impossibilitando a segmentação destas, conforme é mostrado na Figura 2.8(a).

De acordo com Xu e Prince (1997), o MCA *Gradient Vector Flow* (GVF), soluciona os problemas de inicialização e da segmentação de concavidades, baseando-se na expansão do fluxo gradiente de uma imagem. Neste método, é construído um campo de vetores que direciona o gradiente para as bordas da imagem, conduzindo a curva até às bordas

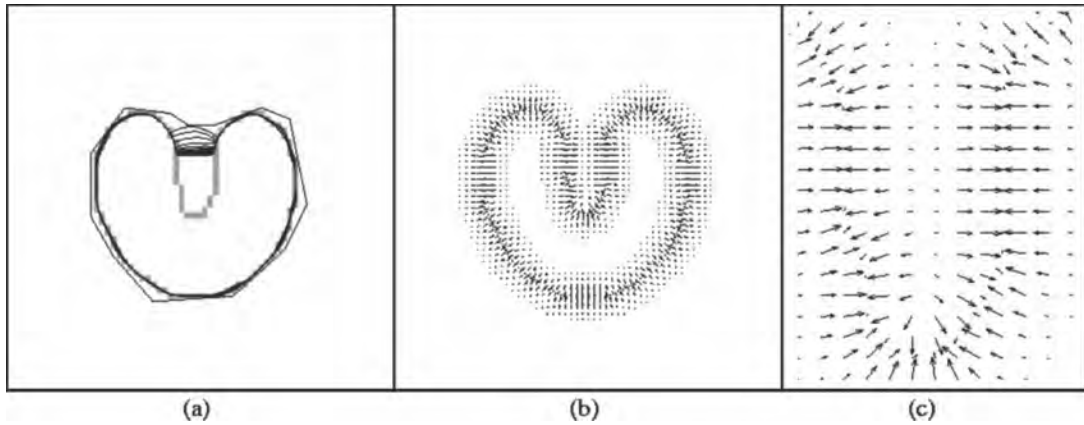


Figura 2.8: a) convergência do *snake*, b) campo de vetores gradiente, c) ampliação da concavidade do campo de gradiente (Xu and Price, 1997).

do objeto. Isto resolve os problemas de inicialização e de convergência inadequada nas concavidades.

Deste modo, o MCA GVF utiliza a energia interna do método tradicional combinado a uma nova energia externa. Esta energia externa $E_{ext_{GVF}}$ é definida por um fluxo de vetores gradiente w de acordo com (XU; PRINCE, 1997) como

$$E_{ext_{GVF}} = w(x, y), \quad (2.20)$$

sendo

$$w(x, y) = [u(x, y), v(x, y)], \quad (2.21)$$

em que $u(x, y)$ e $v(x, y)$ são funções que calculam o valor de derivadas parciais para compor $w(x, y)$. Esta energia externa é uma expansão do mapa das bordas da imagem determinada por um operador gradiente. Esta expansão é feita de forma iterativa, minimizando a energia funcional ε definida por (XU; PRINCE, 1997) como

$$\varepsilon = \int \int \left\{ \mu \left(\frac{\partial u^2}{\partial x} + \frac{\partial u^2}{\partial y} + \frac{\partial v^2}{\partial x} + \frac{\partial v^2}{\partial y} \right) + |\nabla f|^2 |w - \nabla f|^2 \right\} dx dy, \quad (2.22)$$

em que ∇f é a função de um operador gradiente, $\frac{\partial u}{\partial x}$, $\frac{\partial u}{\partial y}$ e $\frac{\partial v}{\partial x}$, $\frac{\partial v}{\partial y}$ são as derivadas parciais de u e v em relação a x e y , respectivamente. Neste caso, o parâmetro μ permite ajustar o equilíbrio entre os dois termos da integral.

É observado que, quando ∇f é pequeno na equação 2.22, *i.e.*, em regiões homogêneas, a energia obtida provém das derivadas parciais do fluxo de vetores, resultando em um campo com pequenas variações. Por outro lado, quando $|\nabla f|$ é grande comparado ao primeiro termo, a minimização resulta em $w = \nabla f$. Assim, obtém-se o efeito esperado

para o campo, que é de manter o valor do gradiente nas bordas, e de ser pouco variável em regiões homogêneas.

Outro aspecto importante é que o campo de fluxo gradiente em uma imagem depende diretamente da parametrização do fator μ da equação 2.22 e do número de iterações da aplicação desta mesma equação na imagem. Um valor do fator μ sugerido por Bouhours (BOUHOURS, 2006) é 0,1. Sendo assim, aplicando a equação 2.22 em uma imagem com 100, 200 e 400 iterações, conforme ilustrado na Figura 2.9, constata-se que a área ocupada pelo fluxo de vetores gradiente aumenta proporcionalmente ao número de iterações.




Figura 2.9: fluxo Gradiente obtido com a) 100 iterações, b) 200 iterações, e c) 400 iterações.

A MCA GVF é avaliado nesta tese inicializando-o fora do objeto com concavidades, dentro do objeto afastado das bordas e dentro do objeto descentralizado.

A primeira limitação do MCA Tradicional, corrigida pelo MCA GVF, é a inicialização fora do objeto com concavidades, conforme é mostrado na Figura 2.10(a). As Figuras 2.10(b) e 2.10(c) demonstram iterações sucessivas e o resultado da segmentação obtido pelo MCA GVF que é apresentado na Figura 2.10(d).




Figura 2.10: primeira limitação do MCA Tradicional superada pelo MCA GVF, a) inicialização da curva; b) e c) iterações intermediárias; d) resultado final da segmentação.

Analisando o resultado da segmentação mostrada na Figura 2.10, percebe-se que o MCA GVF é eficaz na segmentação de objetos com concavidades quando inicializado fora do objeto.

Aplicando o MCA GVF visando superar a segunda limitação encontrada pelo MCA Tradicional, obtida quando a inicialização da curva é realizada dentro do objeto e afastada de suas bordas, conforme está mostrado na Figura 2.11(a), obtêm-se as iterações intermediárias, apresentadas nas Figuras 2.11(b) e 2.11(c), e o resultado final demonstrado na Figura 2.11(d).




Figura 2.11: segunda limitação do MCA Tradicional, corrigida pelo MCA GVF, a) inicialização da curva; b) e c) iterações intermediárias; d) resultado final da segmentação pelo MCA GVF.

Com base no resultado da segmentação mostrada na Figura 2.11, percebe-se que este método é eficaz na segmentação de objetos com concavidades cuja inicialização ocorre dentro do objeto de forma centralizada.

Já considerando a limitação do método Balão para aplicar o MCA GVF, têm-se a inicialização da curva dentro do objeto, afastada das bordas e descentralizada, conforme é ilustrado na Figura 2.12(a). As iterações intermediárias obtidas a partir do MCA GVF são ilustrados nas Figuras 2.12(b) e 2.12(c), e o resultado final da segmentação é apresentado na Figura 2.12(d).

Analisando os resultados obtidos na Figura 2.12(d), observa-se que a propagação do gradiente da imagem não garante que os pontos da curva detectem o objeto de interesse completo, mas apenas garante que a curva se desloca para a borda mais próxima de cada ponto da curva.

Deste modo, conclui-se que o MCA GVF resolve os problemas de inicialização afastada das bordas e da segmentação de regiões côncavas, mas somente quando inicializado fora do objeto. Já quando inicializado dentro do objeto, o resultado depende diretamente da inicialização da curva, principalmente em regiões côncavas. Além disto, constata-se




Figura 2.12: limitação dos MCAs Tradicional, Balão e GVF, a) inicialização da curva; b) e c) iterações intermediárias; e d) resultado final da segmentação pelo método GVF.

também que outra limitação do GVF ocorre em aplicações em tempo real, devido ao fato deste método ser aproximadamente 30 vezes mais lento, em relação aos métodos Tradicional e Balão (WILLIAMS; SHAM, 1992; MACKIEWICH, 1995; BOUHOURS, 2006). Isto ocorre por causa das iterações sucessivas realizadas para gerar o fluxo de vetores gradiente, que são custosas computacionalmente.

2.2.4 MCA *Vector Field Convolution* (VFC)

De forma análoga aos outros MCAs descritos, Li e Acton (2007) propõem o MCA VFC utilizando as energias internas do MCA Tradicional, combinando uma nova energia externa. Esta nova energia externa $\mathbf{E}_{vfc}(x, y) = [u_{vfc}(x, y), v_{vfc}(x, y)]$ é obtida fazendo a convolução (*) do núcleo do campo de vetores $\mathbf{k}_{vfc}(x, y) = [u_k(x, y), v_k(x, y)]$ com o mapa de bordas $f_{vfc}(x, y)$ gerado da imagem $I(x, y)$, sendo dada por (LI; ACTON, 2006, 2007)

$$\begin{aligned} E_{vfc}(x, y) &= f_{vfc}(x, y) * \mathbf{k}_{vfc}(x, y) \\ &= [f_{vfc}(x, y) * u_k(x, y), f_{vfc}(x, y) * v_k(x, y)]. \end{aligned} \quad (2.23)$$

O mapa de borda $f_{vfc}(x, y) = -\nabla E_{ext}^i$ com $i = 1, 2, 3$ ou 4 e o núcleo do campo de vetores $\mathbf{k}_{vfc}(x, y) = [u_k(x, y), v_k(x, y)]$, em que todos os vetores apontam para a origem do núcleo, é dado por (LI; ACTON, 2007)

$$\mathbf{k}_{vfc}(x, y) = m_k(x, y) \mathbf{n}_k(x, y), \quad (2.24)$$

nos quais $m_k(x, y)$ é a magnitude do vetor na posição (x, y) e $\mathbf{n}_k(x, y)$ é um vetor unitário para a origem do núcleo. Este vetor do núcleo é dado por

$$\mathbf{n}_k(x, y) = [-x/r, -y/r], \quad (2.25)$$

em que $r = \sqrt{x^2 + y^2}$ é a distância da origem (raio do núcleo), exceto quando $\mathbf{n}_k(0, 0) = [0, 0]$ na origem (LI; ACTON, 2006, 2007).

O MCA VFC tem forte dependência da magnitude $m_k(x, y)$. Por isto, este tem duas funções de magnitude, definidas por (LI; ACTON, 2007)

$$m_{k1}(x, y) = (r + \varepsilon)^{-\gamma}, \quad (2.26a)$$

$$m_{k2}(x, y) = \exp(-r^2/\zeta^2), \quad (2.26b)$$

em que γ e ζ são parâmetros positivos para controlar o decrescimento e ε é uma constante positiva pequena para evitar divisões por zero. As funções de magnitude $m_{k1}(x, y)$ e $m_{k2}(x, y)$ são inspiradas na lei de gravitação universal de Newton e em uma função com forma de Gaussiana, respectivamente (LI; ACTON, 2007).

O MCA VFC tem como principal vantagem a redução do custo computacional, se comparado com o MCA GVF, bem como apresenta uma ampla faixa de captura, redução de sensibilidade na posição de inicialização do contorno e correta deformação na presença de ruído impulsivo e gaussiano (LI; ACTON, 2007). Entretanto, o MCA VFC possui uma limitação que ocorre quando a imagem com ruído apresenta dois objetos que estão próximos. Um com bordas de baixa intensidade e o outro com bordas de alta intensidade. Isto faz com que a curva do referido MCA ultrapasse o objeto de interesse, que é o de bordas com baixa intensidade, e localize o objeto errado, com bordas de alta intensidade (LI; ACTON, 2006, 2007).

2.2.5 MCAs baseados na Transformada de Hilbert Radial (THR)

As informações de bordas, em geral, são muito utilizadas nos MCAs como a força externa obtida a partir de uma imagem, representada usualmente pela magnitude do operador gradiente desta imagem (PARK; SCHOEPFLIN; KIM, 2001). Entretanto, a detecção de bordas por meio de técnicas tradicionais como os operadores gradiente, Roberts, Prewitt, Sobel e LoG, bem como o gradiente morfológico clássico, apresentam sensibilidade a imagens ruidosas, comprometendo a detecção de bordas em tais imagens (SOILLE, 2004; SONKA; HLAVAC; BOYLE, 2008; GONZALEZ; WOODS, 2010).

Por outro lado, a Transformada de Hilbert (TH) 2D supera esta limitação, pois apresenta a característica de espalhamento gradual da borda, semelhante a um processo de difusão da borda. Este fato é importante, pois permite que a curva do MCA seja inicializada sem tocar a borda do objeto desejado.

A TH tem sido pouco explorada na área de Processamento Digital de Imagens sendo aplicada de forma mais efetiva somente nas últimas duas décadas, apresentando evoluções significativas na detecção de bordas e filtragem de imagens (KOHLMANN, 1996; DAVIS;

LINYING; SHARP, 1999; PEI; YEH, 2000; PEI; DING, 2003; PEI et al., 2008; GUANLEI; XIAO-TONG; XIAOGANG, 2009; FELIX, 2011; ALEXANDRIA, 2011).

Utilizando a TH, Davis et al. (2000) propõem a Transformada de Hilbert Radial (THR), sendo esta definida por

$$THR(x, y) = TFI_{2D}\{exp(j \cdot n \cdot \theta) \cdot TF_{2D}[g(x, y)]\}, \quad (2.27)$$

em que $\theta = \cos^{-1}(\omega/r) = \sin^{-1}(s/r)$, $r = (\omega^2 + s^2)^{1/2}$, ω e s são variáveis no domínio da frequência, $j \in \mathbb{C}$ e $n \in \mathbb{Z}$. TF e TFI são as Transformada de Fourier e a Transformadas de Fourier Inversa, respectivamente.

Aplicando este princípio, FELIX (2011) propõe 6 MCAs utilizando energia externas baseadas na THR. Dentre estes destacam-se os MCAs THR bidirecional, o multidirecional e o módulo multidirecional. Todos estes MCAs utilizam a energia interna do MCA Tradicional. Então, o primeiro MCA, denominado de MCA THR bidirecional (MCA THRbi) é determinado por (FELIX, 2011)

$$v_t(s, t) = \alpha[v''(s, t)] - \beta[v''''(s, t)] + E_{THR}[v(s, t)], \quad (2.28)$$

em que s é substituído por (x, y) . A energia externa $E_{THR}(x, y) = THR(x, y)$ é obtida pela aplicação direta da equação 2.27 na imagem $I(x, y)$, gerando a energia externa THR bidirecional. Este MCA THR é chamado de bidirecional pelo fato de seu cálculo utilizar duas direções: $\theta = 0^\circ$ e $\theta = 90^\circ$.

O segundo MCA THR, denominado de multidirecional (MCA THRmult), realiza o cálculo da energia externa em quatro direções para θ , assumindo os valores iguais a 0° , 60° , 90° e 120° . A utilização destas quatro direções permite a captura de regiões côncavas.

O terceiro contorno ativo é baseado no MCA THR multidirecional. Este é chamado de MCA THR módulo multidirecional (MCA THRmod), cuja energia externa é dada por (FELIX, 2011)

$$E_{THR}(x, y) = [|THR(x, y)|]^2 * G_\sigma(x, y). \quad (2.29)$$

A $E_{THR}(x, y)$ calculada desta forma possibilita que a energia externa amplie a informação de bordas, aumentando o espaço de captura deste MCA. Porém, a intensificação da energia externa causa o aparecimento de vetores ruidosos que podem conduzir a uma convergência errada de sua curva. Isto é minimizado aplicando o filtro $G_\sigma(x, y)$ para reduzir a influência de tais vetores (FELIX, 2011).

2.2.6 MCA Crisp

Os MCAs tradicional, balão e GVF são ineficientes na segmentação pulmonar, pois utilizam no cálculo de suas energias externas algum tipo de gradiente tradicional. Este fato ocorre porque as energias externas destes métodos detectam todas as bordas presentes na imagem de TC dos pulmões, sem distinguir estruturas internas (vasos e vias aéreas) das paredes pulmonares, gerando falsas bordas que conduzem a erros de localização dos pulmões (REBOUÇAS FILHO, 2010).

Analogamente, esse fato pode ser estendido para os MCAs GVF e VFC, que também utilizam a expansão do gradiente da imagem, seja por um processo de difusão para o GVF ou de convolução com um núcleo de vetores como no caso do VFC.

A segmentação dos pulmões em imagens de TC possui outras restrições, tais como: problemas com a inicialização da curva devido a forma dos pulmões e os diferentes níveis de cortes tomográficos, dificultando a localização da curva inicial próxima à borda. Existe também, a presença de ar dentro e fora dos pulmões, conduzindo a uma identificação inadequada das densidades radiológicas das regiões internas dos pulmões (REBOUÇAS FILHO, 2010).

Além disso, quando a curva não é inicializada próximo às bordas dos pulmões, os vasos fazem o papel de ruído, dificultando o deslocamento da curva até às bordas pulmonares. Porém, realizar uma inicialização manual nas imagens de TC dos pulmões pode ser um processo lento, devido ao grande número de cortes, e portanto de imagens geradas, para um único exame de TC.

Por exemplo, numa Tomografia Computadorizada de Alta Resolução (TCAR) obtida com tomógrafo de múltiplos detectores, podem ser geradas entre 300 a 600 imagens, com espessuras de cortes de 1,0 mm e 0,5 mm, respectivamente, para um pulmão de comprimento médio estimado em 30 cm (KALENDER, 2006).

As imagens podem ser obtidas por uma TCAR nos seguintes níveis de cortes: nível de ápice, nível de hilo e nível de base¹. Em cada um destes níveis os pulmões apresentam diferentes formatos, conforme é apresentado na Figura 2.13

O MCA Crisp proposto por Rebouças Filho (2010) visa superar as limitações observadas na aplicação dos MCAs tradicional, balão e GVF na segmentação dos pulmões em imagens de TC. O MCA Crisp é baseado nas faixas de densidade pulmonar, que são: áreas

¹As imagens de TC dos pulmões são adquiridas da parte superior para a inferior do tórax de pacientes. Por isso, o nível de ápice corresponde à parte superior dos pulmões, o hilo e a base representam as partes médio e inferior dos pulmões, respectivamente.




Figura 2.13: imagens dos pulmões em TCAR de um voluntário sadio, (a) corte em nível de ápice; (b) corte em nível de hilo; e (c) corte em nível de base.

hiperaeradas, -1000 a -950 UH, normalmente aeradas, -950 a -500 UH, pouco aeradas, -500 a -100 UH, não aeradas, -100 a 100 UH, e região óssea, 600 a 2000 UH (GEVENOIS; YERNAULT, 1995; VIEIRA et al., 1998; FELIX, 2007).

O MCA Crisp incorpora a sua energia externa E_{crisp} ao MCA balão desenvolvido por Mackiewich (1995). A E_{crisp} é estabelecida por uma função para calcular os percentuais de cada umas das regiões presentes na imagem. A definição destas regiões é realizada de forma análoga à técnica de multilimiarização. Com base nas faixas de densidade hiperaeradas, normalmente aeradas, pouco aeradas, não aeradas, óssea e áreas não classificadas, são definidas 6 classes u_i , em que i varia de 0 a 5 (REBOUÇAS FILHO, 2010).

A partir da definição destas classes, uma matriz de densidades pulmonares $D(x, y)$ é considerada, em que (x, y) são as coordenadas nas quais a vizinhança 9×9 é analisada. Assim, a função que determina a quantidade de pontos com densidades presente em cada classe u_i é determinada por (REBOUÇAS FILHO, 2010)

$$f(x, y, u_i) = \sum_{l=-4}^4 \sum_{m=-4}^4 R(x-l, y-m), \quad (2.30)$$

no qual

$$R(x, y) = \begin{cases} 1, & \lim_{inf}(u_i) \leq D(x, y) < \lim_{sup}(u_i), \\ 0, & \text{caso contrário,} \end{cases} \quad (2.31)$$

em que $\lim_{inf}(u_i)$ e $\lim_{sup}(u_i)$ são os limites inferior e superior da faixa de densidade, em UH, para a classe u_i . A partir destes dados é possível calcular o percentual P_i de cada classe i por (REBOUÇAS FILHO, 2010)

$$P_i = \frac{f(x, y, u_i)}{\sum_{j=0}^4 f(x, y, u_j)}. \quad (2.32)$$

A classe 5 é desconsiderada, pois esta representa áreas não classificadas. A E_{crisp} é dada por (REBOUÇAS FILHO, 2010)

$$E_{crisp}(x, y) = \begin{cases} 0, & \text{para } P_3 < 0,2 \text{ e } P_4 < 0,15, \\ S(x, y), & \text{caso contrário,} \end{cases} \quad (2.33)$$

em que $S(x, y)$ é o operador Sobel e os limiares 0,2 e 0,15 são determinados de forma empírica. Um resultado do cálculo com a energia Crisp é ilustrado na Figura 2.14.




Figura 2.14: imagens de TCAR dos pulmões, (a) original, (b) gradiente de Sobel e (c) energia Crisp (REBOUÇAS FILHO, 2010).

O MCA Crisp utiliza uma inicialização automática, denominada nesta tese de $Crisp_{inicial}$, baseada nas faixas de densidade hiperaeradas e normalmente aeradas. Para isto, a imagem de TC dos pulmões é dividida em quatro regiões: esquerda, direita, superior e inferior. As regiões superior e inferior são desconsideradas, pois podem confundir o método de inicialização, devido à semelhança das densidades radiológicas destas regiões com os pulmões. Isto ocorre porque, em tais regiões, há presença de ar, como também nos pulmões.

As regiões esquerda e direita estão compreendidas no intervalo $[LIX, LSX]$ no eixo das abscissas e $[LIY, LSY]$ no eixo das ordenadas, em que LIX e LIY são os limites inferiores nos eixos x e y , respectivamente, e LSX e LSY são os limites superiores nos eixos x e y , respectivamente. Após testes exaustivos, os valores são obtidos de forma empírica sendo a região esquerda $[0, 256]$ e a direita $[256, 512]$ no eixo das abscissas e ambas possuem $[180, 360]$ no eixo das ordenadas. Deste modo, a localização automática do MCA Crisp é dada por

$$Crisp_{inicial}(x) = \sum_{x=LIX}^{LSX} p(y) \therefore p(y) = \begin{cases} 1, & -1000 \text{ } UH < I(x, y) < -500 \text{ } UH, \\ 0, & \text{caso contrário,} \end{cases} \quad (2.34)$$

e

$$Crisp_{inicial}(y) = \sum_{x=LIX}^{LSY} p(x) \cdot p(x) = \begin{cases} 1, & -1000 \text{ UH} < I(x, y) < -500 \text{ UH}, \\ 0, & \text{caso contrário,} \end{cases} \quad (2.35)$$

em que os valores de entrada y da função $Crisp_{inicial}(y)$ está no intervalo $[LIY, LSY]$ e os de x da função $Crisp_{inicial}(x)$ está no intervalo $[LIX, LSX]$ e $I(x, y)$ é uma imagem de TC dos pulmões, com dimensões 512×512 (REBOUÇAS FILHO, 2010). As coordenadas de inicialização x e y são as saídas que obtiverem maior valor nas equações 2.34 e 2.35, respectivamente, sendo um ponto de inicialização (x, y) para cada região.

A região analisada considerando esses parâmetros está ilustrada Figura 2.15, em vermelho, assim como os pontos de inicialização, encontrados a partir das equações 2.34 e 2.35, em amarelo. Estes pontos são utilizados como baricentro de um polígono regular, cuja a distância de cada ponto para o baricentro é configurada no algoritmo de inicialização, juntamente com a quantidade de vértices do polígono. Nesta Figura é apresentada uma curva com uma distância de 10 *pixels* entre cada ponto e o baricentro, e um total de 20 vértices, conforme é apresentado, em azul, na Figura 2.15.




Figura 2.15: demonstração das regiões, em vermelho, utilizadas para encontrar os pontos para as inicializações, em amarelo, dos contornos dos pulmões esquerdo e direito, em azul (REBOUÇAS FILHO, 2010).

O MCA Crisp possui uma restrição, que é a sua aplicação somente em imagens de TC dos pulmões em pacientes com Doença Pulmonar Obstrutiva Crônica (DPOC) e voluntários sadios. Além disso, o MCA Crisp apresenta segmentação imprecisa em regiões

côncavas quando a sua curva é inicializada internamente de forma descentralizada, devido este ser baseado no MCA balão (REBOUÇAS FILHO, 2010).

2.3 Medidas de avaliação da segmentação

A segmentação é tida como o principal processo dentro de um sistema de visão computacional, pois os resultados posteriores dependem diretamente do eventual sucesso ou fracasso desta etapa. Diante disto, inúmeras técnicas de segmentação são propostas para diversas aplicações. Entretanto estas técnicas devem ser avaliadas e/ou validadas por meio de técnicas de avaliação de forma distinta para cada aplicação.

Os métodos de avaliação de segmentação têm sido propostos ao longo dos anos, visando avaliar algoritmos de segmentação aplicados em diversos tipos de imagens, tais como: imagens de radares de abertura sintética SAR (DELVES et al., 1992; ZHANG, 1996; CAVES; QUEGAN; WHITE, 1998; DLUGOSZ et al., 2009; CARVALHO et al., 2010), imagens de angiografia do ventrículo esquerdo (BARRETT; CLAYTON; WARNER, 1980; POPE et al., 1985; LILLY; JENKINS; BOURDILLON, 1989), imagens de ressonância magnética cardíaca (GOSHTASBY; TURNER, 1995; THEDENS; SKORTON; FLEAGLE, 1995), imagens de ecocardiograma do ventrículo esquerdo (ADAM; HAREUVENI; SIDEMAN, 1987; TARATORIN; SIDEMAN, 1993; COPPINI; POLI; VALLI, 1995) e imagens de tomografia computadorizada dos pulmões (SANTOS et al., 2004; EZHIL et al., 2008).

A avaliação qualitativa é realizada por meio de uma inspeção visual por um especialista, o qual verifica informações relacionadas com a presença, ausência ou acréscimo de regiões, bordas ou pontos, estruturas diversas que estão em desacordo com a segmentação desejada. Esta avaliação está sujeita às limitações inerentes à subjetividade e à variabilidade intra e interobservadores (COXSON et al., 1999; FELIX et al., 2009; FELIX, 2011). Já a avaliação quantitativa utiliza informações obtidas diretamente de regiões ou imagens segmentadas, tais como: médias das intensidades da região, área, perímetro, características de complexidade da região, dentre outras.

Deste modo, esta tese adota avaliações com métricas qualitativas, quantitativas e medidas de subjetividade intra e interobservador.

2.3.1 Medidas de avaliação quantitativa de ajuste

Os métodos de avaliação quantitativa de segmentação adotados nesta tese utilizam uma região como referência denominada padrão-ouro. Deste modo, esta avaliação é realizada por meio da comparação entre a imagem de referência e a imagem segmentada. Para uma comparação com imagem sintética, esta é tida como imagem de referência. Na comparação com uma imagem digital real, a imagem de referência é adquirida por uma segmentação manual, obtida por especialistas (ZHANG, 1996; LUCCA, 1998). Dentre as maneiras de quantificar a região segmentada com o padrão-ouro, destacam-se as medidas de ajuste.

As medidas de ajuste *Fit* são baseadas nas simetrias entre as regiões da imagem de referência $A_k = \{k_1, k_2, \dots, k_n\}$ e regiões da imagem segmentada $A_l = \{l_1, l_2, \dots, l_m\}$, ou seja, o quanto uma região k é simétrica ou ajustada à outra l quando estão sobrepostas, em que k e l possuem dimensão n e m , respectivamente. As medidas de ajuste definidas por Delves et al. (1992) são ajustes de: posição, intensidade, tamanho e forma.

Ajuste de posição - o ajuste de posição Fit_{xy} mede a precisão do ajuste entre A_k e A_l , baseando-se nas diferenças das médias das abscissas xd e das ordenadas yd entre os centros geométricos de cada região, definido por (DELVES et al., 1992)

$$Fit_{xy} = 1 - \frac{xd + yd}{2}, \quad (2.36)$$

em que xd e yd são definidas, respectivamente por

$$xd = \frac{|\bar{x}_{A_k} - \bar{x}_{A_l}|}{M} \quad e \quad yd = \frac{|\bar{y}_{A_k} - \bar{y}_{A_l}|}{N}, \quad (2.37)$$

em que $\bar{x}_{A_k}, \bar{x}_{A_l}, \bar{y}_{A_k}$ e \bar{y}_{A_l} indicam as médias das abscissas x e das ordenadas y das regiões A_k e A_l , respectivamente; M e N representam as dimensões da imagem.

Ajuste de intensidade - o ajuste de intensidade Fit_i é definido como a razão da variação da média de intensidade dos níveis de cinza das regiões k_n e l_m , dado por (DELVES et al., 1992)

$$Fit_i = 1 - \frac{|\bar{I}_{A_k} - \bar{I}_{A_l}|}{\bar{I}_{A_k} + \bar{I}_{A_l}}, \quad (2.38)$$

em que \bar{I}_{A_k} e \bar{I}_{A_l} são as médias dos valores de intensidade das regiões A_k e A_l , respectivamente. O valor obtido com Fit_i varia entre $[0, 1]$, quando este valor tende a 1 indica que houve uma pequena variação de intensidade e tendendo à zero, em caso de ocorrer uma grande variação.

Ajuste de tamanho - o ajuste de tamanho Fit_{mn} é definido como a razão da diferença

entre as áreas de A_k e A_l e a soma das mesmas, dado por (DELVES et al., 1992)

$$Fit_{mn} = 1 - \frac{|A_k - A_l|}{A_k + A_l}. \quad (2.39)$$

O valor do Fit_{mn} também varia entre $[0, 1]$. Se este valor tende a 1, indica que as áreas são semelhantes e quando tende à zero, há um aumento de diferença entre as áreas.

Ajuste de forma - o ajuste de forma Fit_f é definido como a razão da intersecção e união das áreas de A_k e A_l , dada por (DELVES et al., 1992)

$$Fit_f = \frac{(A_k \cap A_l)}{(A_k \cup A_l)}. \quad (2.40)$$

Da mesma forma que as demais medidas de ajuste, esta medida varia no intervalo $[0, 1]$. Quando o valor de Fit_f tende para zero, indica a ausência ou discordância na sobreposição entre as áreas de A_k e A_l . Caso contrário, quanto este valor tende para 1, a sobreposição entre as áreas de A_k e A_l é concordante.

2.3.2 Medidas de avaliação qualitativa

A avaliação adotada nesta tese baseia-se na avaliação qualitativa de segmentação descrita por Gonzales e Woods (GONZALEZ; WOODS, 2010). Deste modo, no critério de avaliação qualitativa adotado são consideradas 5 notas: ótimo, aceitável, razoável, ruim e péssimo. Esta classificação e sua respectiva nota está descrita na Tabela 2.1.

Tabela 2.1: *critério de avaliação qualitativa de segmentação de imagens.*

Nota	Classificação	Descrição
5	Ótimo	altíssima qualidade, tão bom quanto se poderia desejar
4	Aceitável	qualidade boa, com a presença de pequenos erros
3	Razoável	média qualidade, com a presença de erros grosseiros
2	Ruim	possui apenas uma pequena parcela do objeto de interesse
1	Péssimo	não encontra parte nenhuma do objeto de interesse

Esta avaliação, apresentada na Tabela 2.1, é utilizada também por REBOUÇAS FILHO (2010) na avaliação da segmentação dos pulmões em imagens de TC. Além disto, Cavalcante (2010) também realiza a avaliação da segmentação das vias áreas por este método.

Cada uma das classificações apresentadas na Tabela 2.1 é exemplificada na Figura 2.16 de acordo com REBOUÇAS FILHO (2010). Deste modo, na Figura 2.16(a) é mostrada uma imagem de TC dos pulmões obtida na posição supina no nível de ápice, na Figura 2.16(b) está ilustrada uma segmentação ótima, em que o pulmão à esquerda é segmentado

sem falhas, seja por excesso ou por falta de regiões pulmonares. Na Figuras 2.16(c) é ilustrada uma segmentação aceitável, com pequenas falhas, em que parte do pulmão está fora da segmentação. Já na Figura 2.16(d) se encontra uma segmentação razoável, com erros grosseiros, em que uma parte considerável do pulmão está fora da região segmentada. Na Figura 2.16(e) é mostrada uma segmentação ruim, identificando apenas uma parte das paredes pulmonares, faltando grande parte do pulmão. Na Figura 2.16(f) é visualizada uma segmentação classificada como péssima, totalmente errada, sem identificar o pulmão corretamente. Vale ressaltar que o Apêndice B apresenta mais detalhes das estruturas e posições de visualização de uma imagem de TC do tórax.




