



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

TARIQUE DA SILVEIRA CAVALCANTE

MÉTODO DE SUPERFÍCIES ATIVAS USANDO *LOCAL BINARY PATTERNS* (LBP) APLICADO NA SEGMENTAÇÃO DE LOBOS PULMONARES EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX

FORTALEZA

2016

TARIQUE DA SILVEIRA CAVALCANTE

MÉTODO DE SUPERFÍCIES ATIVAS USANDO *LOCAL BINARY PATTERNS*
(LBP) APLICADO NA SEGMENTAÇÃO DE LOBOS PULMONARES EM IMAGENS
DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX

Tese apresentada ao Programa de Pós-graduação em Engenharia de Teleinformática do Departamento de Engenharia de Teleinformática da Universidade Federal do Ceará, como parte dos requisitos necessários para a obtenção do título de Doutor em Engenharia de Teleinformática. Área de concentração: Sinais e sistemas.

Orientador: Prof. Dr. Paulo César Cortez

FORTALEZA

2016

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

C364m Cavalcante, Tarique da Silveira.
Método de superfícies ativas usando local binary patterns (LBP) aplicado na segmentação de lobos pulmonares em imagens de tomografia computadorizada do tórax / Tarique da Silveira Cavalcante. – 2016. 202 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2016.
Orientação: Prof. Dr. Paulo César Cortez.

1. Modelos ativos. 2. Método de superfícies ativas. 3. Padrões locais binários. 4. Lobos pulmonares. 5. Processamento digital de imagens médicas.. I. Título.

CDD 621.38

TARIQUE DA SILVEIRA CAVALCANTE

**MÉTODO DE SUPERFÍCIES ATIVAS USANDO LOCAL BINARY
PATTERNS (LBP) APLICADO NA SEGMENTAÇÃO DE LOBOS
PULMONARES 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 Sianis e Sistemas.

Aprovada em 21/03/2016.

BANCA EXAMINADORA

Prof. Dr. PAULO CÉSAR CORTEZ (Orientador)
Universidade Federal do Ceará

Prof. Dr. JOSÉ MARQUES SOARES
Universidade Federal do Ceará

Prof. Dr. TARCISIO FERREIRA MACIEL
Universidade Federal do Ceará

Prof. Dr. ANDRÉ VICTOR ALVARENGA
Instituto Nacional de Metrologia, Qualidade e Tecnologia

Prof. Dr. WAGNER COELHO DE ALBUQUERQUE PEREIRA
Universidade Federal do Rio de Janeiro

Prof. Dr. AUZUIR RIPARDO DE ALEXANDRIA
Instituto Federal de Educação, Ciência e Tecnologia do Ceará

Prof. Dr. MARCELO ALCANTRA HOLANDA
Universidade Federal do Ceará

AGRADECIMENTOS

À toda minha família pelo apoio e incentivo que dedicaram a mim durante toda essa jornada, em especial aos meus pais João Antonio Filho e Laura Natercia da Silveira, à minha irmã Teane da Silveira Cavalcante.

À minha, em breve, esposa Camila da Silva Leal Medeiros pelo apoio, pela dedicação, pela paciência, pela persistência, pelo amor e por tudo.

Ao professor Paulo César Cortez pela orientação, amizade, confiança, paciência e pelas condições que me proporcionou para a realização deste trabalho.

Ao professor Marcelo Alcântara de Holanda e os profissionais da saúde José Holanda Maia Filho e Ingrid Correia Nogueira que tornaram possível a realização deste, graças à disponibilidade, dedicação e apoio.

A todos os companheiros e amigos da UFC e do IFCE pela amizade, paciência e pelos conselhos e ensinamentos que me foram passados durante essa jornada, em especial agradeço aos amigos Alyson Bezerra Nogueira Ribeiro, André Luiz de Souza Araújo, Auzuir Ripardo de Alexandria, Edson Cavalcanti Neto, Francisco José Marques Anselmo, John Hebert Silva Felix, Thomaz Maia de Almeida, Valberto Enoc Rodrigues da Silva Filho.

A todos os amigos que participaram deste trabalho como colaboradores ou ouvintes, contribuindo com experiências, incentivos e apoio.

Ao CNPq, pelo apoio e financiamento.