Figura 2.16: exemplo de avaliação qualitativa de segmentação dos pulmões em imagens de TC: a) imagem original, b) segmentação ótima, c) segmentação aceitável, d) segmentação razoável, e) segmentação ruim e f) segmentação péssima (REBOUÇAS FILHO, 2010).

2.3.3 Medidas de avaliação inter e intra observador

O índice de concordância intra e inter-observadores constitui uma medida utilizada para analisar o acordo entre dois intervalos de observação (intraobservadores) e entre avaliadores (entre-observadores) na atribuição de categorias para uma determinada.

A medida estatística de concordância utilizada nesta tese é o índice Kappa de Cohen. Este índice é uma medida de concordância intra e entre-observador e mede o grau de concordância entre dois observadores e varia de 0 até 1, em que 1 significa a maior concordância e 0 sugere que a concordância é atribuída ao acaso (CONGALTON; GREEN, 1999). O índice Kappa é calculado a partir de uma matriz de confusão, sendo um exemplo de representação desta apresentado na Tabela 2.2.

Tabela 2.2: *representação matemática de uma matriz de confusão (Adaptada de Figueiredo e Vieira (2007)).*

Classificação	1	2	c	Total nas linhas n_{i+}
1	x_{11}	x_{12}	x_{1c}	x_{1+}
2	x_{21}	x_{22}	x_{2c}	x_{2+}
c	x_{c1}	x_{c2}	x_{cc}	x_{c+}
Total nas colunas n_{+i}	x_{+1}	x_{+2}	x_{+c}	n

A análise de Kappa é uma técnica multivariada discreta usada na avaliação da precisão temática e utiliza todos os elementos da matriz de confusão. O coeficiente Kappa (K) é uma medida da concordância real, indicado pelos elementos diagonais da matriz de confusão, menos a concordância por chance, indicado pelo produto total da linha e coluna, que não inclui entradas não reconhecidas, ou seja, é uma medida do quanto a classificação está de acordo com os dados de referência. O índice Kappa K pode ser calculado através da equação (FIGUEIREDO; VIEIRA, 2007)

$$K = \frac{n \sum_{i=1}^c x_{ij} - \sum_{i=1}^c x_{i+} x_{+i}}{n^2 - \sum_{i=1}^c x_{i+} x_{+i}} \quad (2.41)$$

em que K é uma estimativa do índice Kappa, x_{ij} é o valor na linha i e coluna j , x_{i+} é a soma da linha i e x_{+i} é a soma da coluna i da matriz de confusão, n é o número total de amostras e c o número total de classes. Embora o coeficiente Kappa K seja muito utilizado na avaliação da exatidão de mapeamento, não existe uma fundamentação teórica para recomendar quais os níveis mínimos aceitáveis deste coeficiente numa classificação (FIGUEIREDO; VIEIRA, 2007). Entretanto, a Tabela 2.3 apresenta níveis de desempenho da classificação para o valor do índice Kappa obtido, normalmente aceitos pela comunidade científica.

Tabela 2.3: *índice Kappa e o correspondente desempenho da classificação (CONGALTON; GREEN, 1999).*

Índice Kappa (K)	Desempenho
0	Pobre
0 a 0,20	Ligeira
0,21 a 0,40	Considerável
0,41 a 0,60	Moderada
0,61 a 0,80	Substancial
0,81 a 1	Excelente

Atualmente, o índice Kappa é amplamente utilizado para cálculo do grau de concordância entre observadores em diversas aplicações, podendo ser citadas classificação e análise de imagens SAR (ZHANG et al., 2010), classificação de moléculas subcelulares (CAN; BELLO; GERDES, 2010), classificação de lesão de mama (DUNDAR et al., 2011) e avaliação da qualidade multimídia (ENGELKE; PITREY; CALLET, 2011).

2.4 Rede Neural Artificial

A Rede Neural Artificial (RNA) surgiu com o objetivo de modelar o sistema nervoso biológico para obter soluções de problemas computacionais complexos. A técnica da computação neural corresponde a estabelecer procedimentos similares aos usados na solução de problemas pelo cérebro humano e aplicá-los em sistemas computacionais. Assim como no cérebro humano, uma das características principais das Redes Neurais consiste na capacidade de aprender padrões através de exemplos e reconhecê-los após este aprendizado (HAYKIN, 1999).

2.4.1 Perceptron Simples

Das diversas topologias existentes para as RNAs, uma bastante popular é a rede Perceptron, proposta por ROSEMBLATT (1958). A rede Perceptron possui múltiplas entradas totalmente conectadas a uma única camada, cujos neurônios determinam a saída da rede. Esta configuração recebe o nome de Perceptron Simples (PS).

O Perceptron ou neurônio artificial é um modelo de neurônio biológico e a forma mais básica de uma rede neural. Este neurônio artificial consiste de um conjunto de n entradas (x_i) associadas a n pesos (w_i), uma função de ativação f , e uma saída y conforme ilustrado na Figura 2.17.




Figura 2.17: representação de um perceptron.

A saída ou resposta de um neurônio depende das entradas e de seus pesos associados, sendo calculada por (HAYKIN, 1999)

$$y = f \left(\sum_{i=0}^n x_i w_i \right). \quad (2.42)$$

Para a função de ativação f é possível adotar diversas funções. Dentre as mais comuns estão a função degrau, função pseudolinear, sigmóide e a função gaussiana.

A rede PS possui duas fases de operações distintas, a fase de treinamento e a de execução. Na fase de treinamento, os pesos w_i são adequadamente calculados para que a rede possa aprender o padrão e apresentar saídas corretas. Em redes PS, o treinamento é supervisionado, ou seja, é apresentado um conjunto de dados com resposta do sistema conhecida e em seguida a resposta da rede é comparada com a saída desejada. Caso algum erro seja detectado, os pesos w_i são atualizados para que a saída seja a esperada. Geralmente, esta fase se encerra quando o erro obtido é menor do que um valor de tolerância pré-estabelecido. Dentre os algoritmos aplicados para esse tipo de treinamento, o mais comum é a regra delta (ALEXANDRIA, 2005; CAVALCANTE et al., 2010a).

Já na fase de execução é apresentado um conjunto de dados cuja resposta é desconhecida e a rede previamente treinada deve reconhecer o padrão apresentado. A rede PS é aplicável somente a problemas de classificação considerados linearmente separáveis. O exemplo clássico desta limitação é a função Ou-Exclusivo que não pode ser implementada por este tipo de rede (HAYKIN, 1999). Para estes e outros casos mais complexos, outras topologias de RNA são mais adequadas, dentre estas destaca-se a rede MLP.

2.4.2 Rede Neural Perceptron Multicamada - MLP

A rede MLP surgiu com o intuito de superar algumas limitações do PS, resolvendo problemas cujos padrões não são separáveis linearmente. Além disso, revela-se uma ferramenta eficaz de mapeamentos tipo entrada-saída para aproximação de funções e classificação de padrões. Este tipo de rede é especialmente indicado para modelagem caixa-preta de mapeamentos não-lineares a partir de treinamento supervisionado, tornando-se atrativa para aplicações que possuem modelos analíticos ou dedutivos complexos (ALEXANDRIA, 2005; CAVALCANTE et al., 2010a).

Basicamente uma rede MLP é constituída por um conjunto de unidades de entrada (que recebem os sinais), uma ou mais camadas ocultas (ou escondidas) compostas por neurônios não-lineares, e uma camada de saída composta por um ou mais neurônios que podem ser lineares ou não-lineares. Os neurônios das camadas intermediárias são chamados de neurônios ocultos ou escondidos pelo fato de não se conectarem diretamente à saída da rede (HAYKIN, 1999).




Figura 2.18: representação de uma rede MLP com uma camada oculta.

As camadas ocultas são aquelas que não fazem parte da entrada e nem da saída, mas que tornam a rede capaz de extrair características mais representativas do sistema, possibilitando a resolução de problemas não separáveis linearmente. Observando a Figura 2.18, vale ressaltar que a rede MLP apresenta interligações entre os neurônios das diferentes camadas e em cada ligação é associado um valor numérico chamado de peso sináptico (HAYKIN, 1999).

O vetor de pesos associado ao j -ésimo neurônio da camada intermediária e da camada de saída são dados respectivamente por (HAYKIN, 1999)

$$w_j = \begin{pmatrix} w_{0j} \\ \vdots \\ w_{nj} \end{pmatrix} \text{ e } m_k = \begin{pmatrix} m_{0k} \\ \vdots \\ m_{qk} \end{pmatrix}. \quad (2.43)$$

Assim, da mesma forma que como as redes perceptron, a MLP também possui as fases de treinamento e execução. Apesar da fase de treinamento ser também supervisionada, esta fase é bastante diferente do treinamento de uma rede perceptron simples. Pelo fato da MLP possuir camadas intermediárias, na fase de treinamento não é possível utilizar a regra delta, pois, esta regra não permite a correção do erro nas camadas intermediárias e na entrada. As regras de aprendizado utilizadas são mais complexas, sendo que o algoritmo do gradiente descendente de retropropagação do erro (*backpropagation*) se apresenta como uma das alternativas de maior simplicidade, tornando-se o mais popular (ALEXANDRIA, 2005; MEDEIROS, 2008; SANTOS, 2010).

Inicialmente o treinamento da MLP, realizado através do algoritmo de retropropagação do erro, envolve o cálculo das saídas de todos os neurônios das camadas escondidas e de todos os neurônios da camada de saída. Assim, ao se apresentar um vetor de entradas \mathbf{x} à rede MLP, calcula-se as ativações dos neurônios u_j da camada oculta na iteração t por

$$u_j(t) = \sum_{i=0}^q w_{ij}(t)x_i(t), \quad i = 1, \dots, n, \quad (2.44)$$

tal que w_{ij} é uma conexão sináptica entre a i -ésima entrada e o j -ésimo neurônio da camada oculta, q é número de neurônios na camada oculta, e n é o número de neurônios da camada de entrada. A partir das ativações da camada de entrada, são calculadas as saídas dos respectivos neurônios por

$$z_i(t) = \varphi_i(u_i(t)), \quad (2.45)$$

em que φ_i é a função de ativação e geralmente, consiste na tangente hiperbólica ou sigmóide logística (HAYKIN, 1999).

Caso a rede MLP possua mais de uma camada oculta, as saídas z_i de cada neurônio são apresentadas na camada seguinte como entradas x_i , refletindo-se este processo para todas as outras camadas.

Em seguida, é realizado o cálculo do erro, gradientes locais e o ajuste dos pesos dos neurônios das camadas ocultas e da camada de saída. Nessa etapa, o fluxo de informações dá-se da camada de saída para a entrada (sentido inverso). Inicialmente calcula-se o erro de cada neurônio da camada de saída por (HAYKIN, 1999)

$$e_k(t) = d_k(t) - y_k(t), \quad (2.46)$$

em que $e_k(t)$ é o erro entre a saída desejada $d_k(t)$ para o neurônio da camada de saída k e a saída gerada por ele $y_k(t)$. A partir deste erro, calcula-se os gradientes da camada de saídas, dados por (HAYKIN, 1999)

$$\delta_k(t) = e_k(t)\varphi'(u_k(t)), \quad (2.47)$$

em que $\varphi'(u_k(t))$ é a derivada da função de ativação adotada. Em seguida, é possível calcular o gradiente de cada neurônio das camadas ocultas por

$$\delta_i(t) = \varphi'_i(u_i(t)) \sum_{k=1}^n m_{ki} \delta_k(t). \quad (2.48)$$

Por fim, resta apenas atualizar os pesos da rede MLP. Assim, para atualização dos pesos de cada camada oculta tem-se (HAYKIN, 1999)

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_i(t) x_j(t), \quad (2.49)$$

em que α é um parâmetro de ponderação da atualização dos pesos, conhecido como taxa de aprendizagem.

Para validar a rede treinada, deve-se testar sua saída para dados diferentes daqueles usados durante o treinamento. O conjunto de dados usados para testes deve possuir saída desejada, assim como o conjunto de dados utilizados no treinamento.

Geralmente, apenas uma fração entre 70 e 90% do conjunto de dados com a saída desejada é selecionada aleatoriamente para que o restante possa ser usado para testar o desempenho da rede. O valor do erro calculado com os dados de teste é denominado erro de generalização da rede. É importante ressaltar que, geralmente, o erro de generalização é maior do que o erro de treinamento, pois trata-se de um novo conjunto de dados (HAYKIN, 1999).

2.5 Conclusão do Capítulo

Neste Capítulo são fundamentados os métodos de contornos ativos, desde sua proposição, com o MCA tradicional, até os modelos mais recentes, tais como: GVF, VFC, THMod, THMulti e Crisp. As vantagens e desvantagens destes MCAs também são discutidas, com a intenção de estabelecer um espaço para a inserção do método proposto e as variações. Também, neste Capítulo, são descritas as medidas de avaliação da segmentação adotadas, bem como as Redes Neurais Artificiais, enfatizando a MLP.

Capítulo 3

Metodologia

Neste Capítulo é descrito a forma de aquisição de imagens digitais através de Tomografia Computadorizada e, posteriormente, novos métodos de contornos ativos são propostos buscando suprir as limitações dos MCAs analisados. O primeiro MCA proposto é o MCA Crisp Adaptativo 2D para segmentação dos pulmões em imagens de TC do tórax. Em seguida, este MCA é expandido para 3 Dimensões (3D), gerando o MCA Crisp Adaptativo 3D, que é específico para segmentação dos pulmões em exames de TC do tórax.

3.1 Aquisição de Imagens Médicas

Antes da aquisição das imagens, o tomógrafo é calibrado para a densidade de ar -1000 UH. A calibração é realizada em período inferior a três meses da realização dos exames, conforme especificação técnica recomendada pelo fabricante (TOSHIBA, 1997). Ainda é realizado, antes da aquisição, um corte tomográfico com o *phantom* de água, cuja densidade já é conhecida para análise e controle de parâmetro pelo sistema (FORTALEZA, 2006; WINKELER, 2006). As imagens são quantificadas em 16 *bits* e armazenadas no padrão DICOM (*Digital Imaging and Communications in Medicine*).

Para a leitura destas imagens, que estão no formato DICOM, é utilizada a biblioteca livre DCMTK (*Dicom ToolKit*) fornecida pela OFFIS. Esta biblioteca é compatível com a linguagem de programação C++, a mesma utilizada no desenvolvimento desta tese.

Na Figura 3.1(a) é ilustrado um exemplo de imagem obtida utilizando TC com multidetectors. Esta imagem baseia-se no princípio de que cada estrutura interna do corpo humano possui um determinado valor de densidade radiológica, expresso em Unidades Hounsfield. Portanto, as faixas de densidade pulmonar adotadas neste trabalho são: áreas hiperaeradas ou hiperinsufladas (-1000 a -950 UH), normalmente aerada (-950 a

−500 UH), pouco aerada (−500 a −100 UH), não aerada (−100 a 100 UH) e região ossea (600 a 2000 UH) (GEVENOIS; YERNAULT, 1995; VIEIRA et al., 1998; FELIX, 2007).

A distribuição destas faixas de densidade é mostrada na Figura 3.1(b), em que a cor vermelho representa regiões hiperaeradas, azul escuro normalmente aerada, azul claro representa as áreas pouco aeradas, preto não aerada, verde região óssea, e branco áreas não classificadas.




Figura 3.1: imagem de TC dos pulmões obtida na posição axial, a) obtida com TC multidetectora; b) representação das faixas de densidades (REBOUÇAS FILHO, 2010).

3.2 MCA Crisp Adaptativo 2D

Esta nova técnica de segmentação em imagens é intitulada MCA Crisp Adaptativo 2D, e surge visando superar as limitações observadas na aplicação do MCA Crisp, proposto por REBOUÇAS FILHO (2010), na segmentação dos pulmões em imagens de TC do tórax.

Neste sentido, este novo método baseia-se no funcionamento do MCA Crisp, porém substituindo a força Balão proposta por Mackiewicz (1995) por uma nova força Balão Adaptativa proposta, além de substituir a energia Crisp proposta por REBOUÇAS FILHO (2010) por uma nova energia externa denominada energia Crisp Adaptativa (F_{CRAD}).

A junção destas duas novas energias, propostas nesta tese, gera um MCA denominado MCA Crisp Adaptativo (MCA CRAD), visando identificar as bordas pulmonares, além de não possuir limitações quanto à segmentação de objetos com concavidades, saliências ou bifurcações. Neste sentido, a energia total de um ponto $c(s)$ do MCA CRAD é dado

por

$$E_{CRAD}[c(s)] = E_{int_{adap}}[c(s)] + E_{ext_{CRAD}}[c(s)], \quad (3.1)$$

em que $E_{int_{adap}}$ é a energia interna adaptativa e $E_{ext_{CRAD}}$ é a energia externa Crisp Adaptativa. Estas energias são detalhadas a seguir.

3.2.1 Energia interna adaptativa 2D

Esta nova energia interna proposta no MCA Crisp Adaptativo 2D surge visando superar as limitações observadas na aplicação da energia interna proposta no MCA Balão na segmentação de objetos em imagens digitais.

O MCA Balão apresenta resultados promissores na segmentação de imagens em estudos anteriores quanto ao tempo de processamento, porém este método possui algumas limitações quanto à qualidade da segmentação de alguns objetos. Dentre as restrições encontradas pelo MCA Balão, pode-se destacar a dependência da inicialização adequada para cada objeto de interesse, além de mostrar-se ineficaz na segmentação de algumas regiões com formas tubulares, com saliências e bifurcações (CAVALCANTE, 2010; REBOUÇAS FILHO, 2010).

Neste sentido, o MCA Crisp Adaptativo 2D propõe uma nova energia interna dada por

$$E_{int_{adap}}[c(s)] = w_{cont}F_{cont}[c(s)] + w_{adap}F_{adap}[c(s)]. \quad (3.2)$$

em que $F_{cont}[c(s)]$ é a mesma Força de Continuidade utilizada no MCA Tradicional proposto por Kass, Witkin e Terzopoulos (1987), $F_{adap}[c(s)]$ é a nova força Balão Adaptativa e os parâmetros w_{cont} e w_{adap} são pesos associados a cada força para ajustar a importância de cada um dos seus respectivos termos no cálculo da energia interna $E_{int_{adap}}$.

A força Balão Adaptativa utiliza informações da topologia da curva para expandir o contorno. Estas informações são específicas para cada ponto, e partem do princípio que a curva possui formatos distintos ao longo de sua topologia. Deste modo, a força Balão Adaptativa desloca cada ponto da curva de maneira distinta em direção às bordas do objeto de interesse, adaptando-se a topologia em que está inserido.

No cálculo dessa nova força interna, as informações utilizadas sobre a topologia de cada ponto são geradas a partir de duas informações. A primeira é obtida com base nas coordenadas de seus vizinhos imediatos e a segunda se baseia na forma geral da curva.

A primeira informação da topologia utiliza as coordenadas dos vizinhos imediatos do ponto de interesse para o cálculo da F_{adap} . Estas coordenadas são utilizadas para

determinar o ponto médio dos vizinhos, em que este ponto usa como referência para determinar a direção da F_{adap} .

Já a segunda informação da topologia para o cálculo de F_{adap} é determinada pela forma geral da curva. Isto é possível analisando se o ponto médio dos vizinhos imediatos, calculado anteriormente, está dentro do polígono gerado pela curva considerando todos os seus pontos. Dentre as soluções possíveis deste problema, utiliza-se a solução sugerida por BERG et al. (1975), visto que este método apresentou-se adequado quanto à velocidade e desempenho (FIGUEIREDO; CARVALHO, 1991; LASZLO, 1996).

O método desenvolvido por BERG et al. (1975), também conhecido por Teorema da Curva de Jordan, determina se um ponto é interno ou externo a um polígono, traçando uma semi-reta deste ponto até um ponto externo do polígono. A partir disto, conta-se as intersecções desta semi-reta com o polígono. Caso a quantidade de intersecções seja ímpar, o ponto está dentro do polígono. Caso contrário, o ponto está fora do polígono.

Após encontrar as duas informações da topologia da curva para cálculo da F_{adap} , têm-se que a mesma é dada por

$$F_{adap}[c(s)] = \sqrt{E_x^2 + E_y^2}, \quad (3.3)$$

em que as componentes E_x e E_y são definidas por

$$E_x = |x(s) \pm x_m|, \quad (3.4)$$

e

$$E_y = |y(s) \pm y_m|, \quad (3.5)$$

em que $x(s)$ e $y(s)$ são as coordenadas do ponto $c(s)$ onde F_{adap} está sendo calculada, x_m e y_m são as coordenadas do ponto médio dos vizinhos. A segunda informação da topologia determina o sinal utilizado nas equações 3.4 e 3.5, sendo negativo quando o ponto é externo à curva e positivo quando o ponto está interno.

Mostra-se na Figura 3.2 uma curva para exemplificar a aplicação da F_{adap} em duas situações distintas, analisando os casos do ponto médio dos vizinhos está interno ou externo à curva, considerando os pontos A e F , respectivamente.

Analisando o ponto A da Figura 3.2, constata-se que este possui como vizinhos imediatos os pontos O e B , em que a média de suas coordenadas resulta no ponto M_{OB} . Já o ponto F , possui como vizinhos imediatos os pontos E e G , e a média das coordenadas destes pontos geram o ponto M_{EG} . Considerando os pontos M_{EG} e M_{OB} e aplicando a solução descrita por BERG et al. (1975), têm-se que o ponto M_{OB} é considerado dentro da curva, enquanto M_{EG} é dito como ponto externo.

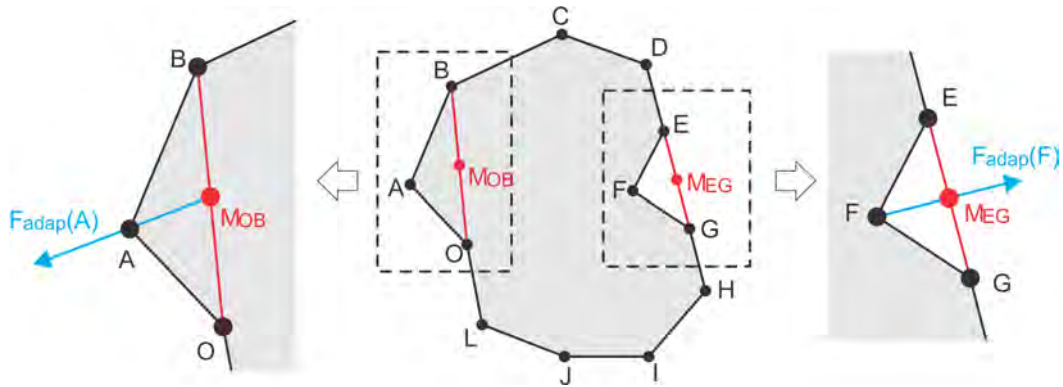


Figura 3.2: exemplos de cálculo da força Balão Adaptativa.

Desse modo, sabendo as informações da topologia em que os pontos A e F estão inseridos, têm-se que o resultado da equação 3.3 nestes pontos deve expandir a curva na direção e sentido demonstradas, respectivamente, pelas forças $F_{adap}(A)$ e $F_{adap}(F)$, conforme demonstrado em azul na Figura 3.2.

A partir dos argumentos expostos, têm-se que a Força Adaptativa é de fundamental importância por expandir a curva, principalmente quando esta se encontra em regiões homogêneas da imagem, pois a força externa é nula e as únicas forças que interferem na curva são as forças internas. Neste caso, a Força Adaptativa deforma o contorno para que este se aproxime das bordas após iterações sucessivas do método.

Para exemplificar a ação da F_{adap} nos pontos de uma curva completa, a Figura 3.3 demonstra a força balão de duas curvas com formas distintas, sendo a Figura 3.3(a) uma forma quadrada e a Figura 3.3(b) uma forma composta por partes côncavas e partes convexas. Nesta Figura, os pontos estão em azul, o contorno em vermelho e o vetor da F_{adap} de cada ponto é apresentado em verde.

Analisando as forças apresentadas na Figura 3.3, conclui-se que os pontos da curva são impulsionados para todas direções, não possuindo limitações quanto à forma dos objetos de interesse. Deste modo, esta nova força interna é chamada Adaptativa devido seu comportamento de adaptar-se ao formato da curva, impulsionando os pontos da curva em diversas direções distintas para fora do contorno.

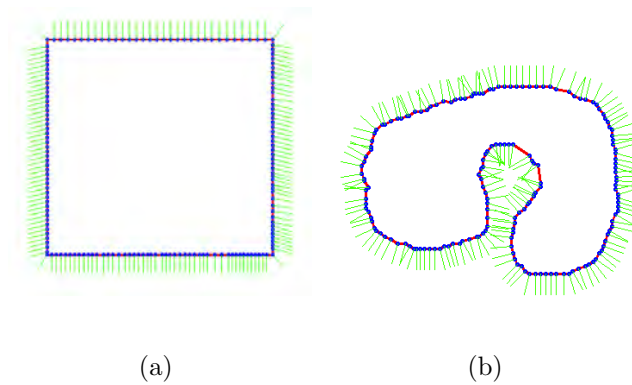


Figura 3.3: demonstraç o da Força Bal o Adaptativa, em verde, dos pontos, em azul, de curvas nas formas: a)quadrada; e b)convexos/c ncavos.

Um exemplo do passo-a-passo da evolu o desta nova energia interna   apresentada na Figura 3.4, desde a sua inicializa o, apresentada na Figura 3.4(a) at  sua estabiliza o no resultado final mostrado na Figura 3.4(i), ressaltando que a energia externa utilizada neste exemplo   a Tradicional. Nesta Figura, os pontos s o apresentados em azul, suas conex es em vermelho formando a curva e a dire o da energia interna Bal o Adaptativa   apresentada em verde. Esta energia parte de cada ponto e aponta para dire o onde esta energia   m nima para topologia apresentada em sua vizinhan a.

Analisando cada dire o gerada pela minimiza o da energia interna de cada ponto em todas as imagens apresentadas na Figura 3.4, podem-se listar tr s motivos para esta energia interna obter resultados superiores aos demais MCAs estudados. Primeiramente, tem-se que cada uma destas dire es possui uma dire o distinta em todas as imagens. Em segundo lugar, nenhuma desta dire es aponta para dentro do objeto de interesse, acelerando a converg ncia dos pontos para as bordas do objetos de interesse, al m de evitar poss veis falhas de segmenta o. Por  ltimo, ressalta-se que em regi es homog neas e distantes das bordas do objetos, a dire o sempre aponta para uma borda do objeto de interesse.

Estes motivos, em conjunto, explicam a velocidade de converg ncia gerada pela energia interna proposta, j  que cada ponto   direcionado para um local distinto. Al m disso, explica sua adaptabilidade  s diferentes topologias do objeto de interesse, visto que sempre existe, pelo menos um ponto na dire o do restante do objeto que ainda n o faz parte do interior do contorno j  obtido.

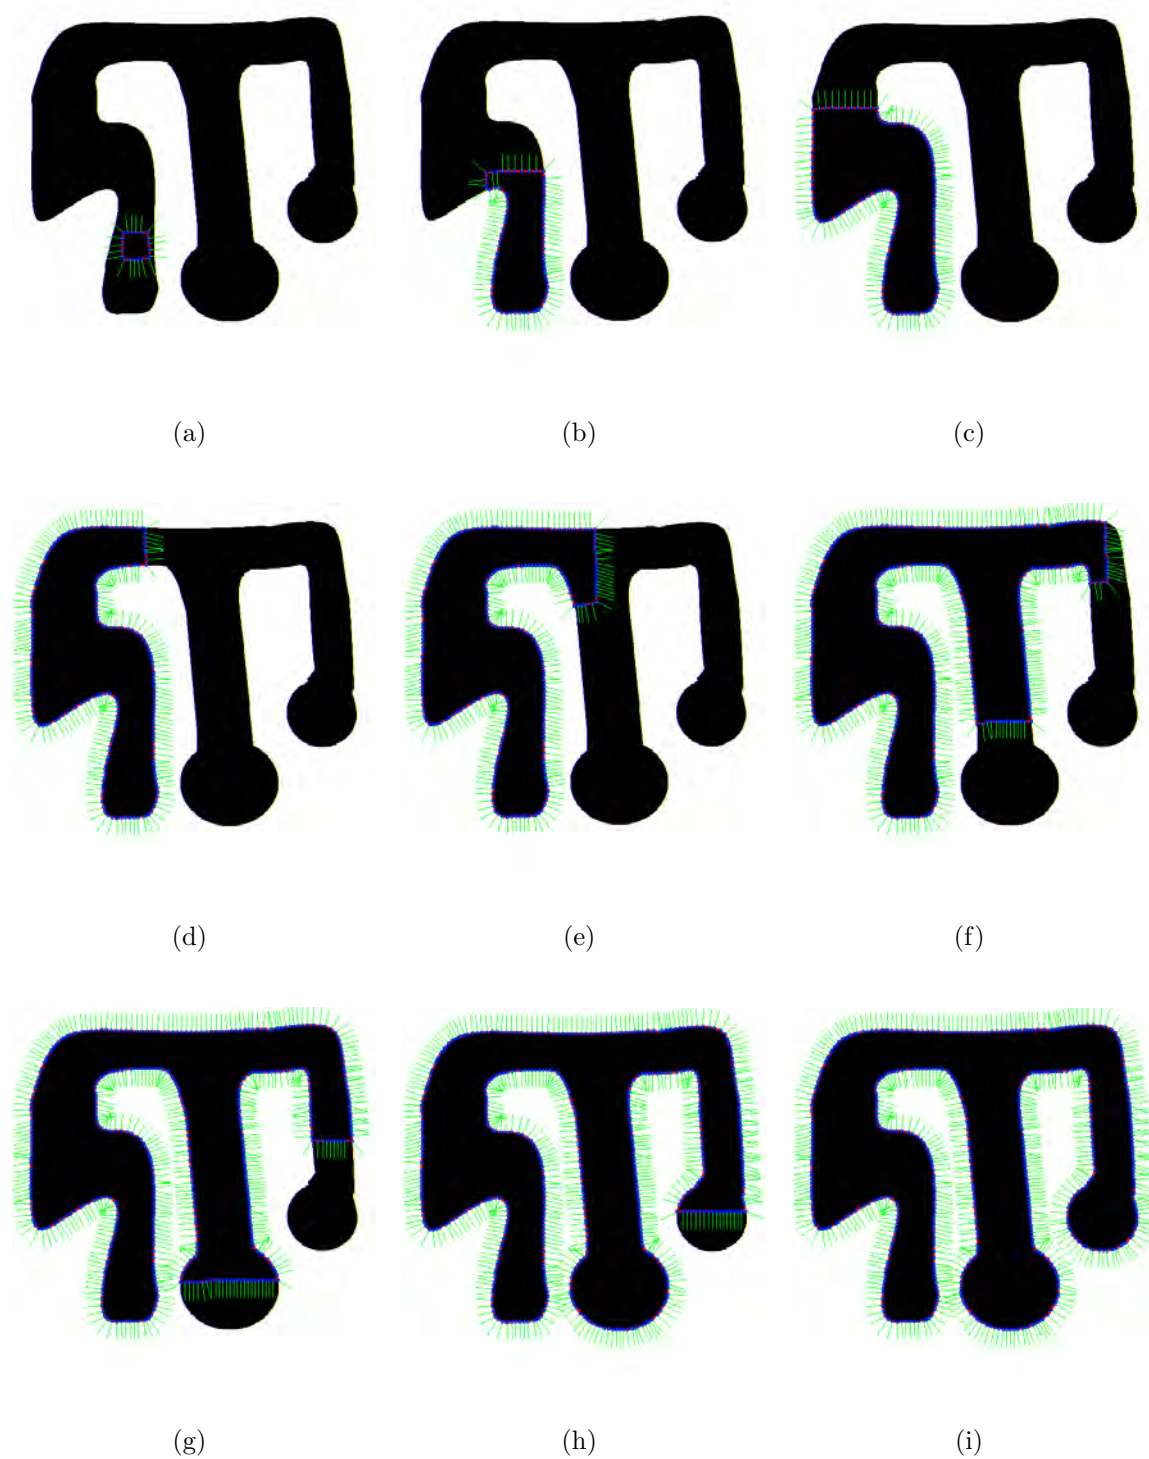


Figura 3.4: exemplo da segmentação obtida pelo MCA Balão Adaptativo 2D, em que os pontos são apresentados em azul, o contorno em vermelho e a direção da força Balão Adaptativo 2D de cada ponto é apresentada em verde, a) inicialização; b) até h) passo a passo do método; e i) resultado da segmentação.

3.2.2 Energia externa Crisp Adaptativa 2D

O MCA Crisp, proposto em um estudo anterior, insere uma energia externa, denominada energia Crisp (E_{Crisp}), baseada nas faixas de densidade pulmonar e é estabelecida por uma função para calcular os percentuais de cada uma das faixas de densidade pulmonar presentes na vizinhança de um determinado pixel. Esta análise determina a origem das bordas encontradas por um operador Sobel, em que apenas as bordas do pulmão são consideradas, e as demais apagadas da energia externa deste MCA. Um exemplo da classificação gerada por esta energia externa é apresentada na Figura 3.5.




Figura 3.5: imagem de TC dos pulmões, a) original; b) gradiente Sobel; e c) resultado da classificação gerada pela força externa do MCA Crisp (REBOUÇAS FILHO, 2010).

Esta energia externa apresentou resultados promissores quando integrada a um MCA na segmentação dos pulmões em imagens de TC do tórax em estudos anteriores (CAVALCANTE, 2010; REBOUÇAS FILHO, 2010). Entretanto, este método possui limitações na segmentação da região do hilo e dos vasos internos, em algumas imagens, considerando-os como pulmões. Isto ocorre devido este método distinguir as paredes pulmonares das demais apenas por uma regra geral. Isto acarreta falhas na distinção da origem das bordas encontradas porque os pulmões possuem diversos formatos, em que a posição, tamanho e espessura das estruturas internas são variadas. Além disso, os pulmões podem ter alguma anomalia ou doença que gerem alterações nas densidades radiológicas dos mesmos.

Desse modo, algumas falhas da energia externa Crisp proposta por REBOUÇAS FILHO (2010) são apresentadas na Figura 3.6, em que as **falhas 1 e 3** são causadas pelo fato de a F_{crisp} determinar que dois vasos, que estão dentro dos pulmões, são rotulados como borda do pulmão, enquanto a **falha 2** é o inverso, onde uma borda do pulmão é rotulada como não sendo uma borda do pulmão. Este último erro é comum em imagens

que contém o hilo próximo ao pulmão.




Figura 3.6: demonstração de falhas da força Crisp proposta por REBOUÇAS FILHO (2010) na detecção das bordas pulmonares em imagens de TC do tórax.

A nova energia $E_{ext_{CRAD}}$ proposta utiliza o conceito de Análise das Densidades Pulmonares (ADP) de uma vizinhança aplicado no MCA Crisp (REBOUÇAS FILHO, 2010). Isto é possível aplicando a equação 2.30 para obter os percentuais das 6 classes u_i , em que i varia de 0 a 5, sendo estas:

- u_0 - hiperaeradas (−1000 a −950 UH) ;
- u_1 - normalmente aeradas (−950 a −500 UH);
- u_2 - pouco aeradas (−500 a −100 UH);
- u_3 - não aeradas (−100 a 100 UH);
- u_4 - osso (600 a 2000 UH);
- u_5 - áreas não classificadas (densidades que não se enquadram nas demais).

Para contornar as restrições da energia externa Crisp, esta nova energia incorpora uma RNA MLP para determinar a origem de cada borda encontrada em imagens de TC do tórax. As entradas desta MLP são os 6 percentuais das classes u_i encontradas pelo método ADP utilizando a equação 2.30. Enquanto isto, existe apenas uma saída para

indicar se as bordas encontradas em imagens de TC do tórax são ou não das paredes pulmonares.

Neste método é utilizada apenas uma camada oculta na topologia da MLP, em que esta camada é a responsável pela resolução de problemas não separáveis linearmente. Neste sentido, para determinar a quantidade de neurônios na camada oculta HN é utilizada a solução descrita por YIN, LIU e HAN (2005)

$$HN = \frac{2 \times \max(M_1, M_2)}{3}, \quad (3.6)$$

em que M_1 e M_2 são as quantidades de neurônios na entrada e na saída, respectivamente.

O resultado da equação 3.6 utilizando M_1 sendo os 6 percentuais das classes u_i e M_2 sendo apenas a única saída para determinar se a borda é do pulmão ou não, tem-se que esta aplicação obtém uma topologia 6/4/1, ou seja, 6 neurônios na entrada, 4 neurônios na camada oculta e 1 neurônio na saída. A topologia especificada é verificada pelo método da validação cruzada (HAYKIN, 1999), em que um conjunto de exemplos é separado aleatoriamente, sendo um conjunto utilizado para o treinamento da rede neural e o outro para experimento, visando a validação do classificador.

O conjunto de dados utilizados neste treinamento é extraído de imagens de pacientes com DPOC, fibrose e de voluntários sadios nas posições de ápice, hilo e base dos pulmões em imagens de TC do tórax, obtidas conforme descrito na Seção 4.1.

Para a fase de treinamento, os dados são selecionados manualmente, buscando obter uma maior representação possível das estruturas do pulmão. Em média, 150 pixels são adicionados por imagem, indicando se a origem das bordas encontradas através do operador Sobel são das paredes pulmonares, e quais não são, estando neste conjunto as bordas dos ossos, vasos, vias aéreas, ar e outras estruturas que não sejam os pulmões. São utilizados nesta etapa 500 imagens de diferentes exames, doenças e níveis de corte.

Cada dado do conjunto de entrada é obtido a partir de um *pixel* $P(x_p, y_p)$, em que x_p e y_p são as coordenadas do pixel utilizada na função $f(x_p, y_p, s_i)$ da equação 2.30 para obter todos os percentuais u_i usados como entrada da MLP. O treinamento da rede Neural é efetuado e testado de acordo com a validação cruzada (HAYKIN, 1999).

Utilizando a rede neural MLP, previamente treinada, tem-se que em sua fase de execução a saída desta é dada pela função

$$f_{mlp}(\mathbf{u}) = \begin{cases} 1, & \text{quando a borda detectada constituir a parede pulmonar,} \\ 0, & \text{caso contrário.} \end{cases} \quad (3.7)$$

Utilizando f_{mlp} para determinar a origem das bordas encontradas em imagens de TC

do tórax, tem-se que a energia externa $E_{extCRAD}$, definida na equação 3.1, é dada por

$$E_{extCRAD}(x, y) = \begin{cases} S(x, y), & \text{para } f_{mlp}(\mathbf{u}) = 1, \\ 1, & \text{caso contrário,} \end{cases} \quad (3.8)$$

em que $S(x, y)$ é o operador Sobel, e \mathbf{u} é o vetor de percentuais do método ADP obtidos pela equação 2.30, utilizando as coordenadas (x, y) do *pixel* analisado.

Para exemplificar as diferenças obtidas pela energia externa $E_{extCRAD}$ e a energia proposta no MCA Crisp (REBOUÇAS FILHO, 2010), a Figura 3.7 exemplifica algumas diferenças na análise destas energias aplicadas em uma mesma imagem.




Figura 3.7: resultados da análise da origem das bordas em uma imagem de TC do tórax através dos métodos, a) Crisp; e b) Crisp Adaptativo, com as diferenças apresentadas por regiões, em que o Crisp Adaptativo apresenta os resultados corretos.

Analisando os resultados apresentados na Figura 3.7, conclui-se-se que a energia externa do MCA Crisp acerta a maior parte da origem das bordas presentes em imagens de TC do tórax, entretanto apresenta alguns erros pontuais, demonstrados por quadrado pretos na Figura 3.7(a). Já a energia proposta nesta tese utilizando uma RNA MLP, com o resultado apresentado na Figura 3.7(b), obtém êxito na identificação até mesmo destes pontos em que a energia Crisp apresenta falhas.

A energia externa desse método é capaz de identificar a origem das bordas de pulmões com fibrose, enfisema e sádios. Isto porque a RNA MLP é treinada para reconhecer estes padrões, visto que são os casos de maior incidência nos pulmões em imagens de TC

do tórax. Para exemplificar este funcionamento, a Figura 3.8 apresenta as etapas para obtenção da energia externa Crisp Adaptativa.




Figura 3.8: etapas para obtenção da energia externa Crisp Adaptativa, a), e) e i) imagens originais de pacientes com DPOC, Fibrose e voluntários Sadios, respectivamente; b), f) e g) rerepresentação da energia externa Tradicional em uma imagem; c), g) e k) classificação da MLP para determinar origem das bordas; e d), h) e l) representação da energia externa Crisp Adaptativa em uma imagem.

3.2.3 Inicialização automática do MCA Crisp Adaptativo 2D

O algoritmo de inicialização do contorno tem como objetivo encontrar as coordenadas iniciais para este. No caso de imagens de TC dos pulmões, tem-se dois objetos de interesse, os pulmões direito e esquerdo. Assim, é necessário um ponto de inicialização para cada pulmão.

Analisando várias imagens de TC dos pulmões, observa-se que os objetos de interesse estão centralizados em duas regiões, esquerda e direita, conforme é ilustrado nas imagens de TC na Figura 3.9. As regiões inferior e superior ilustradas nesta Figura são descartadas da análise, devido a existência de ar nestas regiões, tornando-se semelhantes ao interior do pulmão que também contém ar, que pode confundir o método de inicialização, em alguns casos.




Figura 3.9: regiões utilizadas para encontrar os pontos para as inicializações da curva nos pulmões esquerdo e direito, nas posições, a) ápice; b) hilo; e c) base.

Após analisar o desempenho do algoritmo de inicialização, utilizando apenas as regiões esquerda e direita apresentadas na Figura, conclui-se que a taxa de acerto do método aumenta, enquanto o tempo de processamento diminuiu, visto que uma região menor é analisada.

Considerando as regiões esquerda e direita, tem-se que no eixo das abscissas, o limite inferior e o superior são denominados LIX e LSX , respectivamente. Já no eixo das ordenadas, o limite inferior e superior são denominados LIY e LSY . Ressalta-se que, cada uma das regiões esquerda e direita, possui seus próprios limites LIX , LSX , LIY e LSY .

Deste modo, considerando a matriz de *pixels* de uma imagem de TC $I(x, y)$ de dimensão 512×512 , calcula-se as coordenadas de inicialização no eixo das abscissas através da função

$$c(x) = \sum_{y=L1Y}^{LSY} p(y) \quad \therefore \quad p(y) = \begin{cases} 1, & \text{para } f_{mlp}(\mathbf{u}) = 0, \\ 0, & \text{caso contrário,} \end{cases} \quad (3.9)$$

e

$$l(y) = \sum_{x=L1X}^{LSX} p(x) \quad \therefore \quad p(x) = \begin{cases} 1, & \text{para } f_{mlp}(\mathbf{u}) = 0, \\ 0, & \text{caso contrário,} \end{cases} \quad (3.10)$$

em que \mathbf{u} é o vetor de percentuais do método ADP, obtidos pela equação 2.30 utilizando as coordenadas (x, y) do pixel analisado, e f_{mlp} é a função que determina se uma borda do pulmão é falsa ou verdadeira, conforme equação 3.7.

A posição x que obtiver o maior valor de saída da função $c(x)$ é dita como a coluna de inicialização da curva, ou seja, a coordenada x de inicialização, x_e para região Esquerda e x_d para região Direita. Analogamente, a linha que obtiver a maior saída na função $l(y)$ é dita como coordenada de inicialização do eixo y para a região analisada, sendo y_e para a região esquerda e y_d para região direita.

Após determinar os pontos de inicialização esquerdo e direito, então estes são usados como centróide de um polígono regular, em que este polígono é a inicialização da curva referente a cada ponto. A distância de cada ponto para o baricentro é configurada no algoritmo de inicialização, juntamente com a quantidade de vértices do polígono.

São apresentados na Figura 3.10 três exemplos de inicialização das curvas esquerda e direita com raio igual a 30 *pixels* e 30 pontos em cada curva, em que os pontos da curva são apresentados em azul e a curva em vermelho.




Figura 3.10: inicialização automática da curva nos pulmões esquerdo e direito, em que as imagens estão na posição, a) ápice; b) hilo; e c) base.

O método de inicialização proposto no MCA Crisp Adaptativo é uma otimização do proposto pelo MCA Crisp, em que este método possui a mesma eficiência, mas possuindo uma maior velocidade, possuindo em média 25% do tempo do MCA Crisp. Isto acontece porque o MCA Crisp analisa todos os pontos da região analisada nos cálculos implementados, enquanto o método proposto nesta tese analisa somente as bordas que estão dentro do pulmão, diminuindo a quantidade de dados processados, aumentando a velocidade do método de inicialização quando comparado com o método de inicialização proposto pelo MCA Crisp REBOUÇAS FILHO (2010).

3.2.4 Adição e Remoção de pontos do MCA Crisp Adaptativo 2D

A inclusão e exclusão de pontos também são elementos importantes na dinâmica do MCA Crisp Adaptativo 2D. A inclusão permite um maior refinamento do resultado e, portanto, maior acurácia na segmentação dos pulmões. A exclusão elimina pontos do contorno que estavam em discrepância com os seus vizinhos e elimina pontos vizinhos que possuem as mesmas coordenadas. A priori, pontos vizinhos não devem estar em uma mesma coordenadas, sobrepondo-se um ao outro. Entretanto, isto pode acontecer quando os pontos movimentam-se, então um dos pontos deve ser apagado.

O método de remoção de pontos se baseia em dois critérios. O primeiro consiste em apagar o ponto quando suas coordenadas são iguais às coordenadas de um ponto consecutivo. Já o segundo critério baseia-se na remoção de pontos que possuem variação brusca de coordenadas em relação aos seus vizinhos. Esta variação é detectada a partir do ângulo formado entre o ponto analisado e seus vizinhos. Este ângulo α é determinado utilizando a lei dos cossenos dados por $\alpha = \arccos\left(\frac{a^2+b^2-c^2}{2bc}\right)$, em que os termos utilizados são demonstrados na Figura 3.11.

Quando um ângulo entre um ponto e seus vizinhos é inferior ao valor mínimo pré-estabelecido na parametrização deste método, então este ponto é apagado e o contorno é reajustado, conforme ilustrado na Figura 3.12 apagando o ponto *I*.




Figura 3.11: modelo para cálculo do ângulo entre um ponto e seus vizinhos.




Figura 3.12: demonstração da reordenação dos pontos apagando o ponto I.

O método de adição de pontos se baseia na distância Euclidiana entre dois pontos consecutivos do contorno, igualmente o descrito pelo MCA Crisp (REBOUÇAS FILHO, 2010), em que um ponto é adicionado quando a distância entre dois pontos consecutivos é maior que uma distância máxima configurada previamente. Entretanto, este método de adição calcula o ponto médio entre os pontos consecutivos para ser adicionado na curva, mas só o adiciona se o mesmo for rotulado como dentro do pulmão. Para isto, são usadas as faixas de densidades radiológicas que são exclusivas ao interior do pulmão, que são as regiões hiperaeradas (-1000 a -950 UH) e normalmente aeradas (-950 a -500 UH). Deste modo, o ponto só é adicionado se o valor do seu **pixel** em Unidades Hounsfield estiver entre -1000 a -500 UH.

Caso este ponto médio não esteja na faixa de UH pré-definida, para solucionar este problema este método denominado de Adição Adaptativa deve deslocar este ponto para dentro do pulmão. Para isto, este método segue os seguintes passos:

1. encontrar o ponto médio dos vizinhos, que possuem distância maior que a permitida

na configuração;

2. determinar o ângulo α de inclinação formado pela semi-reta dos vizinhos na etapa 1;
3. encontrar duas direções que partem do ponto médio dos vizinhos, uma com o ângulo $\alpha + \frac{\pi}{2}$, e a segunda com o ângulo $\alpha - \frac{\pi}{2}$;
4. determinar qual direção, das duas descritas na etapa 3, resulta dentro da curva já existente;
5. encontrar o primeiro ponto que parte do ponto médio dos vizinhos na direção encontrada na etapa 4 está dentro dos pulmões, e adicionar o ponto naquela coordenada.

Considerando que dois pontos vizinhos com distância maior que a máxima configurada sejam os pontos V_1 e V_2 , compostos pelas coordenadas (x_{V_1}, y_{V_1}) e (x_{V_2}, y_{V_2}) , respectivamente. Tem-se que a conexão entre V_1 e V_2 forma uma semi-reta. Deste modo, seguindo os passos descritos, tem-se que o ponto médio $M(x_M, y_M)$ desta semi-reta é dado por

$$y_M = \frac{y_{V_1} + y_{V_2}}{2} \quad (3.11)$$

e

$$x_M = \frac{x_{V_1} + x_{V_2}}{2}, \quad (3.12)$$

Já o ângulo α desta semi-reta em relação a linha horizontal é dado por

$$\alpha = \arctan\left(\frac{y_{V_1} - y_{V_2}}{x_{V_1} - x_{V_2}}\right). \quad (3.13)$$

Para determinar a direção citada no passo 4 é necessário considerar dois pontos $P_1(x_1, y_1)$ e $P_2(x_2, y_2)$, sendo P_1 utilizando o ângulo $(\alpha + \frac{\pi}{2})$ e P_2 utilizando o ângulo $(\alpha - \frac{\pi}{2})$. Deste modo, o ponto P_1 é determinado por

$$y_1 = y_M + d \times \sin\left(\alpha + \frac{\pi}{2}\right) \quad (3.14)$$

e

$$x_1 = x_M + d \times \cos\left(\alpha + \frac{\pi}{2}\right), \quad (3.15)$$

Já o ponto P_2 é dado por

$$y_2 = y_M + d \times \sin\left(\alpha - \frac{\pi}{2}\right) \quad (3.16)$$

e

$$x_2 = x_M + d \times \cos\left(\alpha - \frac{\pi}{2}\right), \quad (3.17)$$

em que d é uma distância configurável utilizada apenas para determinar uma amostra de ponto em cada direção. Os pontos P_1 e P_2 são analisados pelo método desenvolvido por BERG et al. (1975) para verificar qual dos mesmos está dentro do polígono formado pela curva.

O passo 5 descrito é possível utilizando um ângulo α_a , em que este é $(\alpha + \frac{\pi}{2})$ caso P_1 esteja dentro do contorno e $(\alpha - \frac{\pi}{2})$ caso P_2 esteja dentro do contorno. O ponto $A(x_A, y_A)$ que é adicionado entre os dois vizinhos, determinado por

$$y_A = y_M + d \times \sin(\alpha_a) \tag{3.18}$$

e

$$x_A = x_M + d \times \cos(\alpha_a), \tag{3.19}$$

em que a distância d varia de 1 a 50, e o primeiro ponto (x_A, y_A) que estiver dentro do pulmão é adotado como o ponto a ser adicionado entre os dois vizinhos com distância maior do que a distância máxima configurada. Caso a distância d ultrapasse o valor 50 e um ponto dentro do pulmão não seja encontrado, então o ponto será adicionado.

Para descrever este método, a Figura 3.13 apresenta dois vizinhos com distância superior a máxima permitida previamente, em que o primeiro ponto deve ser adicionado no ponto médio de \overline{AB} , e o segundo no ponto médio de \overline{EF} .




Figura 3.13: demonstração do método de adição de pontos do MCA Crisp Adaptativo.

Seguindo os passos descritos por este método, primeiramente são encontrados os pontos médios dos vizinhos para cada distância. Em seguida, o ângulo α é determinado para cada caso, conforme equação 3.13.

Utilizando o ponto médio dos vizinhos e o ângulo α , aplicam-se as equações 3.14 e 3.15 para descobrir os pontos defasados em $+\frac{\pi}{2}$, sendo estes P_{BA_1} para o segmento \overline{AB} e P_{EF_1} para o segmento \overline{EF} . Para determinar os pontos defasados em $-\frac{\pi}{2}$ aplicam-se as equações 3.16 e 3.17, sendo estes P_{BA_2} para o segmento \overline{AB} e P_{EF_2} para o segmento \overline{EF} .

Após encontrar os pontos P_{BA_1} e P_{BA_2} referentes as direções do segmento \overline{AB} , observa-se que a direção utilizada para adicionar o ponto é P_{BA_1} . Já para o segmento \overline{EF} , a direção utilizada é P_{EF_2} , descartando P_{EF_1} . Neste sentido, analisando a Figura 3.13, conclui-se que a direção utilizada para adicionar o ponto está defasada em $\frac{\pi}{2}$ e apontando para dentro do contorno.

Um exemplo de aplicação da Adição Adaptativa de pontos dentro dos pulmões é mostrado na Figura 3.14, em que o contorno encontra-se na topologia apresentada pelos pontos em azul, as conexões destes em vermelho e os pontos que devem ser adicionados pelo método de Adição Adaptativa estão em verde. Os pontos para adição a priori são os pontos médios das semi-retas, porém quando estes possuem densidade radiológica fora das densidades específicas de dentro dos pulmões (-500 a -1000 UH), então estes são deslocados para dentro do pulmão, mostrado em branco na Figura 3.14.




Figura 3.14: demonstração do método de adição de pontos do MCA Crisp Adaptativo atuando em imagens de TC do tórax.

3.2.5 Segmentação automática dos pulmões em imagens de TC do tórax através do MCA Crisp Adaptativo 2D

A segmentação automática dos pulmões em imagens de TC do tórax utiliza os métodos inicialização automática da curva, os métodos de adição e remoção de pontos e o MCA Crisp Adaptativo descritos anteriormente. Estes métodos são executados seguindo o fluxograma apresentado na Figura 3.15, em que exemplos de cada etapa são apresentados ao lado de sua representação no fluxograma. Nas imagens que contém a curva, os pontos são apresentados em azul e suas conexões em vermelho.

O primeiro passo para segmentar os pulmões de forma automática em imagens de TC é abrir a imagem DICOM. Para isto, é utilizada a biblioteca livre DCMTK. Em seguida, a força externa da imagem é calculada utilizando o método ADP e uma RNA MLP para detectar a origem das bordas obtidas pelo operador Sobel. As bordas do operador detectadas dentro do pulmão são excluídas da força externa, e também são utilizadas para inicialização da curva.

A curva é inicializada utilizando o método proposto, em que as bordas falsas do pulmão determinam o ponto de inicialização dentro do pulmão. Este ponto é o centróide de um polígono regular utilizado como inicialização da curva.

Esta curva move-se por iterações sucessivas da sequência de três métodos: MCA Crisp Adaptativo minimizando sua energia movimentando os pontos da curva, remoção de pontos baseada no ângulo e Adição Adaptativa de pontos na curva. No fluxograma esta sequência de métodos é chamada de ciclos, e a letra n indica a ordem de resultados obtidos em cada ciclo n .

A curva é rotulada estável quando o perímetro não aumenta após duas iterações consecutivas. Quando isto acontece, a segmentação do pulmão está concluída, e o polígono gerado pela curva é dito como o resultado da segmentação do objeto de interesse.

São apresentados exemplos de evolução de duas curvas, uma em cada pulmão, aplicando o MCA Crisp Adaptativo na segmentação dos pulmões em imagens de TC do tórax, em que os pontos estão apresentados em azul e suas conexões em vermelho.

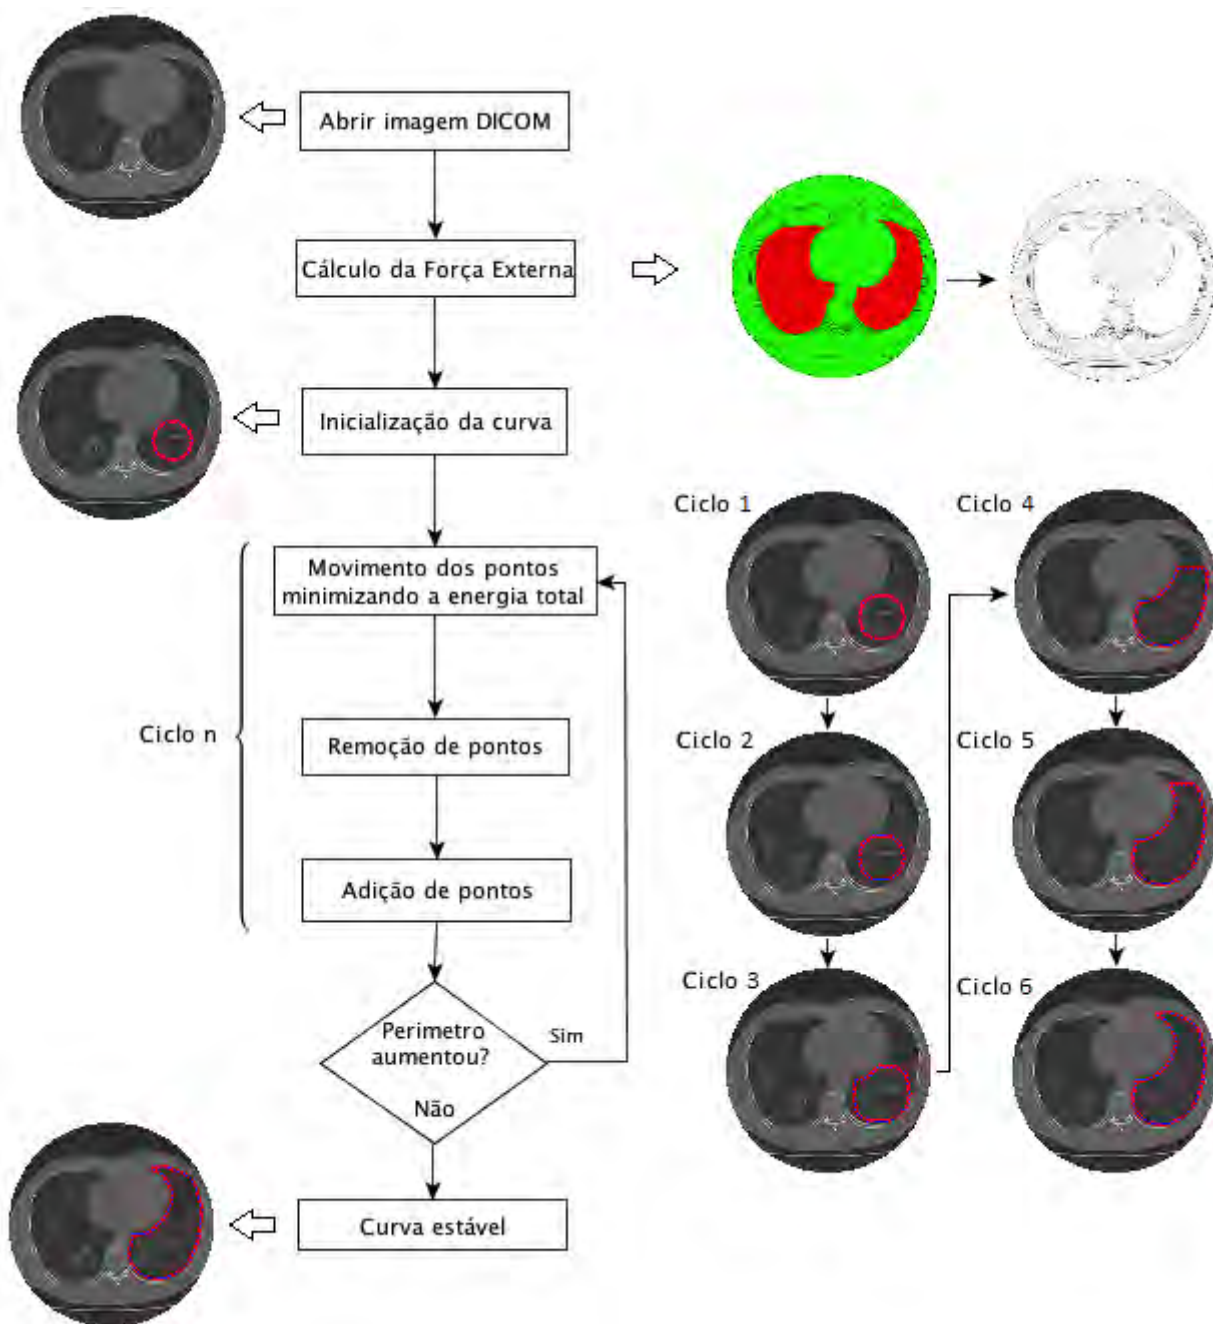


Figura 3.15: demonstração do fluxograma de execução do método MCA Crisp Adaptativo 2D.




Figura 3.16: exemplo de evolução de duas curvas aplicando o MCA Crisp Adaptativo na segmentação dos pulmões em imagens de TC do tórax, a) inicialização; b) até e) evolução do movimento da curva; e f) resultado da segmentação.

3.3 MCA Crisp Adaptativo 3D

Nesta seção é descrita uma nova técnica de segmentação de imagens baseada nos Métodos de Contornos Ativos em três dimensões (3D), denominada de MCA Crisp Adaptativo 3D. Esta é uma expansão da técnica proposta na Seção 3.2 e deve ser aplicada exclusivamente em exames de TC do tórax, visando a segmentação dos pulmões. Esta seção também apresenta os métodos em três dimensões de inicialização automática, adição e remoção de pontos. Além disto, propõe um método de visualização 3D destes objetos para a visualização da execução destes métodos e dos seus resultados.

O MCA Crisp Adaptativo 2D, descrito na Seção 3.2, propõe uma nova energia externa baseada na detecção da origem das bordas presentes em imagens de TC do tórax e uma energia interna Balão Adaptativa, gerando um novo método de segmentação dos pulmões

em imagens de TC do tórax. Seguindo o mesmo princípio, o MCA Crisp Adaptativo 3D propõe novas energias interna e externa 3D, que combinadas são capazes de segmentar os pulmões em três dimensões, ou seja, capaz de segmentar os pulmões utilizando o exame completo de TC, segmentando os pulmões em todas as imagens deste exame.

Neste sentido, o novo método é intitulado MCA Crisp Adaptativo 3D surge, a partir da expansão do MCA Crisp Adaptativo 2D para três dimensões, visando segmentar os pulmões em um exame completo de TC do tórax. Neste sentido, um ponto $m(s)$ movimenta-se minimizando a energia do MCA Crisp Adaptativo 3D E_{CA3D} , em que esta energia é dada por

$$E_{CA3D}[m(s)] = E_{int_{adap3D}}[m(s)] + E_{ext_{CRAD3D}}[m(s)], \quad (3.20)$$

nas quais $E_{int_{adap3D}}[m(s)]$ é a energia interna Adaptativa 3D e $E_{ext_{CRAD3D}}[m(s)]$ é a energia externa Crisp Adaptativa 3D, ambas propostas neste método. Um ponto m do modelo 3D possui como coordenada uma curva c em uma camada i do eixo z . Assim, $[m(s)] = [c(s), z_i]$, em que $[c(s)]$ é composto pelas coordenadas $[x(s), y(s)]$, bem como no método 2D, e z_i é o plano a qual pertence a curva c , ou seja, a posição do ponto $c(s)$ no eixo z .

3.3.1 Energia interna Adaptativa 3D

A energia interna Adaptativa 3D expande a energia interna Adaptativa 2D utilizando informações das camadas imediatamente superior e inferior, gerando uma energia interna definida por

$$E_{int_{adap3D}}[m(s)] = w_{cont}F_{cont3D}[m(s)] + w_{adap}F_{adap3D}[m(s)], \quad (3.21)$$

em que $F_{cont3D}[m(s)]$ é a mesma Força de Continuidade utilizada no MCA Tradicional Kass, Witkin e Terzopoulos (1987) e $F_{adap3D}[m(s)]$ é a Força Adaptativa, ambas expandidas para 3D. Os parâmetros w_{cont} e w_{adap} são pesos associados a cada força para ajustar a importância de cada um dos seus respectivos termos no cálculo da energia interna $E_{int_{adap3D}}$.

Força de continuidade 3D

A Força de continuidade 2D calculada a partir dos pontos de uma curva, descrita na Seção 2.2.1, é associada à distância e atua mantendo o espaçamento entre os pontos da curva uniforme, aumentando a distância entre pontos próximos e aproximando pontos distantes.

A expansão desta força para 3D consiste em inserir informações das camadas vizinhas em seu cálculo. Esta formulação tende a deixar a curva igualmente espaçada, tendendo a deixar os pontos o mais equidistante possível, considerando a distância entre os pontos vizinhos de uma mesma camada e os mais próximos de camadas vizinhas.

Para o cálculo desta força, utiliza-se a distância d_{3D} entre dois pontos considerando os eixos x , y e z , dada por

$$d_{3D} = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2}, \quad (3.22)$$

em que Δx , Δy e Δz correspondem as diferenças dos pontos nos eixos x , y e z , respectivamente.