RESUMO

Em diversas aplicações de análise de imagens médicas, o processo de segmentação de imagens, seja automático ou manual, é uma tarefa presente. Uma segmentação correta fornece informações para inspeção de estruturas anatômicas, para a identificação de doenças e acompanhamento de seu progresso e até mesmo para o planejamento cirúrgico e simulação. Logo, o papel da segmentação de imagens é essencial em qualquer sistema de análise de imagens médicas. Dentre as técnicas de segmentação presentes na literatura, a técnica de modelos ativos é uma das abordagens mais populares durante as duas últimas décadas e tem sido amplamente utilizada em segmentação de imagens médicas, obtendo um sucesso considerável. Os modelos ativos que atuam em aplicações tridimensionais são denominados de Métodos de Superfícies Ativas (MSA), que por sua vez têm sido bastante utilizados na segmentação de objetos 3D, evoluindo sob a influência de suas energias até convergir para a superfície desejada. Neste sentido, tendo em vista que a extração de superfície é essencial para a obtenção de uma correta segmentação, a presente tese realiza um estudo sobre MSA, identificando suas vantagens e limitações, e propõe um novo MSA para a segmentação de lobos pulmonares em imagens de TC. Esta novo MSA tem como contribuições forças internas para malhas não estruturadas, energias externas baseadas em textura LBP e matriz Hessiana, além de inicialização automática por lobo pulmonar. Para validar a proposta é realizado um estudo comparativo da atuação das forças internas em imagens sintéticas, além da comparação da segmentação dos lobos pulmonares obtida pelo método proposto com a segmentação de um padrão ouro realizado por uma junta médica especialista. Os resultados comprovam que as forças internas apresentam bom desempenho na segmentação de imagens sintéticas com valores de distância média menores que 1 voxel e com medidas de ajuste maiores do que 0,95. A inicialização automática também obteve resultados relevantes, com taxa de acerto geral igual a 94%. Por fim, os valores obtidos para a segmentação dos lobos pulmonares permitem validar o método proposto com valores de distância média igual a 1,93 *mm* e valores de ajuste de tamanho e de forma de 0,98 e 0,89, respectivamente. Neste contexto, conclui-se que as métricas apresentadas neste trabalho são suficientes para validar a segmentação lobar obtida nesta tese.

Palavras-chave: Modelos Ativos, Método de Superfícies Ativas, Padrões Locais Binários, Lobos Pulmonares, Processamento Digital de Imagens Médicas.

ABSTRACT

In several applications involving medical image analysis, the process of image segmentation, be it automatic or manual, is a present task. An accurate segmentation provides information for inspection of anatomical structures, to identify diseases and monitoring of its progress, and even for surgical planning and simulation. Thus, the role of image segmentation is essential in any medical image analysis system. Among the segmentation techniques in the literature, the active models technique is one of the most popular approaches of the last two decades and has been widely used in medical image segmentation, achieving considerable success. Active models that are applied on three-dimensional applications are called Active Surfaces Methods (ASM), which has been widely used in the segmentation of 3D objects, evolving under the influence of their energy to converge to the desired surface. So, knowing how essential surface extraction is to obtain an accurate segmentation, this thesis conducts a study on ASM, identifying its advantages and limitations, and proposes a new ASM to the segmentation of pulmonary lobes on CT images. The new ASM has as contributions internal forces for unstructured meshes, external energies based on LBP texture and Hessian matrix, and automatic initialization for each lobe. In order to validate this proposal, a comparative study of the performance of the internal forces in synthetic images, along with the comparison of the segmentation of lung lobes obtained by the proposed method with the segmentation of a gold standard carried out by an expert medical board will be conducted. The results show that the internal forces performs well, providing synthetic images segmentation with average distance of less than 1 voxel and adjustment measures of 0.95. The automatic initialization has also achieved significant results, with overall hit rate of 94%. Finally, the rates obtained for pulmonary lobe segmentation allows validation of the proposed method with average distance values of 1.93 *mm* and rates of size and form adjustment of 0.98 and 0.89, respectively. Thus, it is concluded that the obtained metric is sufficient to validate the lobar segmentation obtained in this thesis.

Keywords: Active Models, Active Surface Methods, Local Binary Patterns, Pulmonary Lobes, Medical Image Processing.

Lista de Figuras

2.1	imagens de seções do pulmão adaptada de Sluimer, Prokop e Ginneken (2005), (a) planos de corte em relação ao corpo humano; (b) seção sagital; (c) seção axial; e (d) seção coronal.	15
2.2	representação de um elemento de volume voxel no lado esquerdo e de um pixel no lado direito, adaptada de Bontrager (2000).	16
2.3	escala em unidades Hounsfield de estruturas do corpo humano, adaptada de Siemens (2004).	16
2.4	imagem de TC do tórax no eixo axial, (a) imagem original e (b) representação colorida em faixas de densidade UH.	17
2.5	imagens 3D do pulmão, (a) direito com evidência da fissura; e (b) esquerdo com evidência da fissura (UGALDE; CAMARGO; DESLAURIERS, 2007).	18
2.6	imagens de TC com ênfase nas fissuras.	19
2.7	recortes de imagens de TC (a), (c), (e) e (g) recortes originais, (b), (d), (f) e (h) recortes com fissura destacada em vermelho e estruturas semelhantes as fissuras destacadas em azul.	20
2.8	exemplo de malha Delaunay.	28
2.9	exemplos de adição de pontos em uma malha Delaunay (SAKAMOTO, 2007), (a) situação geométrica dos pontos, (b) situação 1, adição do ponto P ; (c) situação 2, adição do ponto T ; e (d) situação 3, adição do ponto Q	29
2.10	exemplos de vizinhança circulares, (a) $P = 8, R = 1$; (b) $P = 16, R = 2$; e (c) $P = 8, R = 2$ (PIETIKAINEN et al., 2011).	35
2.11	padrões uniformes para vizinhança $P = 8$ bits, bits com valor igual a 1 representados em escuro e com valor igual a 0 representados em claro. Adaptado de Pietikainen et al. (2011).	37
2.12	distribuição dos descritores de fissuras definidos nas Equações 2.23 e 2.24 com $\alpha = 50, \beta = 35$ e $\gamma = 25$, (a) F_{folha} ; e (b) $F_{estrutura}$	41

2.13	ilustração dos descritores de fissuras pulmonares, (a) e (b) descritor F_{folha} ; e (c) e (d) descritor $F_{estrutura}$	42
2.14	exemplos distintos do coeficiente de similaridade de fissura $S_{fissura}$ definido na Equação 2.25.	42
2.15	ilustração da máscara C definida na Equação 2.26.	43
2.16	exemplos da máscara C após remoção de agrupamentos com volume menor que 0,1 ml.	44
2.17	segmentação de fissuras pulmonares após aplicação de operação morfológica.	44
3.1	fluxograma do processo de segmentação dos lobos pulmonares por MSA.	46
3.2	exemplo da atuação da força de continuidade, (a) disposição antes da atuação da força de continuidade; e (b) disposição depois da atuação da força de continuidade.	48
3.3	exemplo da atuação da força de curvatura, (a) disposição antes da atuação da força de curvatura; e (b) disposição depois da atuação da força de curvatura.	50
3.4	processo para obtenção da energia externa LBP para MSA aplicado à segmentação dos lobos pulmonares.	51
3.5	exemplo de resultado da classificação dos voxels pela rede MLP. Regiões em branco são classificadas como fissuras, demais estruturas são representadas em preto.	53
3.6	resultado do filtro de volume para a classificação da rede MLP, regiões classificadas como fissuras em branco e demais estruturas em preto.	53
3.7	resultado da soma da detecção de fissura e detector de bordas do pulmão.	54
3.8	resultado da transformada da distância.	54
3.9	energia externa LBP em um <i>slice</i> 2D.	55
3.10	processo para obtenção da energia externa Hessiana para MSA aplicado à segmentação dos lobos pulmonares.	56
3.11	energia Hessiana, (a) soma do resultado do filtro de canny aplicado aos pulmões com o resultado da detecção da fissura por matriz Hessiana; e (b) aplicação da transformada da distância em (a), limitada a 50 voxels.	57
3.12	funções de projeção de um mapa de energia externa para lobos, (a) $FPI_z(x, y)$; (b) $FPI_y(x, z)$; (c) $FPI_x(y, z)$ para o pulmão esquerdo; e (d) $FPI_x(y, z)$ para o pulmão direito.	59
3.13	$FPI_H(y)$ a partir de $FPI_y(x, z)$, (a) pulmão direito; e (b) pulmão esquerdo.	60
3.14	$FPI_H(y)$ acima e $FPI'_H(y)$ abaixo para o pulmão direito com $\Delta = 1$	61