Neste sentido, a Força de Continuidade 3D $F_{cont_{3D}}$ é dada por

$$F_{cont_{3D}}[x(s), y(s), z_i] = F_{cont_{3D}z_i}[x(s), y(s), z_i] + F_{cont_{3D}z_{i-1}}[x(s), y(s), z_i] + F_{cont_{3D}z_{i+1}}[x(s), y(s), z_i], \quad (3.23)$$

em que $F_{cont_{3D}z_i}$, $F_{cont_{3D}z_{i-1}}$ e $F_{cont_{3D}z_{i+1}}$ são as parcelas provenientes das camadas i , $i - 1$ e $i + 1$, respectivamente. Sendo estas parcelas determinadas por

$$F_{cont_{3D}z_i}[x(s), y(s), z_i] = \left| DM - \sqrt{[x(s)_{z_i} - x(s-1)_{z_i}]^2 + [y(s)_{z_i} - y(s-1)_{z_i}]^2} \right| + \left| DM - \sqrt{[x(s)_{z_i} - x(s+1)_{z_i}]^2 + [y(s)_{z_i} - y(s+1)_{z_i}]^2} \right|, \quad (3.24)$$

$$F_{cont_{3D}z_{i-1}}[x(s), y(s), z_i] = \left| DM - \sqrt{[x(s)_{z_i} - x_{p_{z_{i-1}}}]^2 + [y(s)_z - y_{p_{z_{i-1}}}]^2 + d_z^2} \right|, \quad (3.25)$$

e

$$F_{cont_{3D}z_{i+1}}[x(s), y(s), z_i] = \left| DM - \sqrt{[x(s)_{z_i} - x_{p_{z_{i+1}}}]^2 + [y_z(s) - y_{p_{z_{i+1}}}]^2 + d_z^2} \right|, \quad (3.26)$$

em que DM é a distância média entre pontos do modelo 3D, $[x(s), y(s), z_i]$ são as coordenadas do ponto $[x(s), y(s)]$ da camada z_i , onde está sendo calculada a força $F_{cont_{3D}}$. Os pontos $[x_{p_{z_{i-1}}}, y_{p_{z_{i-1}}}]$ e $[x_{p_{z_{i+1}}}, y_{p_{z_{i+1}}}]$ são os pontos mais próximos de $[x(s), y(s)]$ nas camadas $i - 1$ e $i + 1$, respectivamente, e d_z é a distância entre as camadas no eixo z , ou espaçamento entre as imagens, sendo esta constante para cada aplicação. Vale ressaltar que $[x(s-1), y(s-1)]$ e $[x(s+1), y(s+1)]$ são os vizinhos do ponto $[x(s), y(s)]$ na camada z_i , sendo assim a parcela $F_{cont_{3D}z_i}$ não possui dz no cálculo.

Mostra-se na Figura 3.17 um exemplo dos pontos e distâncias envolvidas no cálculo das parcelas da força $F_{adap_{3D}}$ descrita na equação 3.23 tomando como referência um ponto C_i .

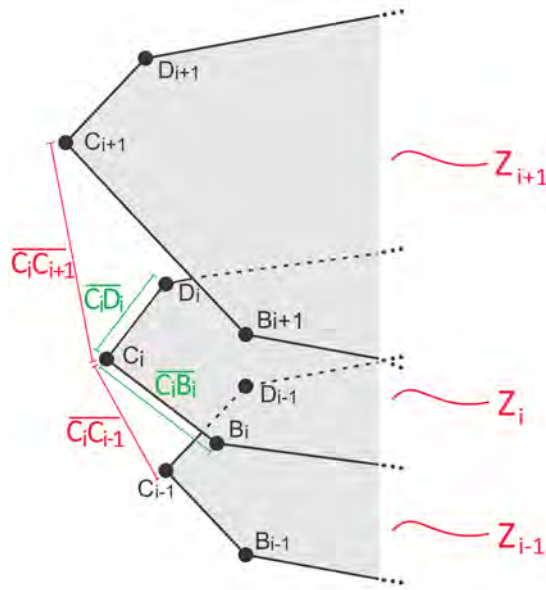


Figura 3.17: demonstração das distâncias utilizadas no cálculo da Força de Continuidade 3D, sendo as verdes as utilizadas em $F_{cont_{3D_i}}$ e as vermelhas em $F_{cont_{3D_{i-1}}}$ e $F_{cont_{3D_{i+1}}}$, em que i é a posição da curva no eixo z .

São demonstradas na Figura 3.17, em verde, as distâncias utilizadas na equação 3.24, que calcula a parcela proveniente dos vizinhos da camada i a qual o ponto C_i pertence. Já as distâncias do ponto C_i para os mais próximos nas camadas vizinhas são apresentadas em vermelho, sendo estas utilizadas nas equações 3.25 e 3.26, que calculam as parcelas provenientes das camadas vizinhas $i - 1$ e $i + 1$, respectivamente.

A resultante de cada uma das parcelas de $F_{cont_{3D}}$ utiliza a distância média entre pontos do modelo, inserido em cada parcela utilizando o parâmetro DM . Este parâmetro é utilizado como alvo das distâncias demonstradas, gerando forças que aumentam as distâncias menores do que DM e diminuem as distâncias maiores do que DM . Deste modo, a Força de Continuidade 3D tende a deixar as ligações do modelo igualmente espaçadas, considerando até mesmo as camadas vizinhas. A distância média DM deve ser atualizada a cada iteração, visto que ao mover os pontos do modelo, as distâncias entre os pontos são alteradas.

Força Balão Adaptativa 3D

A Força Balão Adaptativa 2D proposta na Seção 3.2 é chamada adaptativa devido seu comportamento de adaptar-se ao formato da curva, impulsionando os pontos da curva

em diversas direções distintas para fora do contorno. Esta força expande a área da curva impulsionando cada ponto em uma direção distinta, não possuindo limitações quanto à forma dos objetos de interesse. Esta força interna deforma o modelo para que este se aproxime das bordas após iterações sucessivas do método, funcionando até mesmo em regiões homogêneas da imagem, situação onde é mais importante, já que a força externa é nula e as únicas forças que interferem na curva são as forças internas.

Sabendo que a Força Balão Adaptativa 2D utiliza a topologia de cada ponto para movimentá-lo, então expandir esta curva para 3D é inserir informações das camadas vizinhas no cálculo desta força. Deste modo, esta força deve utilizar a topologia de 3 curvas para movimentar cada ponto, aumentando a convergência do mesmo em direção ao objeto de interesse, visto que as informações do objeto de interesse aumentam quando três curvas consecutivas são analisadas, sendo estas i , $i - 1$ e $i + 1$, em que i corresponde a camada onde está o ponto analisado.

Neste sentido, a Força de Continuidade 3D F_{adap3D} em um determinado ponto $[c(s)]$ pertencente à camada z_i , cujas coordenadas são $[x(s)_{z_i}, y(s)_{z_i}]$, é dada por

$$F_{adap3D}[c(s), z_i] = F_{adap3D_{z_i}}[c(s), z_i] + F_{adap3D_{z_{i-1}}}[c(s), z_i] + F_{adap3D_{z_{i+1}}}[c(s), z_i], \quad (3.27)$$

em que $F_{adap3D_{z_i}}$, $F_{adap3D_{z_{i-1}}}$ e $F_{adap3D_{z_{i+1}}}$ utilizam o ponto mais próximo de $c(s)$ nas camadas i , $i - 1$ e $i + 1$, respectivamente. Estas parcelas são determinadas por

$$F_{adap3D_{z_i}}[c(s), z_i] = \sqrt{|x(s)_{z_i} \pm x_{m_{z_i}}|^2 + |y(s)_{z_i} \pm y_{m_{z_i}}|^2}, \quad (3.28)$$

$$F_{adap3D_{z_{i-1}}}[c(s), z_i] = \sqrt{|x(s)_{z_i} \pm x_{p_{z_{i-1}}}|^2 + |y(s)_{z_i} \pm y_{p_{z_{i-1}}}|^2}, \quad (3.29)$$

e

$$F_{adap3D_{z_{i+1}}}[c(s), z_i] = \sqrt{|x(s)_{z_i} \pm x_{p_{z_{i+1}}}|^2 + |y(s)_{z_i} \pm y_{p_{z_{i+1}}}|^2}, \quad (3.30)$$

em que o ponto $[x_{m_{z_i}}, y_{m_{z_i}}]$ é o ponto médio dos vizinhos do ponto $c(s)$ na camada i do eixo z , visto que são da mesma camada, enquanto os pontos $[x_{p_{z_{i-1}}}, y_{p_{z_{i-1}}}]$ e $[x_{p_{z_{i+1}}}, y_{p_{z_{i+1}}}]$ são os pontos mais próximos da camada $i - 1$ e da camada $i + 1$ do eixo z , respectivamente. Os pontos $[x_{p_{z_{i-1}}}, y_{p_{z_{i-1}}}]$ e $[x_{p_{z_{i+1}}}, y_{p_{z_{i+1}}}]$ são os mesmos utilizados no cálculo da Força de Continuidade 3D descritos na equação 3.23. Os sinais da equação 3.28 são positivos quando o ponto médio $[x_{m_{z_i}}, y_{m_{z_i}}]$ é interno à curva c da camada z , e negativo, caso contrário. Já os sinais das equações 3.29 e 3.30 são definidos pelos pontos $[x_{p_{z_{i-1}}}, y_{p_{z_{i-1}}}]$ e $[x_{p_{z_{i+1}}}, y_{p_{z_{i+1}}}]$, respectivamente. Deste modo, os sinais são positivos quando estes pontos estão internos à curva c da camada i e negativos, caso contrário.

O princípio da Força Adaptativa 3D é o mesmo do utilizado em 2D, em que a curva se expande baseada em duas informações para o cálculo da energia de cada ponto. A

primeira é determinada pelos pontos mais próximos da curva quando se trata das camadas vizinhas, $i + 1$ e $i - 1$, e determinada pelo ponto médio dos vizinhos quando se trata da mesma camada i do eixo z . Estes pontos são analisados expulsando ou atraindo este ponto de acordo com a análise destes, utilizando a solução sugerida por BERG et al. (1975), definindo se este ponto está dentro ou fora da curva.




Figura 3.18: demonstração das parcelas da Força Balão Adaptativa 3D $F_{M_{B_i D_i}}$, $F_{C_{i-1}}$ e $F_{C_{i+1}}$ provenientes das camadas i , $i - 1$ e $i + 1$, respectivamente, em que i é a posição da curva no eixo z

Um exemplo de atuação das parcelas da força $F_{adap_{3D}}$ atuando sobre um determinado ponto C_i , descrita na equação 3.27, é apresentado na Figura 3.18. Nesta Figura, tem-se que a primeira parcela definida na equação 3.28 utiliza o ponto médio dos seus vizinhos $M_{B_i D_i}$, apresentado em vermelho na Figura, obtido através da média de seus pontos vizinhos B_i e D_i . Analisando este ponto através do Teorema da Curva de Jordan (BERG et al., 1975), tem-se que este é dito como ponto interno da camada i , resultando na força $F_{M_{B_i D_i}}$ mostrada em amarelo na Figura 3.18.

A segunda e a terceira parcela da força $F_{adap_{3D}}$ são obtidas a partir dos pontos mais

próximos das camadas vizinhas, utilizando as equações 3.29 e 3.30. A equação 3.29 define a parcela proveniente da camada $i - 1$, utilizando o ponto mais próximo do ponto C_i definido na Figura 3.18 sendo o ponto C_{i-1} . Este ponto é analisado através do Teorema da Curva de Jordan (BERG et al., 1975), alterando o sinal da equação 3.29 para positivo, empurrando o ponto C_i , conforme apresenta a força $F_{C_{i-1}}$ mostrada em verde, já que o mesmo está interno à curva da camada i . Analogamente, a equação 3.30 utiliza o ponto C_{i+1} nos cálculos visto que este é o mais próximo de C_i na camada $i + 1$. Na Figura 3.18 este ponto está interno à curva da camada i , alterando o sinal da equação 3.30 para positivo, o que faz com que a força $F_{C_{i+1}}$, visualizada em azul na Figura 3.18, empurre o ponto C_i .

3.3.2 Energia Externa Crisp Adaptativa 3D

A energia externa Crisp Adaptativa 3D expande a energia externa Crisp Adaptativa 2D para três dimensões, utilizando informações das camadas imediatamente superior e inferior. Assim como a energia externa em 2D, esta nova energia 3D é baseada na Análise das Densidades Pulmonares da vizinhança de um *pixel* juntamente com uma RNA MLP que determina a origem das bordas encontradas na energia externa Tradicional.

Neste sentido, a energia externa Tradicional é expandida para 3D e, posteriormente, a energia externa Crisp Adaptativa 3D é descrita utilizando esta energia externa Tradicional 3D.

Energia Externa Tradicional 3D

A energia externa dos métodos de contornos ativos corresponde às informações provenientes da imagem, e é comum a utilização do operador Sobel para calcular esta energia. Isto se deve ao conjunto de informações geradas sobre os objetos presentes na imagem, em que este operador quantifica pontos, linhas e bordas de objetos utilizando pouco processamento já que emprega-se uma convolução 2D na imagem.

Nesta tese, é adotada a formulação matemática de uma máscara por

$$M = \begin{bmatrix} M_{-1,-1} & M_{0,-1} & M_{+1,-1} \\ M_{-1,0} & M_{0,0} & M_{+1,0} \\ M_{-1,+1} & M_{0,+1} & M_{+1,+1} \end{bmatrix}. \quad (3.31)$$

em que o elemento de referência é $M_{0,0}$, presente na segunda linha e segunda coluna da máscara, em que todos os outros elementos utilizam este para definir seus índices de

posição dentro da máscara. Utilizando esta formulação, o resultado R da aplicação de uma máscara M em um *pixel* de coordenadas (x, y) de uma imagem I é dado por

$$R(x, y) = \sum_{i=-1}^1 \sum_{j=-1}^1 I(x+i, y+j) \times M(i, j). \quad (3.32)$$

A aplicação desta expressão método em todos os *pixels* da imagem I gera a convolução 2D da máscara M na imagem I . Neste sentido, o operador gradiente Sobel utiliza duas máscaras para aproximar seu cálculo, sendo estas (GONZALEZ; WOODS, 2010)

$$s_h = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad e \quad s_v = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \quad (3.33)$$

em que s_h e s_v detectam objetos ou transições na horizontal e na vertical, respectivamente. Adotando a formulação apresentada na equação 3.31, tem-se, por exemplo, que o elemento $M_{-1,-1}$ é -1 em s_h e s_v , enquanto $M_{0,-1}$ é -2 e 0 em s_h e s_v , respectivamente. Deste modo, aplicando a máscara s_v sobre um *pixel* de coordenadas (x, y) de uma imagem I tem o resultado $R_{s_v}(x, y)$ dado por

$$R_{s_v}(x, y) = \sum_{i=-1}^1 \sum_{j=-1}^1 I(x+i, y+j) \times s_v(i, j), \quad (3.34)$$

enquanto aplicando a máscara s_h tem-se o resultado $R_{s_h}(x, y)$ dado por

$$R_{s_h}(x, y) = \sum_{i=-1}^1 \sum_{j=-1}^1 I(x+i, y+j) \times s_h(i, j) \quad (3.35)$$

Utilizando os elementos $R_{s_v}(x, y)$ e $R_{s_h}(x, y)$, o resultado do operador gradiente Sobel $G(x, y)$ em um *pixel* de coordenadas (x, y) em uma imagem I é dado por

$$G(x, y) = \sqrt{R_{s_v}(x, y)^2 + R_{s_h}(x, y)^2} \quad (3.36)$$

Deste modo, quando um MCA utiliza o gradiente Sobel como energia externa tradicional 2D $E_{ext_{2D}}$, então esta é dada por

$$E_{ext_{2D}}[x(s), y(s), z_i(s)] = G(x, y), \quad (3.37)$$

em que z_i corresponde ao plano a qual as coordenadas x e y pertencem, ou seja, é a camada à qual o *pixel* $I(x, y)$ pertence. Esta inserção do termo z_i neste momento é apenas para identificar a qual camada do exame esta imagem corresponde, sendo este valor constante para cada imagem. Esta notação é importante para fundamentação matemática da energia externa 3D, posteriormente.

Neste sentido, a expansão da energia externa Tradicional para 3D consiste em inserir informações das camadas vizinhas em seu cálculo. Esta formulação tende a aumentar a relevância de um objeto que está presente em todas as camadas analisadas, e a diminuir a importância daqueles que estão presentes em apenas uma camada, podendo ser caracterizado por ruído. Esta análise 3D aumenta a convergência da curva de um MCA em direção ao objeto já que diminui a importância de objetos que não são relevantes em várias camadas.

Neste sentido, a energia externa 3D $E_{ext_{3D}}$ de um ponto $m(s)$ de coordenadas $[x(s), y(s), z_i]$ é dada por

$$E_{ext_{3D}}[x(s), y(s), z_i] = E_{ext_{2D}}[x(s), y(s), z_{i-1}] + E_{ext_{2D}}[x(s), y(s), z_i] + E_{ext_{2D}}[x(s), y(s), z_{i+1}], \quad (3.38)$$

em que $E_{ext_{2D}}[x(s), y(s), z_{i-1}]$, $E_{ext_{2D}}[x(s), y(s), z_i]$ e $E_{ext_{2D}}[x(s), y(s), z_{i+1}]$ são as energias externas correspondentes a análise das bordas presentes na vizinhança do ponto $[x(s), y(s)]$ nas camadas $i - 1$, i e $i + 1$, respectivamente. A vizinhança analisada para compor a força $E_{ext_{3D}}[m(s)]$ é ilustrada na Figura 3.19, em que o ponto $m(s)$ é apresentado em vermelho.




Figura 3.19: vizinhança de um ponto central analisada para compor a energia externa 3D de um ponto $m(s)$, apresentado em vermelho.

Analisando a Figura 3.19, conclui-se que a energia externa 3D proposta nesta tese analisa as mesmas posições x e y em camadas i distintas no eixo z , gerando uma análise em três dimensões.

Energia Externa Crisp Adaptativa 3D

A energia externa Crisp Adaptativa 3D (CRAD 3D) detecta a origem das bordas dos pulmões, expandindo a energia externa Crisp Adaptativa 2D, descrita na equação 3.8, para três dimensões. Esta energia em 2D é baseada na Análise das Densidades Pulmonares

da vizinhança de um *pixel* juntamente com uma RNA MLP que determina a origem das bordas encontradas na energia externa tradicional.

Analogamente, a energia externa Crisp Adaptativa 3D verifica a vizinhança de um *voxel* juntamente com uma RNA MLP para determinar a origem das bordas encontradas na energia externa tradicional 3D. Primeiramente são calculados os percentuais de 6 classes v_i em uma vizinhança 3D, em que i varia de 0 a 5, sendo estas: hiperaeradas (−1000 a −950 UH), normalmente aeradas (−950 a −500 UH), pouco aeradas (−500 a −100 UH), não aeradas (−100 a 100 UH), osso (600 a 2000 UH) e áreas não classificadas, que são as densidades que não se enquadram nas demais.

A partir da definição destas classes, um exame T de TC do tórax é considerado, em que este é um conjunto de imagens sobrepostas em sequência. Este exame T possui dimensões $l \times c \times a$, sendo $l \times c$ as dimensões de uma imagem e a a quantidade de imagens.

Considerando um *voxel* de coordenadas (x, y, z) , tem-se que a função que determina a quantidade de pontos com densidades presente em cada classe v_i é determinada por

$$f(x, y, z, v_i) = \sum_{l=-n}^n \sum_{m=-n}^n \sum_{o=-n}^n R(x-l, y-m, z-o), \quad (3.39)$$

em que n é o número que define a vizinhança analisada e $R(x, y, z)$ é dado por

$$R(x, y, z) = \begin{cases} 1, & \lim_{inf}(v_i) < T(x, y, z) < \lim_{sup}(v_i), \\ 0, & \text{caso contrário,} \end{cases} \quad (3.40)$$

os quais $\lim_{inf}(v_i)$ e $\lim_{sup}(v_i)$ são os limites inferior e superior da faixa de densidade, em UH, para a classe v_i .

Utilizando a equação 3.39, torna-se possível calcular o percentual P_{i3D} de cada classe i por

$$P_{i3D}(x, y, z) = \frac{f(x, y, z, v_i)}{\sum_{j=0}^4 f(x, y, z, v_j)}. \quad (3.41)$$

A classe 5 é desconsiderada, pois esta representa áreas não classificadas, assim como no método 2D.

Um exemplo de vizinhança é mostrado na Figura 3.19, em que uma vizinhança com n igual a 3 é definida, gerando um cubo $3 \times 3 \times 3$, em que o *voxel* central, apresentado em vermelho, possui as coordenadas (x, y, z) sendo este analisado pela equação 3.39.

Após testes exaustivos, conclui-se que, à medida que n aumenta, a qualidade da detecção também aumenta, visto que o tamanho da vizinhança é proporcional a n . Entretanto, observa-se que um valor acima de 7 aumenta o tempo de processamento, sem melhoras significativas no resultado, sendo este o valor de n adotado nesta tese.

De forma análoga ao método 2D, esta nova energia externa 3D incorpora uma RNA MLP para determinar a origem de cada borda encontrada em exames de TC do tórax. As entradas desta MLP são os 6 percentuais das classes s_i encontradas pelo método ADP utilizando a equação 3.39, possuindo uma camada oculta com 4 neurônios e uma saída. Deste modo, a topologia gerada é 6/4/1, conforme determina a equação 3.6.

A saída da rede MLP indica se uma borda encontrada em imagens de TC do tórax é ou não é parede pulmonar. Neste sentido, uma base de dados é construída a partir de percentuais extraídos de *voxels* de exames de pacientes com DPOC, fibrose e de voluntários sadios nas posições de ápice, hilo e base dos pulmões em imagens de TC do tórax.

O conjunto de dados é construído manualmente, buscando obter uma maior representação possível das estruturas do pulmão. Nesta etapa, são usados 10 exames completos de TC do tórax, totalizando aproximadamente 5.000 imagens. São extraídos os percentuais $P_{i_{3D}}$ de aproximadamente 500 *voxels* de cada imagem. Cada conjunto de entrada destes percentuais é rotulado, indicando qual das bordas encontradas na energia externa Tradicional 3D são de paredes pulmonares e quais não são. Ressaltando que a energia externa Tradicional 3D é calculada utilizando o operador Sobel através de uma análise 3D. Assim como o método 2D, este conjunto de dados é validado pelo método de validação cruzada (HAYKIN, 1999).

Após treinar a rede MLP, tem-se que em sua fase de execução a saída desta é dada pela função

$$f_{mlp_{3D}}(v) = \begin{cases} 1, & \text{quando a borda detectada constituir a parede pulmonar,} \\ 0, & \text{caso contrário.} \end{cases} \quad (3.42)$$

em que \mathbf{v} é composto pelos 6 percentuais $P_{i_{3D}}$, em que i varia de 0 a 5.

Utilizando $f_{mlp_{3D}}$ para determinar a origem das bordas encontradas em imagens de TC do tórax, tem-se que a energia externa $E_{ext_{CRAD_{3D}}}$, definida na equação 3.20, dada por

$$E_{ext_{CRAD_{3D}}}(x, y, z) = \begin{cases} E_{ext_{3D}}(x, y, z), & \text{para } f_{mlp_{3D}}(v) = 1, \\ 1, & \text{caso contrário,} \end{cases} \quad (3.43)$$

em que $E_{ext_{3D}}(x, y, z)$ é a energia externa Tradicional 3D, demonstrada anteriormente, e v é o vetor de percentuais do método ADP 3D obtidos pela equação 3.39 utilizando as coordenadas (x, y, z) do *voxel* analisado.

Aplicando a equação 3.43, a RNA MLP determina as paredes que são bordas pulmonares retornando valor 1 através da função $f_{mlp_{3D}}$. Já quando esta função retorna valor 0, indica que não é uma borda pulmonar, então esta região recebe o valor máximo da

energia Crisp Adaptativa para que o ponto saia desta região ao minimizar esta energia. Ressalta-se que esta energia é proveniente da análise de camadas consecutivas, diminuindo a importância de pequenos objetos que estejam presentes em apenas uma camada.

3.3.3 Visualização 3D

O sistema de visualização gráfica utilizado nesta tese utiliza a API *Open Graphics Library* (OpenGL). Esta API é uma especificação aberta e multiplataforma de uma biblioteca de rotinas gráficas e de modelagem, ou API (Application Programming Interface), utilizada para o desenvolvimento de aplicações de Computação Gráfica, tais como jogos e sistemas de visualização (ASTLE; HAWKINS, 2009).

A OpenGL é extremamente eficiente, uma vez que muitos dos seus algoritmos são implementados em hardware nas placas gráficas mais modernas (ASTLE; HAWKINS, 2005). Seu funcionamento é semelhante ao de uma biblioteca C, uma vez que fornece uma série de funcionalidades. Normalmente se diz que um programa é baseado em OpenGL ou é uma aplicação OpenGL, o que significa que é escrito em alguma linguagem de programação que faz chamadas a uma ou mais bibliotecas OpenGL. As aplicações OpenGL variam de ferramentas CAD a programas de modelagem usados para criar personagens para o cinema, tal como um dinossauro (ASTLE; HAWKINS, 2005).

Além do desenho de primitivas gráficas, tais como linhas e polígonos, OpenGL dá suporte a iluminação, colorização, mapeamento de textura, transparência, animação, entre muitos outros efeitos especiais. Atualmente, OpenGL é reconhecida e aceita como um padrão API para desenvolvimento de aplicações gráficas 3D em tempo real (COHEN; MANSSOUR, 2006).

Esta tese utiliza duas bibliotecas que constituem a OpenGL, a GLU e a GLUT, ambas *open source*. A GLU (OpenGL Utility Library) contém várias rotinas que utilizam os comandos OpenGL de baixo nível para executar tarefas como, por exemplo, definir as matrizes para projeção e orientação da visualização, e fazer a renderização de uma superfície (COHEN; MANSSOUR, 2006). Já a GLUT (OpenGL Utility Toolkit) é um toolkit independente de plataforma, que inclui alguns elementos de interface gráfica (ASTLE; HAWKINS, 2005).

Neste sentido, as rotinas utilizadas no desenvolvimento do sistema de visualização 3D desta tese são desenvolvidas em Linguagem C/C++, e fazem chamadas às rotinas da biblioteca OpenGL. A biblioteca GLU é chamada para renderizar objetos, configurar sua aparência e sua iluminação. Já a biblioteca GLUT é usada para criar janelas e receber os

comandos do usuário, em que este sistema de visualização é multiplataforma.

Para modelar os objetos em 3D esta tese assumiu a estrutura destes dados sendo um bloco de dados 2D empilhados. Considerando que os dados 2D são imagens, têm-se que os dados em 3D são blocos de imagens empilhadas. Estas imagens possuem um espaçamento entre as mesmas, e este depende de cada aplicação.

No caso específico das imagens de TC, o espaçamento entre imagens, ou entre planos, é uma das propriedades armazenadas no padrão DICOM, definido pela propriedade *Slice Thickness*. O tamanho de um pixel também é específico em cada aplicação quando estas imagens são modeladas em 3D, e no padrão DICOM este é determinado pela propriedade *Pixel Spacing*. Utilizando estes dois parâmetros é possível reconstruir o exame de TC na mesma escala que foi gerado.

Considerando que cada plano representa uma imagem, então cada um dos planos pode ter uma curva, representado por um determinado polígono. Como já visto anteriormente, estas curvas são formadas por pontos e por conexões destes com seus vizinhos. Neste sentido, a Figura 3.20 ilustra a estrutura de dados adotada neste modelo, em que cada plano possui uma curva composta por pontos interligados. Nesta Figura, os pontos são apresentados em vermelho, e as conexões entre os mesmos estão em verde.




Figura 3.20: demonstração da base da estrutura de dados em 3D, em que cada plano possui uma curva, apresentada em verde, gerada a partir de pontos, mostrados em vermelho.

Para renderizar os objetos em 3D, faz-se necessário que pontos pertencentes a cada plano conecte-se às outras camadas, e não somente aos pontos vizinhos de sua camada de origem, conforme utilizado na estrutura de dados do método 2D. Deste modo, cada ponto de uma camada conecta-se aos dois pontos mais próximos na camada imediatamente superior. Esta operação gera uma malha ligando todas as camadas através de linhas traçadas entre as mesmas. A Figura 3.21 apresenta um exemplo destas conexões, em que as linhas entre pontos de uma mesma camada é impressa em verde, e as as linhas

formadas a partir de pontos de camadas distintas estão em vermelho.

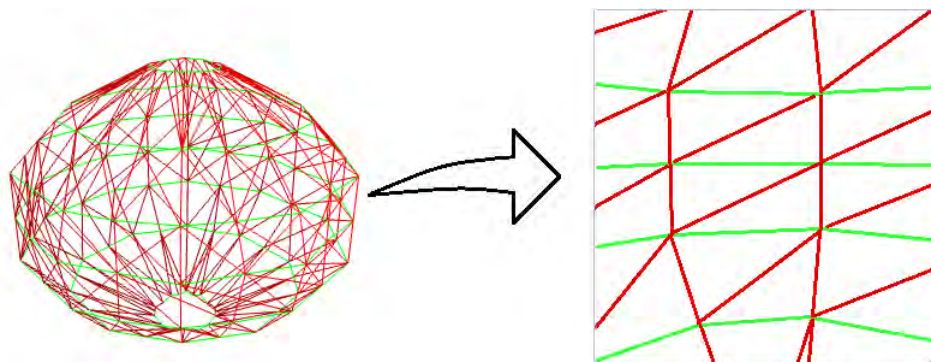


Figura 3.21: estrutura de dados 3D, em que seus pontos conectam-se aos pontos mais próximos da camada superior através de linhas, apresentadas em vermelho, e aos pontos da mesma camada com linhas impressas em verde.

Para completar a renderização proposta nesta tese, a malha apresentada na Figura 3.21 é utilizada para gerar as superfícies do objeto 3D. Estas superfícies são geradas por triângulos, em que cada triângulo é formado por dois pontos vizinhos de uma camada e o ponto mais próximos destes na camada superior. Isto pode ser visto no exemplo de objeto gerado por esta operação é apresentado na Figura 3.22.




Figura 3.22: superfície 3D de um objeto.

As propriedades como cor, iluminação, textura, inclusive a transparência desta superfície podem ser configuradas aproximando os objetos gerados da realidade, usando-se para tanto a biblioteca OpenCV.

Resumidamente, tem-se que a visualização 3D para renderizar objetos utiliza três etapas distintas: sobrepor as curvas presentes em cada imagem, conectar os pontos de

camadas distintas formando triângulos e gerar superfícies a partir destes triângulos, que são ilustradas na Figura 3.23.




Figura 3.23: etapas de renderização, a) sobreposição de curvas presentes em cada imagem; b) conexão de pontos de camadas distintas gerando triângulos; e c) superfície renderizada.

3.3.4 Inicialização do modelo 3D

O método de inicialização do modelo em 2D proposto na Seção 3.2.3 consiste em determinar um ponto de coordenadas (x_{ini}, y_{ini}) , em que este é usado como baricentro de um polígono regular com raio e quantidade de pontos configurável. Este método gera um polígono que se aproxima de um círculo à medida que aumenta a quantidade de pontos do polígono regular.

De forma análoga, o modelo 3D consiste em determinar um ponto de inicialização PI de coordenadas $(x_{ini}, y_{ini}, z_{ini})$, em que este é usado como centro do modelo 3D, com quantidade de pontos e distância destes para o centro configurável. Deste modo, este método constrói um modelo 3D esférico a partir deste centro, em que a distância deste centro para todos os pontos do modelo é constante.

Para construir esse modelo, as curvas de cada camada são inicializadas separadamente, porém todas as camadas seguem o mesmo padrão. Deste modo, todas as camadas utilizam a inicialização proposta pelo método 2D, em que o ponto de coordenadas (x_{ini}, y_{ini}) é usado como baricentro de um polígono regular, em que estas coordenadas são as mesmas para todos os pontos, resultando em várias curvas sobrepostas, sendo cada uma inicializada em uma camada distinta.

O que muda em cada uma das curvas inicializadas é a distância entre cada ponto e

o baricentro, visto que, no modelo 3D, deve-se manter a distância entre todos os pontos do modelo para o centro do modelo constante. Considerando que todas as camadas têm muitos pontos, o modelo deve ser esférico. Neste sentido, a Figura 3.24 apresenta duas curvas presentes em camadas distintas, na qual a distância entre cada ponto, apresentados em vermelho, para o centro do modelo é dada por R , a linha azul apresenta o baricentro utilizado em todas as camadas e r é o raio da camada separada por uma distância d_z do plano z_{ini} do centro I do modelo considerando apenas o eixo z .




Figura 3.24: definições de variáveis do modelo 3D de inicialização.

Analisando a Figura 3.24, observa-se que cada camada possui uma distância dos pontos para o seu baricentro distinta. Deste modo, considerando a camada z_{ini} , à qual pertence o centro do modelo, tem-se que a distância do baricentro para cada ponto é o próprio valor R . Já quando a curva é em outra camada, a distância dos pontos para o baricentro é um valor menor que R , e este valor diminui à medida que o valor d_z aumenta.

Desse modo, faz-se necessário calcular o valor r de cada camada para ser utilizado como distância dos pontos para o baricentro. Considerando a geometria em destaque na Figura 3.24 e aplicando o Teorema de Pitágoras, então o valor de r em relação à R e d_z é dado por

$$r = \sqrt{R^2 - d_z^2}, \quad (3.44)$$

em que R é configurável e d_z é a distância entre camadas ou espessura da fatia, sendo constante para cada aplicação.

Este método percorre camada por camada calculando a distância r da camada em análise e inicializa a curva usando o baricentro pré-definido para gerar o polígono regular. Ressalta-se que apenas as camadas com r maior que 1 *pixel* são inicializadas, visto que a distância é positiva. Dois exemplos de inicialização do modelo 3D são mostrados na

Figura 3.25, em que a Figura 3.25(a) apresenta uma inicialização utilizando 30 *pixels* como distância R , obtendo inicialização em 7 camadas, enquanto a Figura 3.25(b) apresenta uma inicialização com R igual a 50 *pixels*, obtendo inicialização em 11 camadas.




Figura 3.25: inicialização do modelo 3D, a) 7 camadas e $R = 30$ e b) 11 camadas e $R = 50$.

3.3.5 Inicialização automática do MCA Crisp Adaptativo 3D

A inicialização automática do modelo 3D dentro dos pulmões consiste em determinar os pontos de inicialização para os pulmões direito e esquerdo, PID_{3D} e PIE_{3D} , respectivamente. Cada um destes pontos é formado pelas coordenadas $(x_{ini}, y_{ini}, z_{ini})$. Para isto, todas as imagens do exame de TC presentes no modelo 3D são analisadas pelo método de inicialização 2D para determinar os pontos de inicialização automática. O valor da coordenada z de todas as fatias que encontraram uma inicialização automática em 2D com sucesso são armazenadas para determinar qual fatia será usada para inicialização posteriormente.

Neste sentido, a coordenada média das fatias armazenadas previamente é adotada como z_{ini} e as coordenadas (x_{ini}, y_{ini}) obtidas pelo método 2D desta fatia completam as coordenadas de inicialização dos pontos PID_{3D} e PIE_{3D} . Deste modo, este método tende a iniciar o modelo 3D em cada um dos pulmões de forma centralizada dentro dos pulmões.

O modelo 3D inicializado neste método obedece à estrutura descrita na Seção 3.3.4. Sendo assim, as coordenadas $(x_{ini}, y_{ini}, z_{ini})$ de PID_{3D} e PIE_{3D} são os pontos adotados como centro dos modelos 3D do pulmão direito e esquerdo, respectivamente.

Cada um dos modelos é configurado utilizando dois parâmetros, a quantidade de pontos e a distância de cada ponto para o centro, conforme descrito na Seção 3.3.4.

Sendo assim, a Figura 3.26 apresenta um exemplo de inicialização automática do modelo 3D, em que os pontos PID_{3D} e PIE_{3D} são calculados em um exame de 900 imagens. Esta inicialização ocupa 15 fatias, utilizando 30 pontos em cada camada e distância de 30 *pixels* entre cada ponto e o centro de cada modelo, sendo estes os pontos de inicialização PID_{3D} e PIE_{3D} para os modelos 3D esquerdo e direito, respectivamente. Estes modelos são coloridos com uma cor aproximada do pulmão e são mostrados na Figura 3.26(a) e a Figura 3.26(b) apresentada um dos modelos ampliado.

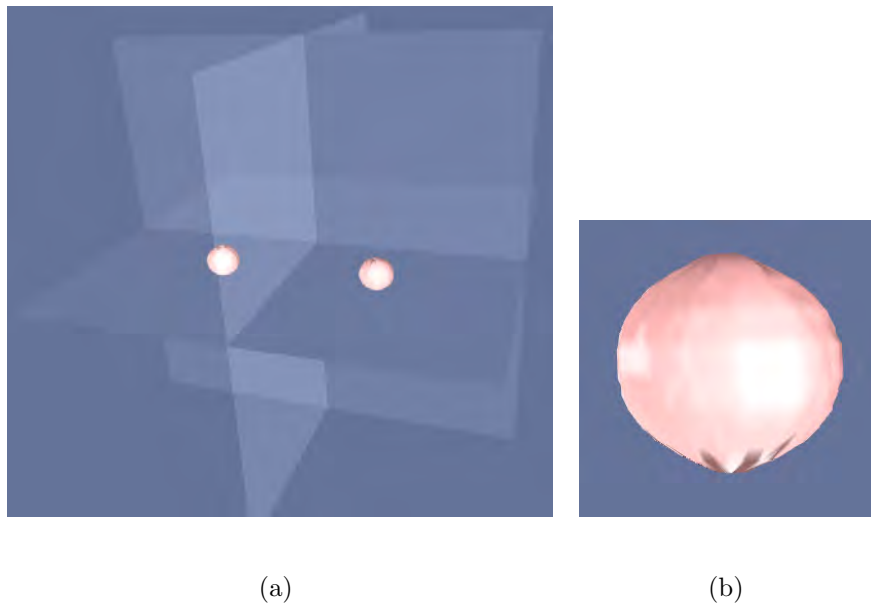


Figura 3.26: inicialização automática do modelo 3D dentro dos pulmões, a) inicialização de ambos os pulmões e b) um dos modelos ampliado.

3.3.6 Locomoção, Adição e Remoção de pontos dos MCA Crisp Adaptativo 3D

A dinâmica de deslocamento, adição e remoção de pontos do MCA em 3D é semelhante à dinâmica do MCA em 2D. Neste sentido, o deslocamento dos pontos continua sendo o mesmo adotado no método 2D, em que uma vizinhança ímpar é analisada, e as coordenadas do ponto que gerar uma menor energia E_{3D} nesta vizinhança, é definida como novas coordenadas deste ponto, ou seja, suas coordenadas são atualizadas para o ponto de menor energia. O MCA Crisp Adaptativo 3D utiliza a energia $E_{CA_{3D}}$ calculada pela equação 3.20.

Ilustra-se na Figura 3.27 uma vizinhança 3×3 de um ponto $c(s)$ pertencente a uma camada i considerando o eixo z . As camadas $i - 1$ e $i + 1$ são usadas apenas para o

cálculo das energias em 3D listadas para compor as parcelas da energia total do MCA Crisp Adaptativo 3D ($E_{CA_{3D}}$). Deste modo, o deslocamento de um ponto pertencente a uma determinada camada z_i será apenas nesta camada. Assim, surge a necessidade de adicionar pontos não apenas entre vizinhos distantes de uma mesma camada, mas também de adicionar pontos em camadas vizinhas. Isto se faz necessário para que o modelo 3D possa detectar um objeto que está presente em várias camadas, e inicialmente nem todas as camadas possuem uma curva para segmentar o objeto.




Figura 3.27: Demonstração da análise de uma vizinhança 3×3 para movimentar um ponto $c(s)$ pertencente a camada i , em que as camadas $i - 1$ e $i + 1$ apenas são utilizadas para cálculo do deslocamento, adição e remoção de pontos.

Para tanto, a adição de pontos ocorre através de dois métodos distintos. O primeiro adiciona pontos entre vizinhos de uma mesma camada que possuam uma distância maior do que a máxima permitida. O MCA Crisp Adaptativo 3D utiliza a Adição Adaptativa, descrita na Seção 3.2.4, que otimiza a adição de pontos dentro dos pulmões em imagens de TC do tórax.

Já o segundo método adiciona pontos entre camadas vizinhas. Este método analisa as curvas presentes em duas camadas, a primeira e a última do modelo 3D. Esta análise é baseada no perímetro destas curvas, em que um perímetro máximo (P_{max}) é configurado inicialmente, e este método adiciona uma nova curva sempre que uma destas curvas citadas ultrapassa o valor de P_{max} pré-definido.

Considerando que a primeira camada esteja na camada f e a última esteja na camada l , então quando a primeira camada possuir um perímetro maior do que P_{max} , uma nova curva é adicionada na camada $f - 1$. Entretanto, quando a última camada do modelo possuir um perímetro maior que P_{max} , uma nova camada é adicionada em $l + 1$. Esta nova camada é adicionada utilizando o centróide da curva em análise como referência, em que para adicionar uma camada em $f - 1$ utiliza-se o centróide de f e para adicionar uma

camada em $l + 1$ utiliza-se o centróide de l .

A Figura 3.28 ilustra a aplicação deste método utilizando o perímetro máximo P_{max} sendo 30 e os parâmetros de inicialização assumindo 10 o valor como distância de cada ponto para o baricentro e 30 como a quantidade de vértices. Na Figura 3.28(a), as camadas inferior e superior possuem perímetro maior do que P_{max} , e a Figura 3.28(b) apresenta a visualização deste modelo com vista interna para a camada superior. Os resultados da aplicação do método de adição de pontos nas camadas superior e inferior são apresentados nas Figuras 3.28(c) e 3.28(d), ilustrando a vista externa e interna do modelo respectivamente, após a adição de pontos.

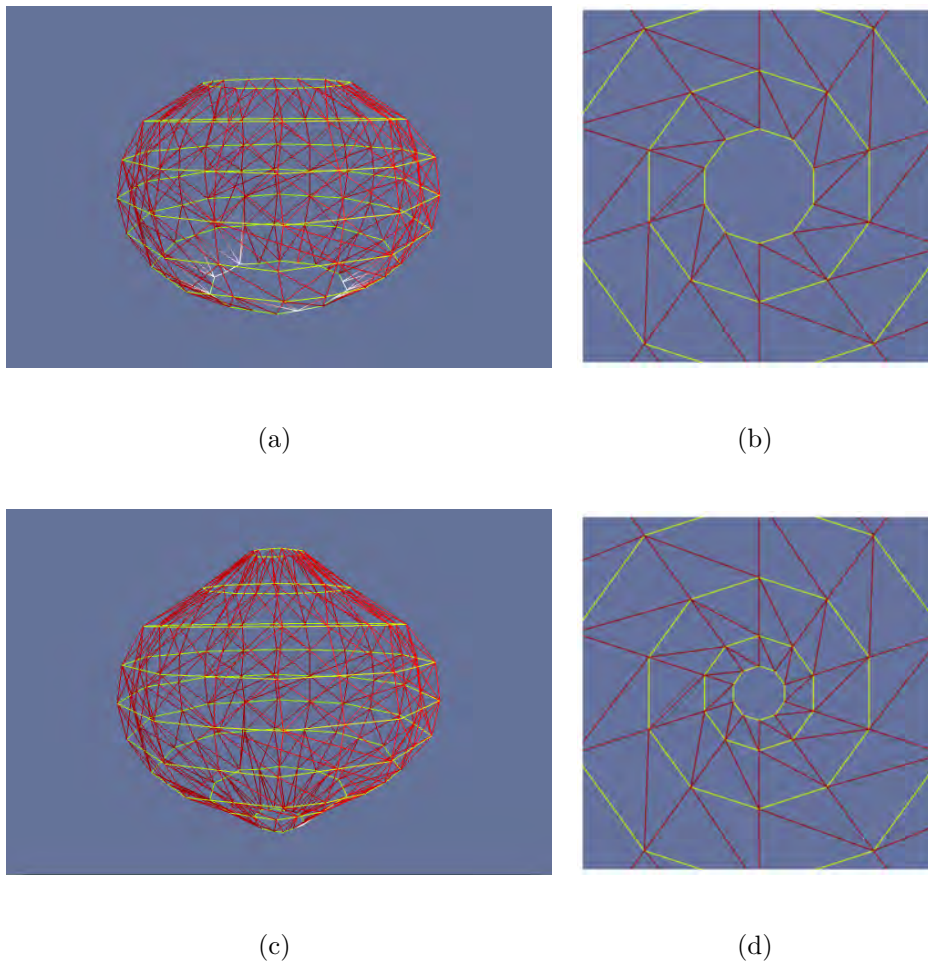


Figura 3.28: adição de camadas no modelo 3D, a) modelo 3D com área maior que a configurada na primeira e na última fatia; b) vista da camada superior de a); c) modelo 3D com novas camadas; e d) vista da camada superior de c).

Outro método importante na dinâmica do MCA Crisp Adaptativo 3D é a remoção de pontos. Analogamente ao método de adição de pontos, esta etapa também baseia-se em duas técnicas. A primeira é a mesma do MCA 2D proposto na Seção 3.2, em que um

ponto pertencente a uma camada z_i é analisado utilizando o ângulo formado entre este e seus vizinhos nesta camada, e caso este ângulo seja inferior a um ângulo previamente configurado, este ponto é apagado da curva e esta é reordenada. Este método exclui da curva os pontos que estão defasados dos seus vizinhos.




Figura 3.29: demonstração dos parâmetros para cálculo do ângulo formado entre um ponto da camada i com os seus mais próximo nas camadas $i - 1$ e $i + 1$, em que a) e b) demonstram a formação dos ângulos θ_1 e θ_2 , respectivamente.

O segundo método utiliza o mesmo princípio de apagar os pontos defasados dos seus vizinhos, porém expandindo este método para 3D. Isto é possível utilizando os pontos

mais próximos nas camadas vizinhas. Deste modo, considerando um ponto pertencente a camada z_i , são utilizados o ponto mais próximo da camada z_{i-1} e o ponto mais próximo da camada z_{i+1} , conforme é demonstrado na Figura 3.29 pelos pontos C_i , C_{i-1} e C_{i+1} pertencentes as camadas i , $i - 1$ e $i + 1$, respectivamente.

A análise para remoção de pontos em 3D deste método é baseada no ângulo formado entre estes pontos, e comparado com um ângulo mínimo θ_{min} pré-configurado. O ponto analisado é apagado quando o ângulo formado entre este e os mais próximos nas camadas vizinhas é menor do que θ_{min} . Considerando o modelo apresentado na Figura 3.29, tem-se o ponto C_i formando um ângulo θ com C_{i-1} e C_{i+1} , em que estes são os mais próximos na camada $i - 1$ e $i + 1$, respectivamente.

Comparando o ângulo θ_1 mostrado na Figura 3.29(a) com o ângulo θ_2 da Figura 3.29(b), conclui-se que θ_1 é maior que θ_2 . Isto ocorre devido C_i estar menos alinhado à C_{i-1} e C_{i+1} na formação de θ_2 , o que não ocorre na formação de θ_1 .

O ângulo θ formado entre um ponto e os seus mais próximos das camadas vizinhas é dado por

$$\theta = \arccos \left(\frac{a^2 + b^2 - c^2}{2bc} \right). \quad (3.45)$$

em que a , b e c são mostrados na Figura 3.29.

Deste modo, os métodos de remoção tendem a excluir os pontos desalinhados dos demais, seja desalinhado de seus vizinhos em uma mesma camada ou desalinhado das curvas presentes nas camadas vizinhas. Isto torna o modelo mais suave e evita erros grosseiros na segmentação em 3D.

3.3.7 Segmentação automática dos pulmões em exames de TC do tórax através do MCA Crisp Adaptativo 3D

A segmentação automática dos pulmões em um exame completo de TC do tórax utiliza os métodos inicialização automática da curva 3D, os métodos de adição e remoção de pontos e o MCA Crisp Adaptativo 3D. Estes métodos são executados seguindo o fluxograma apresentado na Figura 3.30, em que exemplos são apresentados ao lado da respectiva etapa.

O primeiro passo para segmentar os pulmões de forma automática em um exame de TC é abrir a todas as imagens DICOM e dispor as mesmas em camadas consecutivas. Para isto, é utilizada a biblioteca livre DCMTK para ler a imagem e seus parâmetros, bem como identificar e ordenar os arquivos do exame de TC.




Figura 3.30: fluxograma de execução do método MCA Crisp Adaptativo 3D.

Em seguida, a energia externa de todo o exame é calculada utilizando o método Crisp Adaptativo 3D para detectar a origem das bordas obtidas na energia externa Tradicional 3D. As bordas detectadas dentro do pulmão são excluídas da energia externa, sendo

também utilizadas para inicialização da curva.

A curva é inicializada utilizando o método descrito na Seção 3.3.5, em que as bordas falsas de todas as fatias do pulmão determinam o ponto de inicialização dentro do pulmão. Este ponto é o centróide de um modelo 3D de coordenadas x_{ini} , y_{ini} e z_{ini} . Esta curva move-se por iterações sucessivas do MCA Crisp Adaptativo 3D, em que a energia deste minimiza movimentando os pontos do modelo 3D, conforme descrito na Seção 3.3. Além disso, os métodos de remoção de pontos 3D e adição de pontos 3D são aplicados a cada iteração, que estão descritos na Seção 3.3.6.

O modelo é dito estável quando o volume não aumenta após duas iterações consecutivas. Quando isto acontece, a segmentação do pulmão está concluída, e a estrutura gerada pelo modelo 3D é tida como o resultado da segmentação do objeto de interesse, ou seja, o pulmão segmentado.

Um exemplo de evolução de dois modelos 3D aplicando o MCA Crisp Adaptativo 3D na segmentação dos pulmões em imagens de TC do tórax é ilustrado na Figura 3.31.

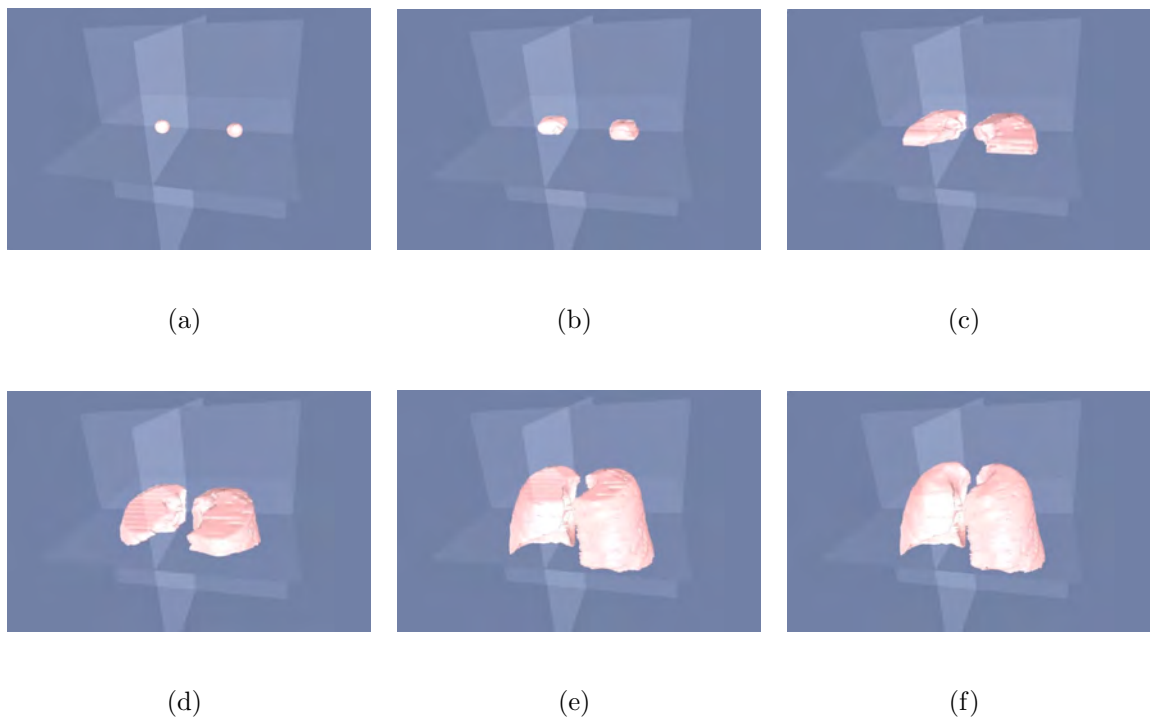


Figura 3.31: evolução de dois modelos 3D aplicando o MCA Crisp Adaptativo 3D na segmentação dos pulmões em um exame de TC do tórax, a) inicialização automática do modelo 3D; b) até e) evolução do modelo 3D; e f) resultado da segmentação.

Capítulo 4

Resultados e Discussões

Os resultados desta tese são apresentados para cada método proposto separadamente. Primeiramente, o MCA Crisp Adaptativo 2D é aplicado na segmentação dos pulmões em imagens de TC do tórax de voluntários saudáveis, pacientes com DPOC e pacientes com fibrose, sendo comparado com os métodos de segmentação automática proposto no sistema SISDEP, além dos MCAs com energia Hilbertiana e dos MCAs VFC, GVF e Crisp. Os resultados em 3D são apresentados posteriormente, em que o MCA Balão Adaptativo 3D é aplicado na segmentação de modelos 3D sintéticos e o MCA Crisp Adaptativo 3D é aplicado na segmentação dos pulmões em exames de TC do tórax de pacientes com DPOC e pacientes com fibrose, além de voluntários saudáveis. Ambos os métodos 3D são comparados com o Crescimento de Regiões 3D.

4.1 Aquisição de Imagens Médicas

As imagens utilizadas para avaliar os algoritmos foram adquiridas em tomógrafos distintos, em que parte das imagens foram salvas de amostras de um exame completo de TC, enquanto outras imagens foram salvas juntamente com o exame completo.

Os modelos utilizados para adquirir os exames completos são Toshiba Aquilion (TA), GE Medical System LightSpeed16 (GEMSL) e Philips Brilliance 10 (PB). Todas as imagens são 512 X 512 e 16 Bits. Na Tabela 4.1 estão dispostas as características destes exames completos, em que todos eles foram cedidos por médico pneumologista com autorização dos pacientes.

Já a Tabela 4.2 apresenta as características das amostras de imagens, em que apenas algumas imagens dos exames foram salvas. Estas imagens constituem um conjunto de imagens obtidas em parceria com o Hospital Walter Cantídio da Universidade Federal do

Tabela 4.1: *descrição dos exames completos utilizados para avaliação dos algoritmos 2D e 3D.*

<i>Nº do exame</i>	<i>Nº de imagens</i>	<i>espessura da fatia</i>	<i>modelo do tomógrafo</i>	<i>Patologia</i>
1	908	0,5 mm	TA	Normal
2	297	0,5 mm	TA	Normal
3	685	0,5 mm	TA	Normal
4	760	0,5 mm	TA	Normal
5	229	3,0 mm	TA	DPOC
6	278	1,25 mm	GEMSB	Normal
7	267	1,25 mm	GEMSB	fibrose
8	239	1,25 mm	GEMSB	Normal
9	276	2,0 mm	PB	fibrose
10	296	2,0 mm	PB	Normal
11	597	1,0 mm	PB	DPOC

Ceará, cedidas por um estudo anterior (FORTALEZA, 2006; WINKELER, 2006). Este estudo foi avaliado e aprovado pelo Comitê de Ética em Pesquisa da UFC – COMEPE (Protocolo nº 35/06) e incorporado às exigências da Resolução nº 196/96 do Conselho Nacional de Saúde, a respeito de pesquisas em seres humanos. Este processo de aquisição de imagens utiliza dois tipos de tomografia computadorizada, TC com multidetectores e TC de Alta Resolução (TCAR). As imagens obtidas utilizando TC com multidetectores são adquiridas por um tomógrafo GE MEDICAL SYSTEMS modelo LightSpeed16 (GEMSL), enquanto as imagens de TCAR são adquiridas em um tomógrafo Toshiba modelo Auklet (TA).

Tabela 4.2: *descrição das amostras de imagens utilizadas para avaliação dos algoritmos 2D.*

<i>Tipo de doença</i>	<i>Nº de pacientes</i>	<i>espessura da fatia</i>	<i>modelo do tomógrafo</i>
DPOC	11	1,5 mm	GEMSL
Sadios	8	1,5 mm	GEMSL
Fibrose	5	1,5 mm	TA

Nestas imagens descritas na Tabela 4.2, as imagens de TCAR dos pulmões são adquiridas nas posições ápice, hilo e base no plano de corte axial, sob as seguintes condições: os cortes possuem 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, a dimensão da imagem reconstruída é de 512×512 pixels, e voxel com dimensões $0,585 \times 0,585 \times 1,5$ mm e quantificadas em 16 bits (FORTALEZA, 2006; WINKELER, 2006; FELIX, 2011).

4.2 Resultados do MCA Crisp Adaptativo 2D

Nesta primeira etapa dos resultados, o MCA Crisp Adaptativo 2D é comparado na segmentação dos pulmões em imagens de TC com os MCAs THRMulti, THRMod, GVF, VFC e Crisp, além do sistema SISDEP. Cada um dos métodos é inicializado de forma distinta, em que sua inicialização obtêm o seu melhor resultado. Deste modo, os MCAs GVF, VFC, THRMod e THRMulti são inicializados conforme a proposta de FELIX (2011) utilizando o método INAUTO, o MCA Crisp inicializado de acordo com REBOUÇAS FILHO (2010), o sistema SISDEP conforme proposto por Felix (2007) e o MCA Crisp Adaptativo 2D conforme descrito na Seção 3.2.3.

Os parâmetros $\alpha = 0,6$, $\beta = 0,1$ e $\tau = 0,3$ são utilizados por todos os MCAs nos testes de segmentação dos pulmões em imagens de TC do tórax. Nos MCAs GVF e VFC outros parâmetros são configurados, sendo $\mu = 0,22$, $K = 0,2$ e $\gamma = 1,8$. Os melhores resultados são obtidos com estes valores de parâmetros, obtidos de modo empírico, com base nos valores apresentados na literatura.

A configuração do método proposto nesta tese possui outras configurações, além das citadas anteriormente. Quanto às regiões usadas para a inicialização automática, aplicam-se as mesmas regiões adotadas em estudos anteriores (REBOUÇAS FILHO, 2010). Deste modo, para a região esquerda são utilizados os valores 0 para LIX , 256 para LSX , 180 para LIY e 360 para LSY . Já para a região Direita, os valores utilizados são 256 para LIX , 512 para LSX , 180 para LIY e 360 para LSY . Após determinar os centróides de inicialização, são utilizados 10 vértices com 40 *pixels* de distância para o centróide na construção do polígono inicial da curva. Quanto à adição e remoção de pontos, a distância d máxima entre pontos utilizada para adicionar novos pontos é 5 *pixels* e o ângulo mínimo entre um ponto e seus vizinhos utilizado nas funções de deleção é 45 graus.

Utilizando as configurações e inicializações citadas, os métodos geram uma segmentação automática dos pulmões em imagens de TC e são avaliadas de forma quantitativa utilizando os valores de ajuste de posição, tamanho, intensidade e forma. Para esta avaliação, o padrão-ouro da segmentação dos pulmões é obtido através da segmentação manual realizada por um médico pneumologista.

O MCA Crisp Adaptativo 2D é utilizado na segmentação dos pulmões em imagens de TC do tórax em mais de 10 mil imagens, obtendo resultados promissores. Entretanto, esta tese faz a comparação destes métodos utilizando apenas 36 imagens de TC do tórax, sendo 12 imagens de voluntários sadios, 12 imagens de pacientes com DPOC e 12 imagens de pacientes com Fibrose. Estes tipos de doenças são usadas por possuírem

características distintas, em que o paciente normal apresenta os *voxels* pulmonares de acordo com o descrito na literatura e obedecendo às faixas de intensidade de cada tecido em Unidades Hounsfields. Entretanto, a DPOC e fibrose tendem a diminuir e aumentar, respectivamente, os valores de intensidade dos *voxels* afetados por esta doença.

Ressalta-se que, para plotar os valores obtidos nas métricas de avaliação quantitativas utilizadas nas 12 imagens de TC de cada doença, são considerados 24 pulmões de teste, em que cada imagem possui 2 destes pulmões. Além disto, nos testes são considerados os níveis de corte ápice, hilo e base. Deste modo, as Figuras 4.1, 4.6 e 4.11 apresentam exemplos de resultados nos níveis ápice, hilo e base de voluntários sadios, pacientes com DPOC e pacientes com fibrose, respectivamente.

Neste sentido, para avaliar os resultados obtidos utilizando as métricas de ajuste, os resultados obtidos nas imagens: de voluntários sadios são mostrados nas Figuras 4.2, 4.3, 4.4 e 4.5; de pacientes com DPOC são apresentados nas Figuras 4.7, 4.9, 4.8 e 4.10; e de pacientes com fibrose são ilustrados nas Figuras 4.12, 4.13, 4.14 e 4.15. Cada um destes resultados é apresentado na seguinte ordem para cada tipo de doença: medida de ajuste de posição, medida de ajuste de intensidade, medida de ajuste de tamanho e medida de ajuste de forma.

Uma média geral (μ) de todos os valores plotados em cada gráfico é apresentado em preto em cada Figura. Estes valores são utilizados como referência, nas subseções seguintes, para comparar os métodos em uma avaliação preliminar.




Figura 4.1: exemplos de segmentação dos pulmões em imagens de TC do tórax de voluntários sadios obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo 2D, apresentadas em cada linha de cima para baixo, respectivamente.




Figura 4.2: ajuste de posição obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.3: ajuste de intensidade obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.4: ajuste de tamanho obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.5: ajuste de forma obtido em cada um dos 24 pulmões de teste em voluntários sadios utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.6: exemplos de segmentação dos pulmões em imagens de TC do tórax de pacientes com DPOC obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo, apresentadas em cada linha de cima para baixo, respectivamente.




Figura 4.7: ajuste de posição obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.8: ajuste de intensidade obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.9: ajuste de tamanho obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.10: ajuste de forma obtido em cada um dos 24 pulmões de teste em pacientes com DPOC utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.11: exemplos de segmentação dos pulmões em imagens de TC do tórax de pacientes com Fibrose obtidas pelo médico especialista, MCA THRMulti, MCA THRMod, MCA GVF, MCA VFC, MCA Crisp, SISDEP e MCA Crisp Adaptativo, apresentadas em cada linha de cima para baixo, respectivamente.




Figura 4.12: ajuste de posição obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRMMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.13: ajuste de intensidade obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRMMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.14: ajuste de tamanho obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.




Figura 4.15: ajuste de forma obtido em cada um dos 24 pulmões de teste em pacientes com Fibrose utilizando os MCAS THRMod, THRMulti, GVF, VFC, Crisp, Sisdep e Crisp Adaptativo 2D.

4.2.1 Avaliação das medidas de ajuste de posição

Nesta primeira avaliação das medidas de ajuste, são consideradas as medidas de ajuste de posição em imagens obtidas nos voluntários sadios, nos pacientes com DPOC e nos pacientes com fibrose mostrados nos gráficos das Figuras 4.2, 4.7 e 4.12, respectivamente.

A média geral de todos os valores em cada gráfico são 99,65 para sadio, 99,08 para DPOC e 99,21 para fibrose. Utilizando estes valores como referência na avaliação dos métodos, conclui-se que os métodos Sisdep e MCA Crisp Adaptativo possuem, em geral, valores superiores às médias em todos os gráficos. Já os MCAs THRMulti, THRMod, GVF, VFC e Crisp oscilam, dependendo do pulmão analisado. Para complementar esta análise, os resultados para cada método avaliado considerando o índice de ajuste de posição, em média e desvio-padrão, são apresentados na Tabela 4.3.

Tabela 4.3: *média (μ) e desvio-padrão (σ) dos índices de ajuste de posição obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.*

Método de segmentação	Sadio		DPOC		Fibrose	
	$\mu(\%)$	$\sigma(\%)$	$\mu(\%)$	$\sigma(\%)$	$\mu(\%)$	$\sigma(\%)$
THRMulti	99,40	0,60	98,10	1,73	97,79	2,16
THRMod	99,52	0,56	99,12	0,84	99,31	0,55
GVF	99,56	0,51	98,20	2,57	99,24	0,82
VFC	99,74	0,29	99,51	0,67	99,25	0,67
Sisdep	99,82	0,14	99,66	0,53	99,73	0,17
Crisp	99,72	0,31	99,20	0,81	99,41	0,86
Crisp Adaptativo 2D	99,79	0,16	99,76	0,10	99,74	0,17

Analisando as medidas de ajuste de posição dos voluntários sadios apresentadas na Tabela 4.3, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep se destacam, obtendo os valores $99,79 \pm 0,16$ e $99,82 \pm 0,14$, respectivamente. Entretanto, os demais métodos também obtêm altos índices de ajuste de posição, em que os menores valores são $99,40 \pm 0,60$, obtidos pelo MCA THRMulti.