3.15	$FPI_y(x, z)$ para o pulmão direito marcada nos vales de $FPI'_H(y)$	61
3.16	$FPI_H(y)$ acima e $FPI'_H(y)$ abaixo para o pulmão esquerdo com $\Delta = 1$. . .	62
3.17	$FPI_y(x, z)$ para o pulmão esquerdo marcada nos pontos z_{e1} , z_{e2} e z_{e3}	63
3.18	imagem 2D da energia externa Hessiana considerada para os lobos (a) superior direito; (b) médio direito; (c) inferior direito; (d) superior esquerdo; e (e) inferior esquerdo.	63
3.19	pontos calculados para inicialização automática dos MSAs para os lobos (a) superior direito; (b) médio direito; (c) inferior direito; (d) superior esquerdo; e (e) inferior esquerdo.	65
3.20	visualização 3D da inicialização do MSA para cada um dos lobos pulmonares em diferentes pontos de vista.	66
3.21	imagens no eixo axial que compõem o padrão ouro (a), (b) e (c) imagens originais e (d), (e) e (f) marcação do padrão ouro.	72
3.22	imagens no eixo coronal que compõem o padrão ouro (a), (b) e (c) imagens originais e (d), (e) e (f) marcação do padrão ouro.	72
3.23	imagens no eixo sagital que compõem o padrão ouro (a), (b), (c), (g), (h) e (i) imagens originais e (d), (e), (f), (j), (k) e (l) marcação do padrão ouro.	73
4.1	Imagem de exames de TC (a) exame 8 com fissura horizontal, e (b) exame 6 sem fissura horizontal.	80
4.2	Inicialização do MSA referente ao lobo médio direito do exame 2.	81
4.3	exemplos de inicializações automáticas geradas para os cinco lobos.	82
4.4	gráfico das distância médias obtidas na segmentação do lobo superior esquerdo para cada método testado.	85
4.5	gráfico das medidas de ajuste de volume (Fit_T) obtidas na segmentação do lobo superior esquerdo para cada método testado.	85
4.6	gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo superior esquerdo para cada método testado.	86
4.7	gráfico das distâncias médias obtidas na segmentação do lobo inferior esquerdo para cada método testado.	86
4.8	gráfico das medidas de ajuste de volume (Fit_T) obtidas na segmentação do lobo inferior esquerdo para cada método testado.	87
4.9	gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo inferior esquerdo para cada método testado.	87

4.10	segmentação dos lobos do pulmão esquerdo, (a), (d) e (g) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) Hessiana/NN; (c) e (f) LBP/Crust; e (i) LBP/NN.	89
4.11	gráfico das distâncias médias obtidas na segmentação do lobo superior direito para cada método testado.	90
4.12	gráfico das medidas de ajuste de volume (Fit_T) obtidas na segmentação do lobo superior direito para cada método testado.	90
4.13	gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo superior direito para cada método testado.	90
4.14	segmentação do lobo superior direito, (a), (d), (g) e (j) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) e (k) Hessiana/NN; (c) e (f) LBP/Crust; e (i) e (l) LBP/NN.	92
4.15	gráfico das distâncias médias obtidas na segmentação do lobo médio direito para cada método testado.	93
4.16	gráfico das medidas de ajuste de volume (Fit_T) obtidas na segmentação do lobo médio direito para cada método testado.	93
4.17	gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo médio direito para cada método testado.	93
4.18	segmentação do lobo médio direito, (a), (d), (g) e (j) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) e (k) Hessiana/NN; (c) e (f) LBP/Crust; e (i) e (l) LBP/NN.	95
4.19	gráfico das distâncias médias obtidas na segmentação do lobo inferior direito para cada método testado.	96
4.20	gráfico das medidas de ajuste de volume (Fit_T) obtidas na segmentação do lobo inferior direito para cada método testado.	96
4.21	gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo inferior direito para cada método testado.	96
4.22	segmentação do lobo inferior direito, (a), (d) e (g) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) Hessiana/NN; (c) e (f) LBP/Crust; e (i) LBP/NN. . .	97
4.23	gráfico das médias de μ_d de cada método utilizado produzido para cada lobo.	98