Já analisando as medidas de ajuste de posição dos pacientes com DPOC mostradas na Tabela 4.3, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep também se destacam, obtendo os valores $99,76 \pm 0,10$ e $99,66 \pm 0,53$, respectivamente. Entretanto, os demais métodos também obtêm altos índices de ajuste de posição, em que os menores valores são $98,10 \pm 1,73$ e $98,20 \pm 2,57$, obtidos pelos MCAs THRMulti e GVF, respectivamente.

Por último, analisando as medidas de ajuste de posição dos paciente com Fibrose apresentadas na Tabela 4.3, conclui-se que o MCA Crisp Adaptativo e o Sisdep também se destacam, assim como nas imagens de sadios e com DPOC, obtendo os valores $99,74 \pm 0,17$ e $99,73 \pm 0,17$, respectivamente. Entretanto, os demais métodos também obtêm altos índices de ajuste de posição, em que os menores valores são $97,79 \pm 2,16$, obtidos pelos MCA THRMulti.

Deste modo, pode-se concluir que todos os métodos obtêm médias de resultados de ajuste de posição superiores a 97,79% em todos os tipos de imagens, considerando os voluntários sadios e os pacientes com DPOC ou fibrose. Entretanto, o MCA Crisp Adaptativo 2D e o sistema Sisdep destacam-se pelos altos índices de ajuste de posição, sempre com médias superiores a 99,74% e 99,66%, respectivamente.

A correlação entre as médias dos ajuste de posição de todos os métodos dos voluntários sadios com os pacientes com DPOC é 0,88 e dos voluntários sadios com os pacientes com fibrose é 0,83. Isto indica que as doenças, DPOC e fibrose, afetam todos os métodos. Entretanto, o MCA Crisp Adaptativo 2D mostrou-se mais estável em relação aos demais métodos, visto que não altera seus valores quando aplicado em imagens com diferentes doenças. Isto pode ser observado na Tabela 4.3, em que este método obtém os valores $99,79 \pm 0,16$, $99,76 \pm 0,10$ e $99,74 \pm 0,17$ em imagens de voluntários sadios, pacientes com DPOC e fibrose, respectivamente.

4.2.2 Avaliação das medidas de ajuste de intensidade

Nesta segunda etapa de avaliação, são consideradas as medidas de ajuste de intensidade obtidas em imagens de voluntários sadios, nos pacientes com DPOC ou fibrose mostrados nos gráficos das Figuras 4.3, 4.8 e 4.13, respectivamente.

A média geral de todos os valores em cada gráfico é 94,69 para sadio, 92,11 para DPOC e 90,61 para fibrose. Utilizando estes valores como referência na avaliação dos métodos, conclui-se que os métodos MCA Crisp Adaptativo 2D e Sisdep possuem, em geral, valores superiores às médias em todos os gráficos. Já os MCAs THRMulti, THRMod, GVF, VFC e Crisp oscilam, dependendo do pulmão analisado. Para complementar esta análise, os resultados para cada método avaliado considerando o índice de ajuste de intensidade, em média e desvio-padrão, são apresentados na Tabela 4.4.

Analisando as medidas de ajuste de intensidade dos voluntários sadios apresentadas na Tabela 4.4, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep se destacam, obtendo os valores $98,92 \pm 0,77$ e $96,01 \pm 2,83$, respectivamente. Os demais métodos também

Tabela 4.4: *média (μ) e desvio-padrão (σ) dos índices de ajuste de intensidade obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.*

Método de segmentação	Sadio		DPOC		Fibrose	
	μ (%)	σ (%)	μ (%)	σ (%)	μ (%)	σ (%)
THRMulti	92,32	4,71	85,42	11,14	77,87	18,93
THRMod	92,96	2,83	92,71	3,56	92,43	10,75
GVF	94,57	3,79	88,36	9,84	90,97	13,62
VFC	94,33	3,42	93,97	3,41	88,38	18,98
Sisdep	96,01	2,83	95,69	2,44	95,19	2,35
Crisp	93,76	4,22	90,60	3,96	91,38	7,22
Crisp Adaptativo 2D	98,92	0,77	98,05	1,50	98,05	2,33

obtem altos índices de ajuste de intensidade, em que os menores valores são $92,32 \pm 4,71$, obtidos pelo MCA THRMulti.

Já analisando as medidas de ajuste de intensidade dos pacientes com DPOC mostradas na Tabela 4.4, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep também se destacam, obtendo os valores $98,05 \pm 1,50$ e $95,69 \pm 2,44$, respectivamente. Os demais métodos obtêm índices de ajuste de intensidade menores que os citados, sendo os menores destes $85,42 \pm 11,14$ e $88,36 \pm 9,84$, obtidos pelos MCAs THRMulti e GVF, respectivamente.

Por último, analisando as medidas de ajuste de intensidade dos paciente com Fibrose apresentadas na Tabela 4.4, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep também se destacam, assim como nas imagens de sadios e com DPOC, obtendo os valores $98,05 \pm 2,33$ e $95,19 \pm 2,35$, respectivamente. Os demais métodos obtêm índices de ajuste de intensidade menores que nos métodos citados, em que os menores valores são $77,87 \pm 18,93$, obtidos pelos MCA THRMulti.

A correlação entre as médias dos ajuste de intensidade de todos os métodos dos voluntários sadios com os pacientes com DPOC é 0,8 e dos voluntários sadios com os pacientes com fibrose é 0,55. Isto indica que as doenças, DPOC e fibrose, afetam todos os métodos. Entretanto, os métodos MCA Crisp Adaptativo 2D e o Sisdep destacam-se pelos altos índices de ajuste de intensidade, sempre com médias superiores a 98,05% e 95,19%, respectivamente. Além disto, destaca-se que o MCA Crisp Adaptativo 2D, além de obter a maior média em todas as imagens, mostrou-se mais estável em relação aos demais métodos, visto que não altera seus valores quando aplicado em imagens com diferentes doenças. Isto pode ser observado na Tabela 4.4, em que este método obtêm os valores $98,92 \pm 0,77$, $98,05 \pm 1,50$ e $98,05 \pm 2,33$ em imagens de voluntários sadios, pacientes com DPOC e fibrose, respectivamente.

4.2.3 Avaliação das medidas de ajuste de tamanho

Nesta terceira análise de medidas de ajuste, são avaliadas as medidas de ajuste de tamanho em imagens obtidas em exames de voluntários sadios, de pacientes com DPOC e de pacientes com fibrose mostrados nos gráficos das Figuras 4.4, 4.9 e 4.14, respectivamente.

A média geral de todos os valores em cada gráfico é 96,71 para sadio, 94,34 para DPOC e 93,99 para fibrose. Utilizando estes valores como referência na avaliação dos métodos, conclui-se que os métodos MCA Crisp Adaptativo 2D e Sisdep possuem, em geral, valores superiores às médias em todos os gráficos. Já os MCAs THRMulti, THRMod, GVF, VFC e Crisp oscilam, dependendo do pulmão analisado. Para complementar esta análise, os resultados para cada método avaliado considerando o índice de ajuste de tamanho, em média e desvio-padrão, são apresentados na Tabela 4.5.

Tabela 4.5: *média (μ) e desvio-padrão (σ) dos índices de ajuste de tamanho obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.*

Método de segmentação	Sadio		DPOC		Fibrose	
	$\mu(\%)$	$\sigma(\%)$	$\mu(\%)$	$\sigma(\%)$	$\mu(\%)$	$\sigma(\%)$
THRMulti	95,76	2,51	92,66	5,39	84,84	16,67
THRMod	95,97	1,50	96,23	1,90	95,80	6,18
GVF	96,35	2,83	91,13	9,78	94,68	7,19
VFC	96,44	2,36	96,29	1,80	92,88	12,18
Sisdep	97,74	1,63	97,75	1,27	96,89	1,93
Crisp	95,66	2,58	87,31	13,25	94,42	3,86
Crisp Adaptativo 2D	99,09	0,64	99,05	0,81	98,46	2,30

Analisando as medidas de ajuste de tamanho dos voluntários sadios apresentadas na Tabela 4.5, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep se destacam, obtendo os valores $99,09 \pm 0,64$ e $97,74 \pm 1,63$, respectivamente. Os demais métodos também obtêm altos índices de ajuste de tamanho, em que os menores valores são $95,66 \pm 2,58$, obtidos pelo MCA Crisp.

Já analisando as medidas de ajuste de tamanho dos pacientes com DPOC mostradas na Tabela 4.5, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep também se destacam, obtendo os valores $99,05 \pm 0,81$ e $97,75 \pm 1,27$, respectivamente. Os demais métodos obtêm índices de ajuste de tamanho menores que os citados, sendo os menores destes $87,31 \pm 13,25$ obtidos pelo MCA Crisp.

Por último, analisando as medidas de ajuste de tamanho dos paciente com Fibrose apresentadas na Tabela 4.5, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep se destacam, assim como nas imagens de sadios e com DPOC, obtendo os valores $98,46 \pm 2,30$ e $96,89 \pm 1,93$, respectivamente. Entretanto, os demais métodos obtêm índices de ajuste de tamanho menores, sendo o menor destes valores $84,84 \pm 16,67$, obtidos pelos MCA THRMulti.

A correlação entre as médias dos ajuste de tamanho de todos os métodos dos voluntários sadios com os pacientes com DPOC é 0,73 e dos voluntários sadios com os pacientes com fibrose é 0,62. Isto indica que as doenças, DPOC e fibrose, afetam todos os métodos. Entretanto, os métodos MCA Crisp Adaptativo 2D e o Sisdep destacam-se pelos altos índices de ajuste de tamanho, sempre com médias superiores a 98,46% e 96,89%, respectivamente. Além disto, destaca-se que o MCA Crisp Adaptativo 2D, além de obter a maior média em todas as imagens, mostrou-se mais estável em relação aos demais métodos, visto que não altera seus valores quando aplicado em imagens com diferentes doenças. Isto pode ser observado na Tabela 4.5, em que este método obtém os valores $99,09 \pm 0,64$, $99,05 \pm 0,81$ e $98,46 \pm 2,30$ em imagens de voluntários sadios, pacientes com DPOC e fibrose, respectivamente.

4.2.4 Avaliação das medidas de ajuste de forma

Nesta quarta análise das medidas de ajuste, são avaliadas as medidas de ajuste de forma obtidas em imagens de voluntários sadios, de pacientes com DPOC ou fibrose mostrados nos gráficos das Figuras 4.5, 4.10 e 4.15, respectivamente. Esta medida de ajuste tende a maximizar os erros presentes nas regiões de segmentação em relação padrão-ouro, sendo por isto a principal medida entre os índices de ajuste avaliados.

A média geral de todos os valores em cada gráfico é 90,86 para sadio, 87,73 para DPOC e 84,80 para fibrose. Utilizando estes valores como referência na avaliação dos métodos, conclui-se que o método MCA Crisp Adaptativo 2D possui valores superiores às médias em todas as imagens, sendo seguido pelo método Sisdep que fica abaixo da média em poucas imagens. Já os MCAs THRMulti, THRMod, GVF, VFC e Crisp oscilam, dependendo do pulmão analisado. Para complementar esta análise, os resultados para cada método avaliado considerando o índice de ajuste de forma, em média e desvio-padrão, são apresentados na Tabela 4.6.

Analisando as medidas de ajuste de forma dos voluntários sadios apresentadas na Tabela 4.6, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep se destacam, obtendo

Tabela 4.6: *média (μ) e desvio-padrão (σ) dos índices de ajuste de forma obtidos pelos métodos THRMulti, THRMod, GVF, VFC, Sisdep, Crisp e Crisp Adaptativo 2D na segmentação dos pulmões em imagens de TC do tórax.*

Método de segmentação	Sadio		DPOC		Fibrose	
	μ (%)	σ (%)	μ (%)	σ (%)	μ (%)	σ (%)
THRMulti	87,55	5,28	80,28	9,49	71,65	15,81
THRMod	89,32	3,72	87,00	4,76	84,58	9,16
GVF	89,92	4,82	81,94	13,68	83,00	12,63
VFC	90,91	3,37	89,25	4,22	82,23	15,36
Sisdep	93,50	2,30	93,78	3,00	92,22	3,19
Crisp	89,25	4,59	96,51	4,32	86,70	6,25
Crisp Adaptativo 2D	95,59	1,53	95,36	1,06	93,26	2,94

os valores $95,59 \pm 1,53$ e $93,50 \pm 2,30$, respectivamente. Os demais métodos obtêm índices de ajuste de forma menores, em que os menores valores são $87,55 \pm 5,28$, obtidos pelo MCA THRMulti.

Já analisando as medidas de ajuste de forma dos pacientes com DPOC mostradas na Tabela 4.6, conclui-se que os MCAs Crisp, Crisp Adaptativo 2D e o Sisdep se destacam, obtendo os valores $96,51 \pm 4,32$, $95,36 \pm 1,06$ e $93,78 \pm 1,27$, respectivamente. Os demais métodos obtêm índices de ajuste de forma menores que os citados, sendo os menores destes $80,28 \pm 9,49$ obtidos pelo MCA Crisp.

Por último, analisando as medidas de ajuste de forma dos paciente com Fibrose apresentadas na Tabela 4.6, conclui-se que o MCA Crisp Adaptativo 2D e o Sisdep se destacam, assim como nas imagens de sádios e com DPOC, obtendo os valores $93,26 \pm 2,94$ e $92,22 \pm 3,19$, respectivamente. Entretanto, os demais métodos obtêm índices de ajuste de forma menores, sendo o menor destes valores $71,65 \pm 15,81$, obtido pelo MCA THRMulti.

A correlação entre as médias dos ajuste de forma de todos os métodos dos voluntários sádios com os pacientes com DPOC é 0,68 e dos voluntários sádios com os pacientes com fibrose é 0,85. Isto indica que as doenças, DPOC e fibrose, afetam todos os métodos. Entretanto, os métodos MCA Crisp Adaptativo 2D e o Sisdep destacam-se pelos altos índices de ajuste de forma, sempre com médias superiores a 93,26% e 92,22%, respectivamente. Além disto, destaca-se que o MCA Crisp Adaptativo 2D, além de obter a maior média em todas as imagens, mostrou-se mais estável em relação aos demais métodos, visto que não altera significativamente seus valores quando aplicado em imagens com diferentes doenças. Isto pode ser observado na Tabela 4.6, em que este método obtêm os valores $95,59 \pm 1,53$, $95,36 \pm 1,06$ e $93,26 \pm 2,94$ em imagens de voluntários sádios, pacientes com DPOC e fibrose, respectivamente.

4.2.5 Tempo médio de processamento

Na quinta e última etapa de comparação entre o sistema SISDEP e os MCAs GVF, THRMod, THRMulti, VFC, Crisp e Crisp Adaptativo 2D é considerado o tempo médio de segmentação dos pulmões em imagens de TC do tórax, em que a média dos tempos obtidos nas 36 imagens de teste é apresentada na Tabela 4.7 em ordem decrescente, considerando o tempo de processamento em segundos. O tempo foi contabilizado em todos os métodos desde a inicialização até a estabilização do perímetro da curva. Caso ultrapassasse 500 ciclos de minimização da energia, o método também era dito estável e a contagem do tempo paralisada. Os testes são realizados em um MacBook Pro Core i5 com 2.4GHz e 8GB de memória RAM.

Tabela 4.7: *tempo médio de processamento de cada método analisado.*

Método	Tempo médio (segundos)
MCA GVF	240
MCA THRMod	150
MCA THRMulti	150
MCA VFC	30
Sistema Sisdep	4
MCA Crisp Adaptativo 2D	2
MCA Crisp	1,5

A partir dos dados da Tabela 4.7, conclui-se que os métodos mais rápidos na segmentação automática dos pulmões em imagens de TC são o sistema Sisdep, o MCA Crisp e o MCA Crisp Adaptativo 2D visto que estes possuem processamento médio aproximadamente 8 vezes menor do que os demais métodos, abaixo dos 5 segundos.

4.2.6 Avaliação geral dos métodos

Considerando as medidas de ajuste obtidas e discutidas anteriormente, tem-se que o método desenvolvido no sistema SISDEP e o MCA Crisp Adaptativo 2D aplicados na segmentação dos pulmões apresentam-se superiores aos demais métodos quando aplicados na segmentação dos pulmões em imagens de TC de voluntários sadios, pacientes com DPOC e com fibrose. Além disto, destaca-se que o MCA Crisp Adaptativo 2D mostrou-se mais estável em relação aos demais em todas as medidas de ajuste, visto que não altera significativamente seus valores quando aplicado em imagens com diferentes patologias

analisadas (normal, fibrose e DPOC) e nos três níveis de corte considerados (ápice, hilo e base).

Dentre as causas dos altos índices das medidas de ajuste obtidos pelo MCA Crisp Adaptativo 2D, podem ser citadas as energias internas e externas deste método. A energia externa determina de forma eficaz as fronteiras que devem ser encontradas por cada ponto da curva. Isto é possível utilizando uma RNA para determinar a origem das bordas presentes em imagens de TC do tórax, indicando quais destas bordas estão dentro dos pulmões. Um exemplo do passo a passo para obtenção desta energia é apresentado na Figura 4.16.




Figura 4.16: exemplo das etapas para obtenção da energia externa do MCA Crisp Adaptativo 2D, a) imagem de TC original; b) gradiente Sobel de a); c) análise do MCA Crisp Adaptativo 2D apresentando as bordas internas do pulmão em vermelho e as externas em verde; e d) representação da energia externa do MCA Crisp Adaptativo 2D.

Quanto ao tempo de processamento de cada método, o tempo de processamento médio do MCA Crisp Adaptativo 2D é 2 vezes menor que o tempo de processamento obtido pelo método do sistema SISDEP, e pelo menos 15 vezes menor que os demais métodos, quando aplicado na segmentação dos pulmões em imagens de TC do tórax. Entretanto, o método que obteve menor tempo médio de processamento é o MCA Crisp, obtendo uma velocidade aproximadamente 2 vezes maior que o MCA proposto.

Dentre os principais motivos que aumentam a velocidade do MCA Crisp Adaptativo 2D em relação aos demais métodos é a energia interna utilizada, caracterizada pela adaptabilidade da curva na segmentação de topologias complexas. Para demonstrar essa afirmativa, a Figura 4.17 mostra o passo a passo da evolução deste método desde a sua inicialização, apresentada na Figura 4.17(a) até sua estabilização no resultado final apresentado na Figura 4.17(f). Nesta Figura, os pontos são apresentados em azul, suas conexões em vermelho, formando a curva, e a direção da energia interna Balão Adaptativa é apresentada em verde. Esta energia parte de cada ponto em direção ao local onde esta energia é mínima para topologia apresentada em sua vizinhança. O contorno demonstrado é desenhado sobre a ilustração da energia externa Crisp Adaptativa 2D obtida na Figura 4.16.

Analisando a convergência do MCA Crisp Adaptativo 2D desde sua inicialização em 4.17(a) até sua estabilização em 4.17(f), pode-se concluir que a energia interna do MCA Crisp Adaptativo 2D gera uma convergência rápida por três motivos:

1. cada energia interna é direcionada para um destino distinto dos demais pontos;
2. nenhuma direção aponta para dentro da curva, diminuindo seu tempo de processamento e aumentando sua eficácia;
3. em regiões homogêneas e distantes das bordas, a direção sempre aponta para as bordas dos objetos

Estes tópicos em conjunto explicam a velocidade de convergência do método, já que cada ponto é direcionado para uma direção diferente. Além disto, explica a adaptabilidade às diferentes topologias dos pulmões, visto que sempre existe pelo menos um ponto na direção do restante do objeto que ainda não faz parte do interior do contorno. Além disso, a energia externa gerada por uma RNA aumenta a eficácia no reconhecimento das bordas pulmonares.

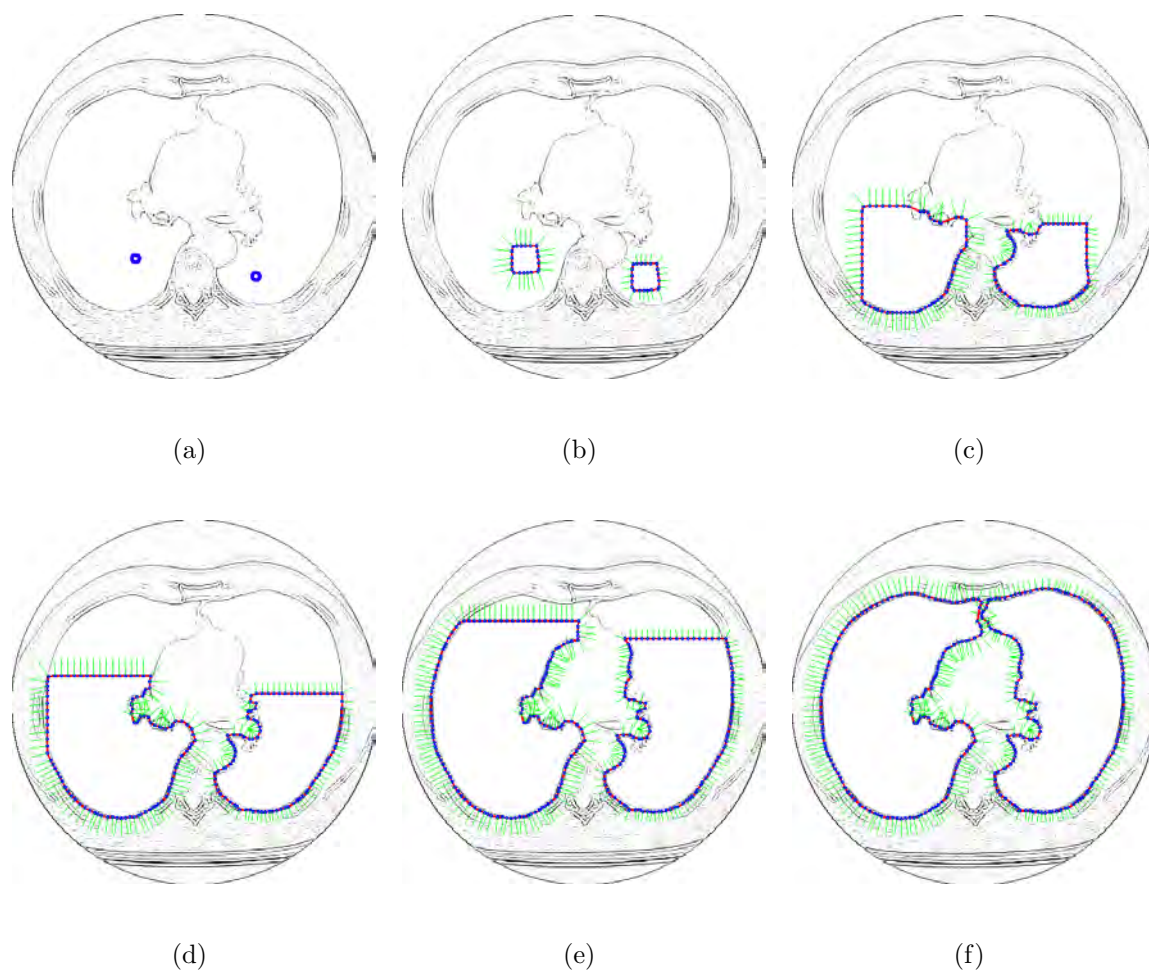


Figura 4.17: exemplo das etapas de aplicação do MCA Crisp Adaptativo 2D, sobre a representação da energia externa deste método e apresentando a direção da energia interna Balão Adaptativa em verde, a) inicialização; b) até e) passo a passo da evolução da curva; e f) resultado da segmentação.

4.3 Resultados do MCA Crisp Adaptativo 3D

Nesta segunda e última etapa dos resultados, o MCA Crisp Adaptativo 3D é comparado na segmentação dos pulmões em exames de TC com o Crescimento de Regiões 3D. Para esta comparação são utilizados exames de TC do tórax de voluntários saudáveis, pacientes com DPOC ou fibrose, totalizando 11 exames completos.

A configuração utilizada no MCA Crisp Adaptativo 3D é semelhante ao método 2D, utilizando os parâmetros $\alpha = 0,6$, $\beta = 0,1$ e $\tau = 0,3$ na composição da energia total. Quanto às regiões usadas para a inicialização automática, aplicam-se as mesmas regiões, sendo para a região esquerda os valores 0 para LIX , 256 para LSX , 180 para LIY e 360

para *LSY*. Já para a região Direita, os valores utilizados são 256 para *LIX*, 512 para *LSX*, 180 para *LIY* e 360 para *LSY*. Após determinar os centróides de inicialização, são utilizados 30 vértices por camada com raio 50 *pixels* de distância para o centróide na construção do modelo 3D inicial. Quanto à adição e remoção de pontos, a distância d máxima entre pontos utilizada para adicionar novos pontos é 5 *pixels* e o ângulo mínimo entre um ponto e seus vizinhos utilizado nas funções de deleção é 45 graus.

O método CR 3D utiliza a mesma inicialização do MCA Crisp Adaptativo 3D, em que toda a região interna do polígono de inicialização deste MCA é utilizada como semente inicial. O método de adição de regiões vizinhas adotado utiliza informações da anatomia do pulmão, adicionando apenas voxels que estejam em alguma faixa de intensidade dentro do pulmão, sendo estas: normalmente aerada, pouco aerada ou hiperaerada. Esta adição acontece por iterações sucessivas, estabilizando quando nenhum voxel é adicionado.

Nos resultados apresentados nesta seção, o MCA Crisp Adaptativo 3D é apresentado na tonalidade rosa, obedecendo a estrutura de visualização proposta na Seção 3.3.3 utilizando apenas o contorno do objeto 3D na construção da visualização. Entretanto, o Crescimento de Regiões 3D é apresentado em azul e utiliza uma construção sólida de toda a região obtida por este método. Deste modo, alguns efeitos de luminosidade e sombra não são iguais aos resultados obtidos pelo MCA Crisp Adaptativo 3D devido sua construção impossibilitar tais efeitos utilizando a biblioteca gráfica OpenGL utilizada nesta tese.

Para avaliar os métodos na segmentação dos pulmões em exames de TC do tórax são utilizadas as mesmas inicializações em ambos os métodos, conforme exemplos apresentados nas Figuras 4.18(a) e 4.18(b), do MCA Crisp Adaptativo 3D e CR 3D, respectivamente. A partir destas inicializações, os métodos evoluem seus modelos por iterações sucessivas até estabilizar. Um exemplo de evolução do MCA Crisp Adaptativo 3D é apresentada nas Figuras 4.18(c) e 4.18(e), obtendo o resultado apresentado na Figura 4.18(g). Já a evolução do CR 3D é exemplificada nas Figuras 4.18(d) e 4.18(f), obtendo o resultado apresentado na Figura 4.18(h).

Analisando a evolução e os resultados do CR 3D e do MCA Crisp Adaptativo 3D apresentados na Figura 4.18, percebe-se que as regiões obtidas no final de cada método são similares, embora a evolução dos modelos seja distinta.

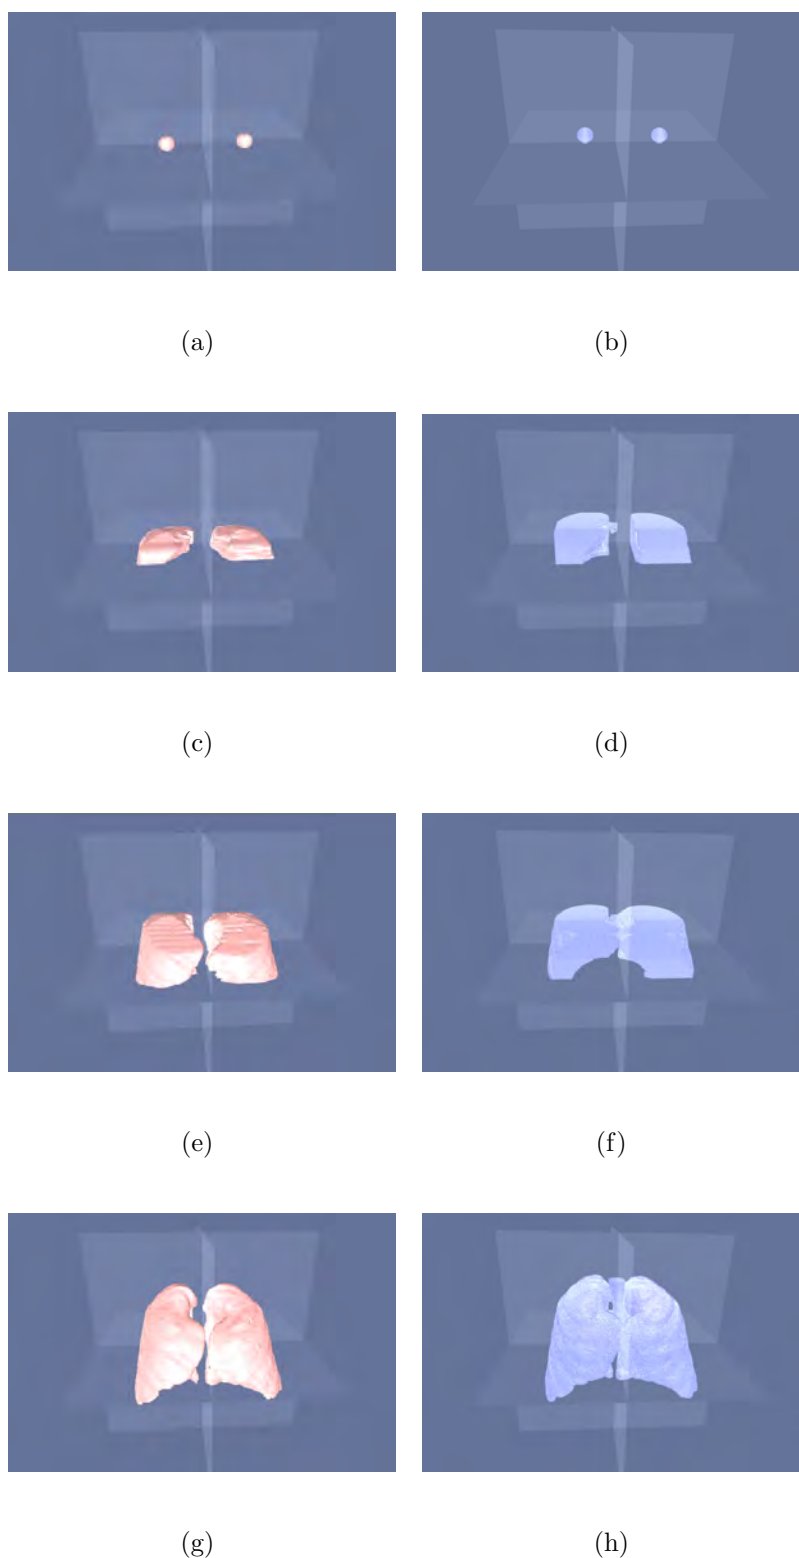


Figura 4.18: exemplo da evolução dos métodos MCA Crisp Adaptativo 3D (rosa) e Crescimento de Regiões 3D (Azul) na segmentação dos pulmões em exames de TC do tórax utilizando a mesma inicialização apresentadas em a) e b), respectivamente. A evolução do MCA 3D em c) e e) até se estabilizar, conforme ilustrado em g). A evolução do CR 3D em d) e f) até se estabilizar, conforme ilustrado em h).

Outros três exemplos segmentações dos pulmões obtidos por estes métodos em imagens de TC do tórax são mostrados na Figura 4.19 em linhas distintas. Nesta Figura, são apresentados exemplos de resultados utilizando o MCA Crisp Adaptativo 3D na primeira coluna, pelo CR 3D na segunda coluna e os dois métodos na terceira coluna. Para o CR 3D na segunda coluna, os resultados são plotados com efeitos de iluminação e transparência para que os detalhes da superfície dos pulmões sejam visualizados. Entretanto, estes efeitos são retirados nos resultados do CR 3D apresentados na terceira coluna, ressaltando as diferenças dos resultados obtidos pelos métodos.




Figura 4.19: segmentação dos pulmões em exames de TC pelos métodos, a), d) e g) MCA Crisp Adaptativo 3D; b), e) e h) Crescimento de Regiões 3D; e c), f) e i) ambos métodos anteriores, retirando os efeitos de luz e transparência do CR 3D para realçar as diferenças.

Analisando os resultados mostrados nas Figuras 4.19(c), 4.19(f) e 4.19(i), conclui-se que a diferença entre os métodos são basicamente duas, diferenças superficiais dos modelos 3D gerados e a segmentação da traquéia. Primeiramente, as diferenças superficiais entre os métodos são causadas pelo funcionamento distinto de ambos, visto que o MCA obtém seu resultado através do movimento de uma curva, enquanto o CR obtém seu resultado voxel a voxel.

Já a segmentação de outras estruturas além do pulmão, como a traquéia, é comum no método CR 3D, bem como a exclusão de partes pulmonares que apresentam doenças como a fibrose. Neste sentido, para avaliar adequadamente os resultados obtidos por estes dois métodos, faz-se necessário uma avaliação qualitativa realizada por médicos especialistas e uma avaliação do tempo de processamento para medir o custo-benefício de cada método.

4.3.1 Avaliação Qualitativa por médicos pneumologistas

A segmentação dos métodos em 3 dimensões (3D) é realizada utilizando o exame completo de TC do tórax, em que estes exames podem variar a quantidade de imagens de um exame para o outro, dependendo da estrutura do corpo do paciente e também da espessura da fatia da imagem DICOM. Sendo assim, considerando que os exames completos de TC do tórax variam entre 250 até 1000 imagens, então uma avaliação de todas as imagens por parte de um médico pneumologista, torna-se inviável. Neste sentido, uma amostragem das imagens a serem avaliadas faz-se necessária.

A amostragem utilizada nesta tese baseia-se na anatomia do pulmão humano, sendo dividida em 4 regiões distintas conforme apresentado na Figura 4.20.




Figura 4.20: regiões do pulmão consideradas na seleção das imagens em cada exame de TC do tórax para a análise qualitativa dos métodos de segmentação 3D dos pulmões.

Enumerando as regiões do ápice até a parte inferior do pulmão de acordo com a Figura 4.20, têm-se que a região 1 é a região dos lobos superiores, que está no ápice do pulmão e caracteriza-se pela presença da traquéia. A região 2 é a região hilar, sendo esta a região de emergência dos vasos e brônquios fontes, caracterizando-se pela presença do hilo, em que este é a divisão da traquéia em duas vias distintas. A região 3 é a região de base, caracterizada pela presença das veias pulmonares. Por último, a região 4 é a região justa diafragmática, podendo ser chamada também de recesso costofrênico, sendo esta região o final do pulmão, caracterizado por formas pulmonares cônicas e com espessura menor, à medida que a camada aproxima-se do final do pulmão. Exemplos de imagens destas regiões são demonstrados na Figura 4.21.

O conjunto de imagens para análise é construído utilizando 3 imagens de cada região por exame de TC, totalizando 12 imagens por exame. Como são utilizados 11 exames completos, então 132 imagens no total são usadas na avaliação pelos médicos especialistas quanto à segmentação dos pulmões em exames de TC do tórax, o que corresponde à 264 pulmões a serem avaliados. Esta análise é realizada utilizando métricas qualitativas devido a impossibilidade de utilizar métricas quantitativas. Isto ocorre devido uma análise quantitativa tornar-se inviável por necessitar que o médico especialista segmente manualmente as imagens, o que é demasiadamente moroso, enfadonho e cansativo, considerando o total de 132 imagens.

Neste sentido, a avaliação qualitativa usada na avaliação da segmentação dos pulmões para os métodos Crescimento de Regiões 3D e MCA Crisp Adaptativo 3D é realizada conforme a Seção 2.3.2. Esta avaliação consiste em atribuir notas para as segmentações obtidas pelos métodos, em que nesta tese, dois médicos pneumologistas são responsáveis para realizar esta avaliação. Deste modo, as notas atribuídas nesta avaliação possuem valor de 1 a 5, em que seus respectivos Critérios de Avaliação Qualitativa (CAQ) da segmentação, em ordem crescente, são:

1. péssima, não encontra parte nenhuma do objeto de interesse;
2. ruim, obtendo apenas uma pequena parcela do objeto de interesse;
3. razoável, possui qualidade média, com a presença de erros grosseiros;
4. aceitável, com a presença de pequenos erros;
5. ótima, com altíssima qualidade, tão boa quanto se poderia desejar.




Figura 4.21: exemplo de imagens das regiões presentes na Figura 4.20, a),b) e c) exemplos da região 1; d),e) e f) exemplos da região 2; g),h) e i) exemplos da região 3 e j),k) e l) exemplos da região 4.

Os médicos que avaliaram os resultados dos métodos em questão são professores e pneumologistas do Hospital Universitário Walter Cantídio da Universidade Federal do Ceará, sendo chamados de médico 1 (M1) e médico 2 (M2).

As avaliações de ambos os médicos sobre os resultados são utilizadas para construir a Tabela de contingência, também chamada de matriz de confusão, das avaliações para cada método, em que as linhas apresentam as avaliações do médico *M1* e as colunas apresentam as avaliações do médico *M2* de todos os 264 pulmões analisados. As Tabelas de contingência de avaliação dos médicos sobre o Crescimento de Regiões 3D e o MCA Crisp Adaptativo 3D são apresentados nas Tabelas 4.8 e 4.9, respectivamente.

Tabela 4.8: *avaliação qualitativa dos médicos M1 e M2 dos resultados obtidos pelo método Crescimento de Regiões 3D.*

		M2					Total(M1)	%
		CAQ	1	2	3	4		
M1	1	0	0	0	0	0	0	(0)
	2	0	5	10	5	0	20	(7,58)
	3	0	1	62	60	0	123	(46,59)
	4	0	0	6	61	9	76	(28,78)
	5	0	0	0	6	39	45	(17,05)
	Total(M2)	0	6	78	132	48	264	(100)
	%	(0)	(2,27)	(29,55)	(50)	(18,18)	(100)	

Tabela 4.9: *avaliação qualitativa dos médicos M1 e M2 dos resultados obtidos pelo método Crisp Adaptativo 3D.*

		M2					Total(M1)	%
		CAQ	1	2	3	4		
M1	1	0	0	0	0	0	0	(0)
	2	0	1	0	0	0	1	(0,38)
	3	0	0	1	2	1	4	(1,51)
	4	0	0	4	201	11	216	(81,82)
	5	0	0	0	13	30	43	(16,29)
	Total(M2)	0	1	5	216	42	264	(100)
	%	(0)	(0,38)	(1,89)	(81,82)	(15,9)	(100)	

Com base nas Tabelas de contingência apresentadas é possível medir a concordância

inter-observador, utilizando o índice Kappa (K) descrito na Seção 2.3.3. Sendo assim, têm-se que o valor de Kappa obtido através dos dados da Tabela 4.8 é 0,464, indicando concordância moderada entre os médicos, de acordo com a Tabela 2.3 para as avaliações sobre os resultados do método Crescimento de Regiões 3D.

Já para os resultados obtidos pelo MCA Crisp Adaptativo 3D, o valor de Kappa obtido através dos dados da Tabela 4.9 é 0,614, indicando uma concordância substancial entre os médicos, de acordo com a Tabela 2.3.

Para uma melhor análise entre os resultados, a Tabela 4.10 apresenta um resumo dos percentuais obtidos pelos métodos CR 3D e MCA Crisp Adaptativo 3D nas avaliações pelos médicos especialistas, extraídos das Tabelas 4.8 e 4.9, respectivamente.

Tabela 4.10: *avaliação qualitativa dos médicos M1 e M2 dos resultados obtidos pelos métodos Crescimento de Regiões 3D e MCA Crisp Adaptativo 3D.*

Método Classificação	CR 3D		MCA CRAD 3D	
	M1	M2	M1	M2
1	0%	0%	0%	0%
2	7,58%	2,27%	0,38%	0,38%
3	46,59%	29,55%	1,51%	1,89%
4	28,78%	50%	81,82%	81,82%
5	17,05%	18,18%	16,29%	15,9%
Satisfatório	45,83%	68,18%	98,11%	97,72%

Analisando os índices percentuais mostrados na Tabela 4.10 quanto à concordância entre os médicos, constata-se que as avaliações dos resultados do método CR 3D são divergentes entre os dois médicos, em que os percentuais de algumas classes são significativamente diferentes. Isto pode ser observado nas classificações 3 e 4, em que na classificação 3 o médico M1 está com 46,59% e o médico M2 está com 29,55%, enquanto na classificação 4, o médico M1 está com 28,78% e o médico M2 está com 50%. Esta análise apresenta a discordância entre os médicos avaliadores, ficando comprovado com o índice Kappa obtido de 0,464, indicando concordância moderada entre os médicos.

Fazendo a mesma análise dos resultados do MCA Crisp Adaptativo 3D quanto à concordância entre os médicos, utilizando os índices percentuais obtidos na Tabela 4.10, observa-se que as avaliações são convergentes, em que a diferença entre os médicos é menor do que 1% em todos os níveis de classificação. Este fato é comprovado pelo índice Kappa de 0,614, indicando uma concordância substancial entre os médicos.

Já analisando os índices obtidos na Tabela 4.10 quanto à qualidade dos resultados nas segmentações, indicam que os dois métodos nas classes 1 e 5 são próximos, pois não têm ocorrência da classe 1 e na classe 5, os índices percentuais obtidos pelo método CR 3D são 17,05% e 18,18%, sendo um pouco superiores aos obtidos pelo MCA Crisp Adaptativo 3D que são 16,29% e 15,9%, entretanto, os resultados das classes 2, 3 e 4 são distintos entre os métodos.

Na classe 4, os resultados obtidos pelo CR 3D são 28,78% e 50%, indicando que o médico 1 observa pequenos erros em 28,78% e o médico 2 identifica 50% neste método. Entretanto, os dois médicos obtêm os mesmos 81,82% no MCA Crisp Adaptativo 3D, indicando a classe aceitável (pequenos erros) em mais de 80% das imagens.

Considerando os erros grosseiros determinados pela classe 3, os resultados obtidos pelo CR 3D são 46,59% e 29,55% e pelo MCA Crisp Adaptativo 3D são 1,51% e 1,89%, indicando que no MCA Crisp Adaptativo 3D a presença de erros grosseiros é menor que 2% na avaliação dos dois médicos. Isto já não ocorre com o método CR 3D, em que o médico M1 identifica a classificação razoável (erros grosseiros) em 46,59% e o médico M2 29,55%.

Já considerando a classe 2, os resultados obtidos pelo CR 3D são 7,58% e 2,27%, enquanto no MCA Crisp Adaptativo 3D são 0,38% e 0,38%, indicando que os dois médicos identificam segmentação de classe ruim, obtendo apenas uma pequena parcela do objeto de interesse nos dois métodos. Porém a incidência no CR 3D é mais significativa, chegando a 7,58%, ocorrendo em apenas uma imagem no MCA Crisp Adaptativo 3D, produzindo o índice percentual de 0,38%.

Considerando a qualidade de modo geral das segmentações, duas das classes são consideradas satisfatórias, sendo estas as classes 4 e 5. Estas duas classes são consideradas satisfatórias por indicarem que a segmentação não possui nenhum erro ou possuem pequenos erros, em que os médicos podem utilizar os resultados para análise das regiões interna pelo fato da região se aproximar da ideal, ou ser a região ideal propriamente dita. Além disto, estes pequenos erros podem ser corrigidos manualmente, desde que o sistema possua esta funcionalidade. Sendo assim, os resultados considerados satisfatórios são obtidos somando as classes 4 e 5.

Neste sentido, o método CR 3D obtém 45,83% e 68,18% e o MCA Crisp Adaptativo 3D obtém 98,11% e 97,72% de resultados satisfatórios segundo a avaliação dos médicos M1 e M2, respectivamente. Portanto, constata-se que o MCA Crisp Adaptativo 3D apresenta-se superior ao CR 3D segundo a análise dos dois médicos pneumologistas, em que o MCA Crisp Adaptativo 3D possui apenas 1,89% e 2,28% de resultados

insatisfatórios.

Alguns exemplos de resultados obtidos pelos métodos avaliados são apresentados nas Figuras 4.22, 4.23, 4.24 e 4.25, em que estas figuras apresentam os principais tipos de resultados obtidos entre as avaliações dos médicos avaliadores. Primeiramente, a Figura 4.22 apresenta um exemplo de avaliação 5 para os dois pulmões segundo os dois médicos especialistas.




Figura 4.22: exemplos de segmentação dos pulmões em imagens de TC em que ambos os médicos avaliaram a segmentação como ótima nos dois pulmões, obtendo avaliação 5. a) e d) imagens originais; b) e e) resultado utilizando Crescimento de Regiões 3D; e c) e f) resultado utilizando o MCA Crisp Adaptativo 3D.

São apresentados na Figura 4.23 exemplos de resultados avaliados com classificação distinta entre os médicos, devido a presença do hilo e da traquéia como região pulmonar, em que o médico M1 considera este erro sendo grosseiro e o médico M2 avalia este erro como pequeno.

Considerando as avaliações da Figura 4.23, o médico M1 atribuiu ao CR 3D a avaliação

3 no pulmão à esquerda da Figura 4.23(b) pela presença da traquéia e nos dois pulmões da Figura 4.23(e) pela presença do hilo, atribuindo nota 5 ao pulmão à direita da Figura 4.23(b). Já para o MCA Crisp Adaptativo 3D, o médico M1 avaliou os resultados da segmentação apresentados na Figura 4.23(c) com nota 5 e os resultados mostrados na Figura 4.23(f) com nota 4. A análise do médico M2 é igual ao do M1, exceto que os resultados com presença de hilo ou traquéia recebem classificação com nota 4 devido este médico considerar este erro sendo pequeno.




Figura 4.23: exemplos de segmentação dos pulmões em imagens de TC, sendo a) e d) imagens originais. O hilo é agregado à região pulmonar pelo Crescimento de Regiões 3D conforme apresentado em b) e e), o que não acontece utilizando o MCA Crisp Adaptativo 3D, cujo os resultados são apresentados em c) e f).

Outro erro presente na segmentação dos pulmões em imagens de TC que os médicos discordam é mostrado na Figura 4.24, em que, além do erro gerado pela presença do hilo ou traquéia, destaca-se também a presença de doenças no pulmão, no caso, fibrose.




Figura 4.24: exemplos de segmentação dos pulmões em imagens de TC com Fibrose, sendo a) e d) imagens originais. As regiões do pulmão com Fibrose são excluídas da região pulmonar no método Crescimento de Regiões 3D conforme apresentado em b) e e), o que não acontece utilizando o MCA Crisp Adaptativo 3D, cujo os resultados são apresentados em c) e f).

Considerando as avaliações da Figura 4.24, os médicos concordam com as avaliações realizadas quando existe doenças. Neste sentido, os médicos atribuíram ao CR 3D a classificação 3 aos dois pulmões apresentados na Figura 4.24(b) pela ausência na segmentação das regiões que apresentam fibrose, considerando este erro como grosseiro, além de que o pulmão à esquerda também agrega a traquéia à sua região. Além disto, os médicos avaliam a segmentação do pulmão à direita da Figura 4.24(e) com nota 3 por também não segmentar as regiões com fibrose, considerando um erro grosseiro, e o pulmão à esquerda com nota 2 por segmentar apenas parte do objeto, isto devido à doença estar presente na maior parte do pulmão em questão. Quanto ao MCA Crisp Adaptativo 3D,

os médicos atribuem aos pulmões à direita das Figuras 4.24(b) e 4.24(e) a nota 4, observando a presença de erros pequenos e nota 3 aos pulmões à esquerda das mesmas Figuras, caracterizando a presença de erros grosseiros.

Por último, a Figura 4.25 mostra resultados de segmentação com os erros já citados anteriormente, além de destacar a junção entre os pulmões esquerdo e direito na segmentação, em que a fronteira das duas regiões não existe nos resultados obtidos pelo CR 3D.




Figura 4.25: exemplos de segmentação dos pulmões em imagens de TC, sendo a) e d) imagens originais. As regiões do pulmão esquerdo e direito se confundem no método Crescimento de Regiões 3D conforme apresentado em b) e e), o que não acontece utilizando o MCA Crisp Adaptativo 3D, cujo os resultados são apresentados em c) e f).

A partir dos resultados mostrados na Figura 4.25, o médico M1 atribui nota 2 aos resultados de segmentação em que ocorrem a junção dos dois pulmões por considerar que este é um erro maior que grosseiro, entretanto o médico M2 atribui nota 4 para este erro,

considerando que este é um erro pequeno.

Sendo assim, o médico M1 atribui nota 2 para todos os pulmões presentes nas Figuras 4.25(b) e 4.25(e) obtidos pelo CR 3D devido ocorrer a junção dos dois pulmões. Além disto, este médico atribui nota 4 a todos os pulmões presentes nas Figuras 4.25(c) e 4.25(f), observando presença de erros pequenos. Já o médico M2 atribui as mesmas notas aos resultados do MCA Crisp Adaptativo 3D que o médico M1, porém atribui nota 4 aos pulmões presentes na Figura 4.25(b) e no pulmão à direita da Figura 4.25(e). Para o pulmão à esquerda da Figura 4.25(e), o médico M2 atribui nota 3, mas não pela junção dos pulmões e sim pela região com fibrose excluída nesta segmentação.

4.3.2 Avaliação do tempo de processamento

Para finalizar a comparação entre os métodos 3D avaliados, faz-se necessário uma análise quanto ao tempo de processamento dos mesmos na segmentação dos pulmões em exames de TC. O gráfico apresentado na Figura 4.26 mostra o tempo de processamento de cada método, considerando a quantidade de imagens de cada exame, sendo que os resultados do CR 3D estão em azul e do Crisp Adaptativo 3D em vermelho. Além disto, a estimativa do tempo de processamento de todas as imagens do exame de TC aplicando o MCA Crisp Adaptativo 2D, e sua reconstrução em 3D, é apresentado em verde. Os testes são realizados em um MacBook Pro Core i5 com 2.4GHz e 8GB de memória RAM.




Figura 4.26: gráfico do tempo de processamento versus quantidade de fatias do exame de TC aplicados em 11 exames.

Analisando o gráfico apresentado na Figura 4.26, conclui-se que o método CR 3D

possui o tempo de processamento menor do que o MCA Crisp Adaptativo 3D em todos os exames, obtendo aproximadamente metade do tempo de processamento.

Além disso, observa-se que o tempo de processamento do MCA Crisp Adaptativo 3D obtém tempo de processamento menor do que o mesmo método 2D. Isto ocorre, principalmente, devido as energias envolvidas no método 3D que aceleram a convergência do modelo em direção às paredes pulmonares. Outro fator importante para isto é a diminuição de processamento nos cálculos de inicialização de cada camada, pois cada nova camada é inicializada com base nas camadas já existentes no método 3D, reduzindo o processamento. Por último, as funções de deleção e adição de pontos no método 3D diminuem os erros que possam vir a surgir no modelo 3D de forma mais eficaz do que no método 2D, considerando que estas sejam aplicadas no exame completo de TC do tórax, acarretando menos processamento para diminuir o erro.

Capítulo 5

Conclusões, Contribuições e Trabalhos Futuros

Nesta tese são propostos dois métodos de contornos ativos, sendo um destes aplicado na segmentação de imagens 2D e o outro na segmentação de modelos 3D, compostos por um conjunto de imagens sobrepostas de forma ordenada.

O primeiro MCA proposto é denominado Crisp Adaptativo 2D é um novo método de segmentação automática dos pulmões em imagens de TC do tórax, possuindo como principais contribuições a energia interna Balão Adaptativa 2D, a energia externa Crisp Adaptativa 2D, a inicialização automática e a adição de pontos adaptativa. A energia externa deste método é baseada em uma RNA MLP e nas densidades pulmonares, apresentando-se capaz de identificar a origem das bordas dos pulmões, inclusive na presença de fibrose e enfisema, que tendem a aumentar e diminuir os valores das densidades radiológicas em UH, respectivamente. A energia interna utiliza informações dos seus vizinhos e da topologia da curva para empurrar a curva até a borda dos objetos.

Esse método é comparado com o sistema SISDEP e com os MCAS THRMod, THRMulti, GVF, VFC e Crisp na segmentação dos pulmões em imagens de TC de forma automática. Esta comparação utiliza as métricas de ajuste de posição, tamanho, intensidade e forma, tomando como padrão de referência a segmentação manual realizada por um médico pneumologista. Nesta avaliação são considerados 72 pulmões, sendo 24 de voluntários sádios, 24 de pacientes com DPOC e 24 de pacientes com Fibrose.

A partir dos resultados obtidos nestes testes, analisando os métodos quanto às medidas de ajuste encontradas, conclui-se que os MCAS THRMod, THRMulti, GVF, VFC e Crisp oscilam significativamente seus resultados quando aplicados em imagens de pacientes com doenças e em imagens com níveis de corte distintos. Entretanto, o método desenvolvido no

sistema SISDEP e o MCA Crisp Adaptativo 2D aplicados na segmentação dos pulmões apresentam-se superiores aos demais quando empregados na segmentação dos pulmões em imagens de TC do tórax de voluntários saudáveis, pacientes com DPOC e pacientes com fibrose. Estes métodos obtêm medida de ajuste de posição superior a 99,5% e medidas de ajuste de intensidade, tamanho e forma superiores a 90% em todos os pulmões testados, mantendo estes índices de medidas de ajuste nos três tipos de imagens analisadas, normal, fibrose e DPOC, e nos três níveis de corte considerados, ápice, hilo e base.

Com relação ao tempo médio de processamento, conclui-se que os valores obtidos pelo MCA Crisp Adaptativo 2D é metade do tempo médio de processamento obtido pelo método do sistema SISDEP quando aplicado na segmentação dos pulmões em imagens de TC do tórax. Portanto, pode-se concluir que o MCA Crisp Adaptativo 2D possui baixo custo computacional, comparado aos outros métodos analisados. Além disso, obtêm altos índices de ajuste em todos os níveis de corte experimentados, considerando imagens de voluntário saudável, paciente com DPOC e fibrose.

O segundo método proposto nesta tese é denominado Crisp Adaptativo 3D que é um novo método de segmentação automática dos pulmões em exames de TC do tórax, possuindo como principais contribuições a energia externa Crisp Adaptativa 3D, a energia interna Balão Adaptativa 3D, a inicialização 3D automática, adição e remoção de pontos 3D. A energia externa deste método é a expansão da energia externa Crisp Adaptativa 2D para 3D, enquanto a energia interna é a expansão da energia Balão Adaptativa 2D, ambas considerando as informações das curvas presentes nas camadas vizinhas.

O Crisp Adaptativo 3D é comparado com o CR 3D na segmentação de exames de TC do tórax de voluntário saudável e de pacientes com DPOC e fibrose, nos quais os resultados obtidos por estes métodos são avaliados de forma qualitativa por dois médicos pneumologistas. Considerando-se resultados ditos como satisfatórios na segmentação aqueles em que o método não apresenta erro ou apenas pequenos erros, conclui-se que o método CR 3D obtém 45,83% e 68,18% e o MCA Crisp Adaptativo 3D obtém 98,11% e 97,72% de resultados satisfatórios, segundo a avaliação dos médicos M1 e M2, respectivamente. Deste modo, o MCA proposto apresenta-se superior ao CR 3D segundo a análise dos dois médicos pneumologistas, em que o MCA Crisp Adaptativo 3D possui apenas 1,89% e 2,28% de resultados insatisfatórios.

O MCA Crisp Adaptativo 3D também apresenta-se superior ao CR 3D quanto à concordância entre a avaliação dos médicos para cada método, obtendo uma concordância substancial, enquanto o CR 3D obtém apenas uma concordância moderada. Isto ocorre

devido o CR 3D apresentar erros que o método proposto não apresenta, podendo ser citados à inclusão do hilo e traquéia como região pulmonar, exclusão de parte do pulmão com doença, a junção dos pulmões, entre outros. Estes erros são avaliados de maneira distinta por cada médico, gerando uma concordância menor do que o MCA Crisp Adaptativo 3D. Entretanto, o CR 3D apresenta-se superior ao MCA Crisp Adaptativo 3D quanto ao tempo de processamento, consumindo aproximadamente a metade do tempo de processamento do MCA proposto. Vale ressaltar que o MCA Crisp Adaptativo 3D, comparado com este mesmo método em 2D segmentando todas as imagens do exame de TC obtém menores tempos de processamento, demonstrando o aumento da velocidade de convergência do método 3D em relação ao 2D.

Deste modo, resumidamente, as principais contribuições desta tese são: o MCA Crisp Adaptativo 2D, o MCA Crisp Adaptativo 3D, inicialização automática dentro dos pulmões em duas e três dimensões, métodos de adição e remoção de pontos em duas e três dimensões e a visualização dos pulmões em 3D. Além disso, diversas publicações são produzidas, indicando que a comunidade acadêmica reconhece tais contribuições.

Todo o desenvolvimento do trabalho de tese, bem como os resultados obtidos não esgota a pesquisa com MCAs Adaptativos. Neste sentido, pode-se propor os seguintes trabalhos futuros:

- aplicar outras técnicas de Inteligência Computacional e Reconhecimento de Padrões na detecção da origem das bordas encontradas no pulmão;
- adaptar os métodos desenvolvidos para detecção de outros órgãos;
- investigar os métodos desenvolvidos para detecção de doenças do pulmão, ou de outros órgãos; e
- adaptar os métodos desenvolvidos para detecção dos lóbulos pulmonares.

Referências Bibliográficas

- ADAM, D.; HAREUVENI, O.; SIDEMAN, S. Semiautomated border tracking of cine echocardiogram ventricular images. *IEEE Transactions on Medical Imaging*, v. 6, n. 3, p. 266–271, 1987.
- ALBUQUERQUE, V. H. C. de; TAVARES, J.; Rebouças Filho, P. P. Medição automática da dureza brinell utilizando técnicas de processamento e análise de imagem. *5th Congresso Luso-Moçambicano de Engenharia*, Maputo - Angola, 2008.
- ALEXANDRIA, A. R. de. *Sistema de Reconhecimento Óptico de Algarismos para Medidores Convencionais de Energia*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, Junho 2005.
- ALEXANDRIA, A. R. de. *Psnakes: método de contornos ativos radial usando energia Hilbertiana para a segmentação do ventrículo esquerdo em imagens de ultrassom*. Tese (Doutorado) — Universidade Federal do Ceará - UFC, Fortaleza, Ceará, Brasil, 2011.
- AMINI, A. A.; WEYMOUTH, T. E.; JAIN, R. C. Using dynamic programming for solving variational problems in vision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 12, n. 9, p. 855–867, Setembro 1990.
- ASTLE, D.; HAWKINS, K. *More OpenGL Game Programming*. EUA: Thomson, 2005.
- ASTLE, D.; HAWKINS, K. *Beginning OpenGL Game Programming*. 2nd. ed. EUA: Thomson, 2009.
- BARRETT, W. A.; CLAYTON, P. D.; WARNER, H. R. Determination of left ventricular contours: a probabilistic algorithm derived from angiographic images. *Computers and Biomedical Research*, v. 13, n. 6, p. 522–548, 1980.
- BARROS, A. C. da S. *Análise comparativa de técnicas de detecção de movimento e rastreamento de objetos em vídeo digital utilizando dispositivos móveis*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, CE, Março 2010.

- BERG, G. et al. The constructive jordan curve theorem. *JOURNAL OF MATHEMATICS* - *Spring*, v. 5, n. 2, 1975.
- BERNSEN, J. Dynamic thresholding of gray-level images. *Proc. Eighth International Conference on Pattern Recognition*, Paris, p. 1251–1255, Outubro 1986.
- BONTRAGER, K. L. *Tratado de Técnica Radiológica e Base Anatômica*. 5. ed. Rio de Janeiro: Guanabara Koogan, 2000.
- BORN, S. et al. 3-step segmentation of the lower airways with advanced leakage-control. *IJCAI 2009 Workshop on Explanation Aware Computing*, p. 239–255, 2009.
- BOUHOURS, A. *Segmentação do ventrículo esquerdo em ecocardiograma usando contornos ativos (snake)*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, CE, Setembro 2006.
- CAMPOS, H.; LEMOS, A. A asma e a dpoc na visão do pneumologista. *Jornal Brasileiro de Pneumologia*, v. 35, n. 4, 2009.
- CAN, A.; BELLO, M. O.; GERDES, M. Quantification of subcellular molecules in tissue microarray. *International Conference on Pattern Recognition*, 2010.
- CARVALHO, E. et al. SAR imagery segmentation by statistical region growing and hierarchical merging. *Digital Signal Processing*, v. 20, n. 5, p. 1365 – 1378, Setembro 2010. ISSN 1051-2004.
- CAVALCANTE, T. et al. Comparative analysis of segmentation techniques of airways on images of chest computed tomography. *Signals and Image Processing*, Rio de Janeiro, 2010.
- CAVALCANTE, T. et al. Segmentação de vias aéreas em imagens de tomografia computadorizada por métodos de contornos ativos. Tiradentes, MG, 2010.
- CAVALCANTE, T. da S. *Técnica para Segmentação Automática de Vias Aéreas em Imagens de Tomografia Computadorizada do Tórax*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, CE, Outubro 2010.
- CAVALCANTE, T. S. et al. Comparative analysis of segmentation techniques of airways on images of chest computed tomography. In: *17th International Conference on Systems, Signals and Image Processing-IWSSIP*. Rio de Janeiro, RJ: IWSSIP, 2010. p. 1–4.

- CAVES, R.; QUEGAN, S.; WHITE, R. Quantitative comparison of the performance of SAR segmentation algorithms. *IEEE Transactions on Image Processing*, v. 7, n. 11, p. 1534–1546, Novembro 1998.
- CHEN, Q. et al. Parametric active contours for object tracking based on matching degree image of object contour points. *Pattern Recognition Letters*, v. 29, p. 126–141, 2006.
- COCQUEREZ, J. P.; PHILLIP, S. Analyse d'images: filtrage et segmentation. *Masson*, France, p. 240–245, 1995.
- COHEN, L. D. On active contour models and balloons. *CVGIP: Image Underst.*, Academic Press, Inc., Orlando, FL, EUA, v. 53, n. 2, p. 211–218, 1991. ISSN 1049-9660.
- COHEN, M.; MANSSOUR, I. H. *OpenGL: Uma abordagem prática e objetiva*. [S.l.]: Novatec, 2006. 486 p.
- CONGALTON, R. G.; GREEN, K. *Assessing the accuracy of remotely sensed data: Principles and practices*. New York: Lewis Publishers, 1999.
- COPPINI, G.; POLI, R.; VALLI, G. Recovery of the 3-d shape of the left ventricle from echocardiographic images. *IEEE Transactions on Medical Imaging*, v. 14, n. 2, p. 301–317, Junho 1995.
- COXSON, H. O. et al. A quantification of the lung surface area in emphysema using computed tomography. *Am. J. Respir. Crit. Care Med.*, v. 159, p. 851–856, 1999.
- DAVIS, D.; LINYING, S.; SHARP, B. Neural networks for x-ray image segmentation. *12th International Conference on Control Systems and Computer Science*, p. 264 – 271, Março 1999.
- DAVIS, J. A. et al. Image processing with the radial Hilbert transform: theory and experiments. *Optics Letters*, Optical Society of America, v. 25, n. 2, p. 99–101, 2000.
- DELVES, L. M. et al. Comparing the performance of sar image segmentation algorithms. *International Journal of Remote Sensing*, v. 13, p. 2121–2149, 1992.
- DLUGOSZ, F. L. et al. Índice para a avaliação de segmentação de imagens. *Floresta*, Curitiba, PR, p. 131–143, Jan-Mar 2009.
- DUNDAR, M. M. et al. Computerized classification of intraductal breast lesions using histopathological images. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, v. 58, n. 7, July 2011.

ENGELKE, U.; PITREY, Y.; CALLET, P. L. Towards an inter-observer analysis framework for multimedia quality assessment. *Third International Workshop on Quality of Multimedia Experience*, p. 183–188, 2011.

EPSTEIN, C. L. *The Mathematics of Medical Imaging*. Philadelphia, EUA: Universidade da Pennsylvania, 2001.

EZHIL, M. et al. Validation of a model-based segmentation approach to propagating normal anatomic regions of interest through the 10 phases of respiration. *International Journal of Radiation Oncology, Biology and Physics*, v. 71, n. 3, p. 900 – 906, Julho 2008.

FELIX, J. et al. Novo método de contornos ativo baseado na transforma de hilbert radial. Havana - Cuba, 2011.

FELIX, J.; CORTEZ, P.; HOLANDA, M. A. Um novo algoritmo de segmentação automática de imagens tomográficas dospulmões. In: *XI Congresso Brasileiro de informática em Saúde - CBIS*. Campos do Jordão, SP: Sociedade brasileira de informática em saúde, 2008. p. 1–6.

FELIX, J. H. da S. *Metodos de Contornos Ativos Hilbert 2D na segmentação de imagens dos pulmões em Tomografia Computadorizada do Tórax*. Tese (Doutorado) — Universidade Federal do Ceará - UFC, Fortaleza, Ceará, Brasil, Março 2011.

FELIX, J. H. S. *Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, CE, Dezembro 2007.

FELIX, J. H. S. et al. Avaliação computacional de enfisema pulmonar em tc: comparação entre um sistema desenvolvido localmente e um sistema de uso livre. *Jornal Brasileiro de Pneumologia*, São Paulo, v. 35, n. 9, p. 868–876, Setembro 2009. ISSN 1806-3713.

FELIX, J. H. S.; CORTEZ, P. C.; HOLANDA, M. A. Sistema automático para quantificação e visualização da aeração pulmonar em imagens de tomografia computadorizada de tórax: Sistema de análise de imagens pulmonares - saip. *Revista Brasileira de Engenharia Biomédica*, São Paulo, v. 00, n. 0, p. 00–00, Dezembro 2010. ISSN 0102-2644.

FELIX, J. H. S. et al. Automatic segmentation and measurement of the lungs in healthy persons and in patients with chronic obstructive pulmonary disease in ct images. *IFMBE Proceedings*, v. 18, p. 370–373, Outubro 2007.

FELIX, J. H. S. et al. Lung and chest wall structures segmentation in ct images. *VIPIMAGE*, Outubro 2007.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de exatidão global, kappa e tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. *Anais XIII Simpósio Brasileiro de Sensoriamento Remoto*, Florianópolis, Brasil, p. 5755–5762, Abril 2007.

FIGUEIREDO, L.; CARVALHO, P. *Introdução à Geometria Computacional*. [S.l.]: IMPA, 1991.

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, CE, 2006.

GEBRIN, E. M. S. Incorporação de novas tecnologias em tomografia computadorizada. *Radiologia Brasileira*, v. 37, n. 1, p. 3–4, Fevereiro 2004. ISSN 0100-3984.

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

GONZALEZ, R. C.; WOODS, R. *Digital Image Processing*. 3a. ed. New Jersey: Pearson Prentice Hall, 2010. ISBN 0-13-168728-x.

GOSHTASBY, A.; TURNER, D. Segmentation of cardiac cine MR images for extraction of right and left ventricular chambers. *IEEE Transactions on Medical Imaging*, v. 14, n. 1, p. 56–64, Março 1995.

GUANLEI, X.; XIAOTONG, W.; XIAOGANG, X. Generalized Hilbert transform and its properties in 2D LCT domain. *Signal Process.*, Elsevier North-Holland, Inc., Amsterdã, Holanda, v. 89, n. 7, p. 1395–1402, 2009. ISSN 0165-1684.

HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd. ed. EUA: Prentice-Hall, 1999.

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

HERMAN, G. T. *Fundamentals of Computerized Tomography: Image Reconstruction from Projections (Advances in Pattern Recognition)*. 2. ed. Nova York, EUA: Springer, 2009. 300 p. ISBN 978-1-85233-617-2.

- HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. description of system. *British Journal of Radiology*, v. 46, p. 1016–1022, 1973.
- 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. ISSN 0278-0062.
- IRVING, B.; TAYLOR, P.; TODD-POKROPEK, A. 3d segmentation of the airway tree using a morphology based method. *IJCAI 2009 Workshop on Explanation Aware Computing*, p. 297–307, 2009.
- ITAI, Y.; KIM, H.; ISHIKAWA, S. A segmentation method of lung areas by using snakes and automatic detection of abnormal shadow on the areas. *International Journal of Innovative Computing Information and Control*, v. 3, n. 2, p. 277–284, Abril 2007.
- 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*. Boca Raton, EUA: CRC Press, 2006.
- JOHANNSEN, G.; BILLE, J. A threshold selection method using information measures. *6th Int. Conf. Pattern Recognition*, Munique, Alemanha, p. 140–143, 1982.
- KALENDER, W. A. Review: X-ray computed tomography. *Physics in Medicine and Biology*, v. 51, n. 13, p. 29–43, Junho 2006.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. *International Journal of Computer Vision*, v. 1, n. 4, p. 321–331, 1987.
- KOHLMANN, K. Corner detection in natural images based on the 2-D Hilbert transform. *Signal Processing*, Inc. Elsevier North-Holland, Amsterdã, Holanda, v. 48, n. 3, p. 225–234, 1996. ISSN 0165-1684.
- LASZLO, M. *Computational Geometry and Computer Graphics in C++*. [S.l.]: Prentice Hall, 1996.
- LI, B.; ACTON, S. Vector field convolution for image segmentation using snakes. In: *IEEE International Conference on Image Processing*. Atlanta, EUA: IEEE Image Processing, 2006. p. 1637–1640. ISSN 1522-4880.

LI, B.; ACTON, S. Active contour external force using vector field convolution for image segmentation. *IEEE Transactions on Image Processing*, v. 16, n. 8, p. 2096–2106, Agosto 2007. ISSN 1057-7149.

LI, C.; LIU, J.; FOX, M. D. Segmentation of edge preserving gradient vector flow: An approach toward automatically initializing and splitting of snakes. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005.

LIANG, J.; DING, G.; WU, Y. Segmentation of the left ventricle from cardiac MR images based on radial GVF snake. In: *International Conference on BioMedical Engineering and Informatics - BMEI*. Sanya: IEEE BMEI, 2008. v. 2, n. 1, p. 238–242.

LIANG, T. K. et al. An automated 3d emphysema extraction method using lung ct. *SICE Annual Conference 2008*, The University Electro-Communications, Japan, p. 3110–3114, 2008.

LILLY, P.; JENKINS, J.; BOURDILLON, P. Automatic contour definition on left ventriculograms by image evidence and a multiple template-based model. *IEEE Transactions on Medical Imaging*, v. 8, n. 2, p. 173–185, Junho 1989.

LUCCA, E. V. D. *Avaliação e Comparação de Algoritmos de Segmentação de Imagens de Radar de Abertura Sintética*. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, Dezembro 1998.

LV, X.; GAO, X.; ZOU, H. Interactive curved planar reformation based on snake model. *Computerized Medical Imaging and Graphics*, v. 32, n. 8, p. 662 – 669, 2008. ISSN 0895-6111.

MACKIEWICH, B. *Intracranial Boundary Detection and Radio Frequency Correction in Magnetic Resonance Images*. Dissertação (Mestrado) — Universidade Simon Fraser, Canadá, Agosto 1995.

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

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.

MARCO, R. de et al. An international survey of chronic obstructive pulmonary disease in young adults according to gold stages. *Thorax*, v. 59, p. 120–125, Julho 2004.

MATSUOKA, S. et al. Quantitative ct assessment of chronic obstructive pulmonary disease. *RadioGraphics*, v. 30, p. 55–66, 2010.

MCINERNEY, T.; TERZOPOULOS, D. Deformable models in medical image analysis: A survey. *Medical Image Analysis*, v. 1, n. 2, p. 91–108, 1996.

MEDEIROS, C. *Uma contribuição ao problema de seleção de modelos neurais usando o princípio de máxima correlação dos erros*. Tese (Doutorado) — Tese (doutorado) Universidade Federal do Ceará, UFC, Departamento de Engenharia Teleinformática, 2008.

NIXON, M. S.; AGUADO, A. S. *Feature Extraction and Image Processing*. 1. ed. Woburn, MA: Newnes, 2002. ISBN 0750650788.

OMS. *Global Strategy for the Diagnosis, Management and Prevention Chronic Obstructive Pulmonar Disease*. [S.l.: s.n.], 2008.

PAPAMARKOS, N.; STROUTHOPOULOS, C.; ANDREADIS, I. Multithresholding of color and grey-level images through a neural network technique. *Image and Vision Computing*, v. 18, n. 213-222, 2000.

PARK, H.; SCHOEPFLIN, T.; KIM, Y. Active contour model with gradient directional information: directional snake. *IEEE Transactions on Circuits and Systems for Video Technology*, v. 11, n. 2, p. 252–256, Fevereiro 2001. ISSN 1051-8215.

PEI, S.-C.; DING, J.-J. The generalized radial Hilbert transform and its applications to 2D edge detection (any direction or specified directions). In: *IEEE International Conference on Acoustics, Speech, and Signal Processing - ICASSP*. Toulouse, France: IEEE Signal Processing Society, 2003. v. 3, n. 1, p. III–357–60. ISSN 1520-6149.

PEI, S.-C. et al. Short response Hilbert transform for edge detection. In: *IEEE Asia Pacific Conference on Circuits and Systems - APCCAS*. Macau: IEEE circuits and systems, 2008. v. 1, n. 1, p. 340–343.

PEI, S.-C.; YEH, M.-H. Discrete fractional Hilbert transform. *IEEE Transactionson Circuits and Systems II: Analog and Digital Signal Processing*, v. 47, n. 11, p. 1307–1311, Novembro 2000. ISSN 1057-7130.

- PICHUMANI, R. *Construction of A Three-Dimensional Geometric Model for Segmentation and Visualization of Cervical Spine Images*. Tese (Doutorado) — Medical Informatics of Stanford University, 1997.
- PLUEMPITIWIRIYAWAJ, C.; SOTTHIVIRAT, S. Active contours with automatic initialization for myocardial perfusion analysis. In: *27th Annual International Conference of the Engineering in Medicine and Biology Society - IEEE-EMBS*. Shanghai: IEEE EMBS, 2005. p. 3332–3335.
- POPE, D. L. et al. Left ventricular border recognition using a dynamic search algorithm. *Radiology*, v. 155, n. 2, p. 513–518, 1985.
- REBOUÇAS FILHO, P. P. *MCA Crisp: nova técnica de segmentação dos pulmões em imagens de Tomografia Computadorizada baseada no Método de Contorno Ativo*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, CE, Março 2010.
- REBOUÇAS FILHO, P. P. et al. Measurement of welding dilution from images using active contours. *South-East European Conference on Computational Mechanics - SEECCM 2009*, Island of Rhodes, 2009.
- RIBEIRO, A. B. N. *SEGMENTAÇÃO DOS VASOS SANGUÍNEOS PULMONARES EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX*. Dissertação (Mestrado) — Univesidade Federal do Ceará, Fortaleza, Março 2013.
- ROSEMBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, p. 386–408, 1958.
- SANTOS, B. S. et al. Quantitative evaluation of a pulmonary contour segmentation algorithm in X-ray computed tomography images. *Academic Radiology*, v. 11, n. 8, p. 868 – 878, Agosto 2004.
- SANTOS, J. D. de A. *Sobre a estimação do número de neurônios ocultos da rede MLP: Uma nova técnica baseada em PCA e SVD*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, CE, 2010.
- SHANG, Y. et al. Active volume models for medical image segmentation. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, v. 58, n. 4, p. 1023–1032, 2011.
- SHEN, T.; LI, H.; HUANG, X. Active volume models for medical image segmentation. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, p. 774–791, 2011.

SHEN, T. et al. Active volume models for 3d medical image segmentation. *IEEE*, p. 707–714, 2009.

SHEN, W.; KASSIM, A. A. A new scheme for automatic initialization of deformable models. In: *IEEE International Conference on Image Processing - ICIP*. San Antonio, EUA: IEEE Signal Processing Society, 2007. v. 4, p. IV–289 – IV–292. ISSN 1522-4880.

SHOJAII, R.; ALIREZAIE, J.; BABYN, P. Automatic lung segmentation in CT images using watershed transform. *IEEE International Conference on Image Processing-ICIP*, v. 2, p. 1270–1273, Setembro 2005.

SIEGWART, R.; NOURBAKHSI, I. *Introduction to Autonomous Mobile Robots*. [S.l.]: The MIT Press, 2004. ISBN 0-262-19502-X.

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. In: *Proc SPIE Conf on Medical Imaging: Physiology and Function from Multidimensional Images*. San Diego, EUA: SPIE Digital Library, 2001. v. 4321, p. 216–224.

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, Rio de Janeiro, Brasil, Fevereiro 2004.

SILVA, A. C. et al. Segmentation and reconstruction of the pulmonary parenchyma. p. 73–82, Maio 2006.

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

SILVA JUNIOR, J. de A. C. et al. Análise comparativa de métodos de contornos ativos aplicados na segmentação do ventrículo esquerdo em imagens digitais de ecocardiograma. In: *XII Congresso Brasileiro de Informática em Saúde*. Porto de Galinhas, PE: CBIS, 2010. v. 1, p. 1–4.

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) — Universidade Medical Center Utrecht, Utrecht, Holanda, 2005.
- SOILLE, P. *Morphological Image Analysis: Principles and Applications*. Secaucus, NJ: Springer-Verlag Nova York, Inc., 2004. ISBN 3540429883.
- SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis, and Machine Vision*. 3. ed. EUA: Thomson, 2008. ISBN 10:0-495-24438-4.
- SOUZA, A. M. de. *Identificação de tumores cerebrais por meio do modelo de contornos ativo se algoritmos genéticos*. Dissertação (Mestrado) — Curso de Pós-graduação em Informática do Setor de Ciências Exatas da Universidade Federal do Paraná, Curitiba, PR, 2003.
- Souza Júnior, O. S. de. *Método de Reconhecimento pessoal através da íris usando funções geoestatísticas*. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2006.
- TARATORIN, A.; SIDEMAN, S. Constrained detection of left ventricular boundaries from cine ct images of human hearts. *IEEE Transactions on Medical Imaging*, v. 12, n. 3, p. 521–533, Setembro 1993.
- TAUBER, C.; BATATIA, H.; AYACHE, A. A general quasi-automatic initialization for snakes: application to ultrasound images. In: *IEEE International Conference on Image Processing - ICIP*. Gênova, Itália: IEEE Image Processing, 2005. v. 2, n. 1, p. II-806–9.
- TERZOPOULOS, D. et al. Elastically deformable models. *Computer Graphics*, v. 21, n. 4, p. 205–214, 1987.
- THEDENS, D.; SKORTON, D.; FLEAGLE, S. Methods of graph searching for border detection in image sequences with applications to cardiac magnetic resonance imaging. *IEEE Transactions on Medical Imaging*, v. 14, n. 1, p. 42–55, Março 1995.
- TOSHIBA. *Manual de operação do sistema: tomógrafo computadorizado de raio-x para corpo inteiro: Aquisição de dados de calibração*. São Paulo, 1997.
- TSCHIRREN, J.; YAVARNA, T.; REINHARDT, J. 3d segmentation of the airway tree using a morphology based method. *IJCAI 2009 Workshop on Explanation Aware Computing*, p. 227–238, 2009.
- VIEIRA, S. R. R. et al. A lung computed tomographic assessment of positive end-expiratory pressure-induced lung over distension. *American Journal of Respiratory and Critical Care Medicine*, v. 158, p. 1571–1577, 1998.

- WILLIAMS, D.; SHAM, M. A fast algorithm for active contours and curvature. *Image Understanding*, 1992.
- 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.
- XU, C.; PRINCE, J. L. Gradient vector flow: A new external force for snakes. In: *Proceedings IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. San Juan: IEEE Computer Society, 1997. p. 66–71.
- YIN, X.; LIU, C.; HAN, Z. Feature combination using boosting. *Pattern Recognition Letters*, v. 25, n. 14, p. 2195–2205, April 2005.
- ZAHARA, E.; FAN, S.-K. S.; TSAI, D.-M. Optimal multi-thresholding using a hybrid optimization approach. *Pattern Recognition Letters*, v. 26, n. 8, p. 1082–1095, June 2005.
- ZHANG, D. et al. Analysis of image fusion and classification for high resolution sar data on-line. *2nd International Conference on Education Technology and Computer (ICETC)*, 2010.
- ZHANG, Y. J. A survey on evaluation methods for image segmentation. *Pattern Recognition*, v. 29, n. 8, p. 1335–1346, 1996.

Apêndices

Apêndice A

Aplicações no auxílio ao diagnóstico médico dos pulmões

Dentre as áreas de pesquisa voltadas para o auxílio ao diagnóstico médico, tem-se destacado a área da Pneumologia, visto que diversas doenças podem ser detectadas e acompanhadas através de imagens de TC do tórax dos pulmões.

Isto é possível devido ao desenvolvimento de *softwares* voltados para este fim, em que os pulmões presentes em imagens de TC do tórax são extraídos e, posteriormente, analisados através de algoritmos de Reconhecimento de Padrões e Inteligência Artificial para detectar doenças e estruturas internas dos pulmões.

Exemplos de segmentação dos pulmões em imagens de TC do tórax são apresentados na Figura A.1, em que a região pulmonar é delimitada em vermelho.




Figura A.1: exemplo de segmentação dos pulmões em imagens de TC realizada manualmente por médicos especialistas.

Enquanto isto, a Figura A.2 apresenta um exemplo de segmentação dos pulmões utilizando um exame completo de TC do tórax, possibilitando a reconstrução dos pulmões em 3D. Vale ressaltar que este modelo pode ser apresentado de forma transparente, como apresentado na Figura A.14, para que as doenças e as estruturas internas possam ser visualizadas.




Figura A.2: exemplo de visualização dos pulmões em 3D, sendo a)reconstrução dos pulmões e b)modelo transparente de a).

A.1 Visualização por cortes da reconstrução 3D

A reconstrução 3D dos pulmões obtida através de um exame completo de TC do tórax possibilita visualizar a anatomia dos pulmões em 3D. Além disto, planos de cortes podem ser inseridos na visualização 3D para auxiliar o médico especialista com visualizações auxiliares de planos de cortes específicos. Este método de visualização através de um modelo e seus planos de cortes aumentam a exatidão do diagnóstico do médico especialista a medida que aumenta a quantidade de informações do mesmo.

Para exemplificar estes planos, são apresentados na Figura A.3 um modelo 3D juntamente com os planos axial, sagital e coronal auxiliando na visualização dos pulmões em imagens de TC do tórax. Ressaltando que este modelo 3D é obtido através da reconstrução do exame de TC utilizando apenas imagens no eixo axial, e os outros planos de cortes são obtidos através do modelo 3D reconstruído.



(a)



(b)



(c)



(d)

Figura A.3: modelos 3D apresentado juntamente com os planos de corte axial, sagital e coronal auxiliando na visualização dos pulmões.

A.2 Aplicação de máscara colorida

De acordo com Felix (2007), uma opção de análise das imagens de TC é a aplicação de máscaras coloridas na imagem analisada. Esta técnica baseia-se em selecionar uma faixa de densidade radiológica expressa em Unidades Hounsfiels(UH), e todos os pixels desta imagem que estiverem na faixa selecionada são identificados e apresentados por cor selecionada previamente. Estes pixels podem também ser contabilizados para levantamento estatístico de faixa analisada em relação as demais.

O sistema SISDEP, desenvolvido por Felix (2007), aplica esta máscara colorida na região pulmonar previamente segmentada, sendo capaz de quantificar dados de cada faixa selecionada. Deste modo, a Figura A.4 apresenta um exemplo da aplicação da máscara colorida utilizando 4 faixas distintas, em que a Figura A.4(a) é a imagem original, a Figura A.4(b) é o resultado da máscara colorida na região somente nas regiões dos pulmões e a Tabela A.1 apresenta os dados de cada faixa e a análise estatística das mesmas.




Figura A.4: exemplo de resultado da aplicação da máscara colorida utilizando o sistemas SISDEP (FELIX, 2007), sendo a)imagem original e b)resultado da máscara colorida aplicada em a).

Tabela A.1: *análise estatística do resultados apresentados na Figura A.4 obtidos através da máscara colorida utilizando o SISDEP (FELIX, 2007).*

Faixa em UH	Cores	Área (mm^2)	(%)na imagem
Abaixo de -951	verde claro	20.703,25	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%

Outra análise possível é a aplicação da máscara colorida e suas medidas estatísticas

dividindo os pulmões em sub-áreas determinadas pelo médico pneumologista, auxiliando o mesmo em uma análise mais detalhada dos pulmões. Um exemplo disto é apresentado na Figura A.5.




Figura A.5: exemplo de resultado da aplicação da máscara colorida em sub-áreas utilizando o sistemas SISDEP (FELIX, 2007).

Tabela A.2: análise estatística do resultados apresentados na Figura A.5 obtidos através da máscara colorida por sub-áreas utilizando o SISDEP (FELIX, 2007).

Pulmão - Região	Área (mm^2)	(%)na imagem	(%)na Região
Esquerdo - 1	1524,612	4,321%	9,164%
Esquerdo - 2	2167,653	6,143%	13,028%
Esquerdo - 3	811,073	2,299%	4,875%
Direito - 1	1657,053	4,696%	8,175%
Direito - 2	2310,361	6,657%	11,624%
Direito - 3	736,126	2,086%	4,349%

A.3 Detecção de doenças e estruturas internas do pulmão utilizando máscara colorida

A técnica de limiar utilizada na máscara colorida que delimita as faixas de densidade radiológicas de interesse, rotulando-as de acordo com o desejado permite detectar diversos tipos de estruturas internas do pulmão, estruturas externas ao pulmão e doenças pulmonares.

A.3.1 Detecção e análise de enfisema

Um exemplo de doença que pode ser detectada com esta técnica é o enfisema pulmonar. Esta doença caracteriza-se pela presença de densidades radiológicas entre -950 e -1000 Unidades Hounsfields, sendo esta faixa rotulada como região hiperaerada.

Esta técnica pode ser aplicada apenas em uma imagem ou em um exame completo de TC do tórax, sendo assim a Figura A.6 apresenta as regiões hiperaeradas em uma imagem de TC do pulmão em verde, enquanto a Figura A.7 apresenta o resultado desta técnica aplicada em um exame completo de TC do tórax, incluindo no modelo 3D as regiões hiperaeradas detectadas em todo o exame, apresentando estes pontos dentro do modelo 3D.




Figura A.6: exemplo de detecção de região hiperaerada em uma imagem de TC do tórax.



Figura A.7: exemplo de modelo 3D com detecção de região hiperaerada em um exame completo de TC tórax.

Vale ressaltar que a técnica de visualização por cortes apresentada na seção A.1 pode auxiliar na visualização destas regiões através dos cortes auxiliares.

A.3.2 Detecção dos vasos pulmonares

Dentre as estruturas internas ao pulmão, destaca-se a detecção dos vasos que de forma geral, podem ser detectados através de limiarização, inclusive podendo ser apresentados através de uma máscara colorida. Estas estruturas caracterizam-se pela densidades radiológicas entre -100 e -500 Unidades Hounsfields, sendo esta faixa rotulada como região pouco aerada. Dois exemplos destas regiões em imagens de TC do tórax são apresentados na Figura A.8, em que esta técnica é aplicada somente na região pulmonar previamente segmentada.




Figura A.8: exemplos da segmentação dos vasos sanguíneos internos ao pulmão obtidos por Ribeiro (2013), sendo a) e c) imagens originais e b) e d) vasos sanguíneos encontrados em a) e c), respectivamente.

Expandindo esta detecção para o exame completo de TC do tórax, em que este método é aplicado individualmente em cada imagem, é possível apresentar os vasos sanguíneos

presentes em todo o pulmão. Um exemplo disto é apresentado na Figura A.10, em que os vasos podem ser apresentados individualmente ou dentro dos pulmões.




Figura A.9: exemplo de visualização dos vasos presentes em um exame de TC do tórax, sendo a) vasos sanguíneos e b) os pulmões e os vasos apresentados em a).

Existem outras técnicas mais eficazes para determinar os vasos, como, por exemplo, a desenvolvida por Ribeiro (2013), em que o autor associa as técnicas Crescimento de Regiões 3D com lógica fuzzy. Exemplos de resultados destas técnicas são apresentados na Figura A.10.




Figura A.10: exemplos de visualização 3D da segmentação dos vasos sanguíneos internos ao pulmão obtidos por Ribeiro (2013).

A.4 Detecção de estruturas do corpo humano em exames de TC do tórax

Outras estruturas não internas ao pulmão também podem ser detectadas e analisadas em exames de TC do tórax. Dentre estas, destacam-se a região óssea e as vias aéreas.

A.4.1 Detecção e análise da região óssea

A região óssea caracteriza-se por estar na faixa entre 600 a 2000 UH, e pode ser detectada através de um limiar utilizando a faixa citada ou até mesmo um Crescimento de Regiões 3D. Deste modo, um exemplo aplicando a limiarização em uma imagem de TC do tórax para detecção da região óssea é apresentada na Figura A.11. Enquanto isto, a Figura A.12 apresenta um exemplo de resultado da aplicação do Crescimento de Regiões 3D na detecção da região óssea.




Figura A.11: exemplo de imagem de TC do tórax com a região óssea apresentada em vermelho, obtida através de limiar da faixa 600 a 2000 UH.



Figura A.12: exemplo de reconstrução 3D da região óssea de um exame de TC do tórax obtida através de Crescimento de Regiões 3D, sendo a)reconstrução óssea 3D e b) reconstrução do pulmão 3D juntamente com região óssea de a).

A.5 Detecção e análise das vias aéreas

As vias aéreas são caracterizadas por estar na faixa hiperaerada e também pela anatomia específica. Dentre as técnicas utilizadas para detectar estas estruturas, destaca-se a técnica desenvolvida por Cavalcante (2010), em que estas vias aéreas são detectadas utilizando uma RNA MLP possuindo como entrada os percentuais da técnica ADP proposto por (REBOUÇAS FILHO, 2010). Exemplos dos resultados obtidos por Cavalcante (2010) são apresentados na Figura A.13.




Figura A.13: exemplo dos resultados obtidos por Cavalcante (2010) na detecção das vias aéreas, apresentadas em vermelho, em imagens de TC do tórax, sendo a) corte axial e b) corte coronal.

Outra técnica utilizada na detecção das vias aéreas é o Crescimento de Regiões 3D, e um exemplo de resultado obtido utilizando esta técnica é apresentado na Figura A.14.



Figura A.14: exemplo de segmentação das vias aéreas obtida aplicando crescimento de regiões 3D com a semente inicial na traquéia, inicializando de forma manual.

Apêndice B

Tomografia Computadorizada do tórax

A Tomografia Computadorizada (TC) é um método de aquisição de imagens no plano axial, que também permite uma visualização em outros planos de cortes, por meio da reconstrução da imagem (HENDEE; RITENOUR, 2002; HERMAN, 2009).

A reconstrução tomográfica consiste em obter um mapeamento adequado do coeficiente de atenuação dos raios-X que ultrapassam o corpo em análise e, a partir destes dados, reconstruir uma imagem que represente a forma geométrica mais próxima do real, conforme é apresentado na Figura B.1. Na Figura B.1(a) são mostrados os principais planos de cortes e exemplos típicos de imagens tomográficas para cada um destes planos nas Figuras B.1(b), B.1(c) e B.1(d).

A estimativa do cálculo de atenuação é feita de forma precisa pela TC. Para realizar esta tarefa, a TC faz diversas medições de atenuação radiográfica¹, por meio de um plano de espessuras de tamanho finito em seções cruzadas. O sistema de aquisição de dados de TC 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 3D, no formato de uma caixa, denominado de *voxel*, que estende-se pela espessura da seção. Um *voxel* ou menor 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 e é representada pela espessura da fatia da seção, conforme é ilustrado na Figura B.2. O valor de cada *voxel* da imagem corresponde à atenuação da intensidade dos raios-X incidentes no tecido do órgão analisado (MADANI; KEYZER; GEVENOIS, 2001;

¹A propriedade que os materiais têm em absorver a radiação eletromagnética.

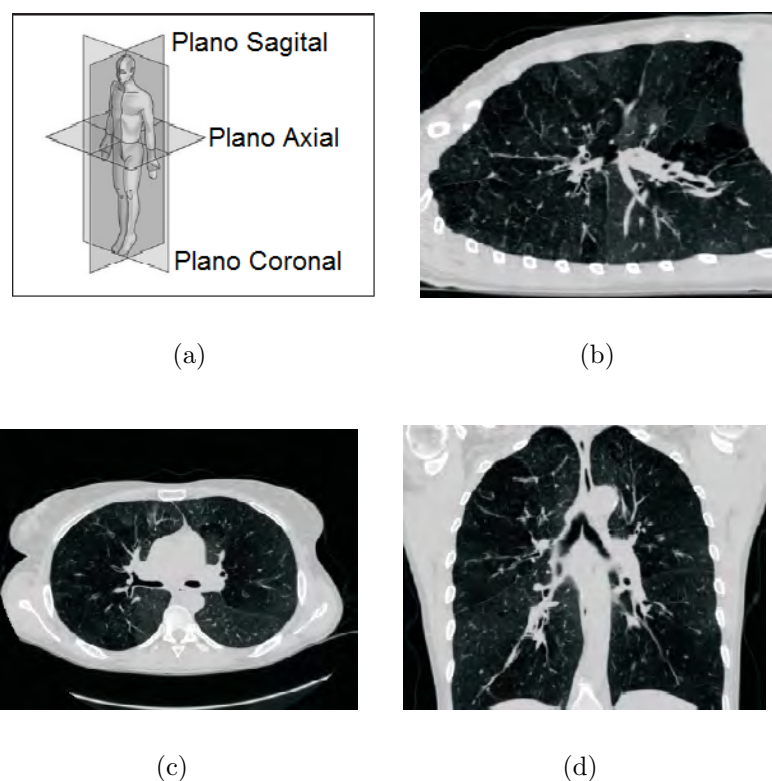


Figura B.1: reconstruções das imagens de seções dos pulmões de TC, adaptada de Sluimer (2005). (a) planos de cortes no corpo, (b) seção sagital, (c) seção axial, (d) seção coronal.

HENDEE; RITENOUR, 2002).

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)². As estruturas do corpo humano apresentam pequenas ou grandes variações, refletindo-se no valor da densidade radiológica em UH (EPSTEIN, 2001). Desta forma, diferentes tipos de tecidos, órgão ou estruturas, apresentam valores diferentes de densidade. Na escala em UH, por exemplo, o ar corresponde a -1000 UH, a água tem valor de 0 UH, gorduras estão entre -100 UH e -80 UH e os pulmões na faixa de -950 UH a +200 UH (SIEMENS, 2004; SLUIMER, 2005).

A TC permite a aquisição de uma fatia para cada rotação da fonte de raios-X e, a TC com múltiplos detectores, que é uma evolução da TC, fornece mais de uma fatia durante uma única rotação da fonte de raios-X, em geral 4, 8, 16 ou 32 fatias por rotação (GEBRIN, 2004). Um exemplo de aquisição de 4 fatias simultâneas é mostrado na Figura B.3.

Na Figura B.3 é utilizado um campo bidimensional de detectores (no lado direito).

²Godfrey N. Hounsfield e Allan M. Cormack foram agraciados com o Nobel de Fisiologia/Medicina de 1979 por desenvolverem no início da década de 70 a tomografia computadorizada. A escala da TC recebeu o nome de unidades Hounsfield para homenagear o seu desenvolvedor.




Figura B.2: representação de um elemento de volume *voxel* no lado esquerdo e de um pixel no lado direito, adaptada de Bontrager (2000).




Figura B.3: arranjo esquemático de uma TC (lado esquerdo) e de uma TC com múltiplos detectores (lado direito), adaptada de Jan (2006).

Diversas linhas paralelas de detectores de 0,5 a 2 mm aproximadamente, são usadas separadamente na direção z (longitudinal), em vez de uma única linha (no lado esquerdo). O princípio de múltiplos fatiamentos fornece dados tridimensionais em um volume limitado de fatias, para o exemplo da Figura B.3, apenas quatro fatias são adquiridas simultaneamente; uma extensão maior ao longo da direção longitudinal, a linha central, pode ser conseguida pela exploração helicoidal, ou seja, por meio do deslocamento axial do paciente no tomógrafo (JAN, 2006).

B.1 Visualização dos pulmões e suas estruturas internas em exames de TC do tórax no plano axial

As imagens de TC do tórax, geralmente são salvas na posição de corte axial, sendo este padrão utilizado em todas as imagens analisadas nesta tese. Estas imagens podem ser obtidas de corte de ápice, hilo e base, conforme é exemplificado na Figura B.4.




Figura B.4: posições de cortes dos pulmões em imagens de TC do tórax. (a) anatomia do pulmão, (b) posição ápice, (c) posição hilo, (d) posição base.

As regiões apresentadas na Figura B.4 pela presença das vias aéreas. Neste sentido, a posição ápice caracteriza-se pela presença da traquéia, conforme é exemplificado em vermelho na Figura B.5(b). Já a região do hilo caracteriza-se pela presença do hilo, que é a ramificação da traquéia, conforme é exemplificado em vermelho na Figura B.5(d). Entretanto, a região de base caracteriza-se pela ausência do hilo e da traquéia.




Figura B.5: posições de cortes dos pulmões em imagens de TC do tórax. (a) anatomia do pulmão, (b) posição ápice, (c) posição hilo, (d) posição base.