4.24	gráfico das médias de Fit_T de cada método utilizado produzido para cada lobo.	99
4.25	gráfico das médias de Fit_F de cada método utilizado produzido para cada lobo.	99
4.26	gráfico da média geral de μ_d para cada método utilizado.	100
4.27	gráfico da média geral de Fit_T e Fit_F para cada método utilizado.	101
4.28	visualização da malha Crust após a segmentação dos lobos por MSA (a) lobo superior esquerdo e (b) lobo inferior esquerdo.	102
4.29	exemplo de segmentação lobar 3D por MSA com energia Hessiana e malha Crust (a) e (b) pulmão direito, em vermelho é representado o lobo superior, em azul o lobo médio e em verde o lobo inferior; e (c) e (d) pulmão esquerdo, em magenta é representado o lobo superior e em ciano o lobo inferior.	103
4.30	exemplo de segmentação lobar 3D por MSA com energia Hessiana e malha Crust (a) e (b) pulmão direito, em vermelho é representado o lobo superior, em azul o lobo médio e em verde o lobo inferior; e (c) e (d) pulmão esquerdo, em magenta é representado o lobo superior e em ciano o lobo inferior.	104
4.31	exemplo de segmentação lobar 3D por MSA com energia LBP e malha Crust (a) e (b) pulmão direito, em vermelho é representado o lobo superior, em azul o lobo médio e em verde o lobo inferior; e (c) e (d) pulmão esquerdo, em magenta é representado o lobo superior e em ciano o lobo inferior.	105
A.1	destaque de vizinhança 5x5 de um ponto de controle do MCA.	128
A.2	aplicação da foça balão definida na Equação A.10, (a) imagem original; (b) mapa da foça balão para um centroide; e (c) resultado da segmentação do MCA para o mapa de forças em (b).	132
A.3	aplicação do GVF, (a) imagem original; e (b) suavização das bordas.	135
A.4	imagem de TC dos pulmões: (a) imagem original e (b) Força Crisp (REBOUÇAS FILHO, 2013a).	136
B.1	representação de um perceptron.	140
B.2	representação de rede MLP com uma camada oculta.	142
C.1	volumes 3D utilizados nos tetes sintéticos, (a) cilindro; (b) cone; (c) cubo; (d) esfera; e (e) pirâmide.	147
C.2	inicialização do MSA com 100 pontos distribuídos sobre a superfície de uma esfera de raio igual a 100 voxels, (a) malha estruturada retangular; (b) malha kNN com $k = 7$; e (c) malha Crust.	148

C.3	gráfico da distância média μ_d baseada na segmentação do cilindro obtida pelo MSA com força de curvatura para número de pontos variando de 100 a 2500.	150
C.4	segmentações obtidas para o cilindro com força de curvatura, para as malhas estruturada, NN e Crust, com 100, 400 e 2500 pontos.	151
C.5	gráficos das medidas de ajuste baseada nas segmentações do cilindro obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500 (a) Fit_T ; e (b) Fit_F	152
C.6	gráfico da distância média baseada nas segmentações do cone obtidas pelo MSA com força de curvatura para número de pontos variando de 100 a 2500.	153
C.7	segmentações obtidas para o cone com força de curvatura e malhas estruturada, NN e Crust, com 200, 700 e 2500 pontos.	154
C.8	gráficos das medidas de ajuste para a segmentação do cone, obtida pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500 (a) Fit_T ; e (b) Fit_F	155
C.9	gráfico da distância média baseada nas segmentações do cubo obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500.	156
C.10	segmentações obtidas para o cubo com força de curvatura e malhas estruturada, NN e Crust, com 200 e 2500 pontos.	156
C.11	gráfico da distância média baseada nas segmentações da pirâmide obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500.	158
C.12	segmentações obtidas para a pirâmide com força de curvatura e malhas estruturada, NN e Crust, com 200, 700 e 2500 pontos.	159
C.13	gráficos das medidas de ajuste baseada na segmentação do cubo obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	160
C.14	gráficos das medidas de ajuste baseada na segmentação da pirâmide obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	160
C.15	gráfico da distância média baseada nas segmentações da esfera obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500.	162
C.16	segmentações obtidas para a esfera com força de curvatura e malhas estruturada, NN e Crust, com 200, 700 e 2500 pontos.	162

C.17 gráficos das medidas de ajuste baseada na segmentação da esfera obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	163
C.18 gráfico da distância média baseada nas segmentações do cilindro obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.	167
C.19 segmentações obtidas para o cilindro com força balão e malhas estruturada, NN e Crust, com 200, 600 e 2500 pontos.	167
C.20 gráficos das medidas de ajuste baseada na segmentação do cilindro obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	168
C.21 gráfico da distância média baseada nas segmentações do cone obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500. . .	169
C.22 segmentações obtidas para o cone com força balão e malhas estruturada, NN e Crust, com 100 e 2500 pontos.	170
C.23 gráficos das medidas de ajuste baseada na segmentação do cone obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	171
C.27 gráficos das medidas de ajuste baseada na segmentação do cubo obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	172
C.28 gráficos das medidas de ajuste baseada na segmentação da pirâmide obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	172
C.24 gráfico da distância média baseada nas segmentações do cubo obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500. . .	173
C.25 gráfico da distância média baseada nas segmentações da pirâmide obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.	173
C.26 segmentações obtidas para o cubo e para a pirâmide com força balão com as malhas estruturada, NN e Crust, com 100 pontos.	173
C.29 gráfico da distância média baseada nas segmentações da esfera obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500. . .	175
C.30 segmentações obtidas para a esfera com força balão e malhas estruturada, NN e Crust, com 500 e 2500 pontos.	175

C.31 gráficos das medidas de ajuste baseada na segmentação da esfera obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F	176
--	-----

Lista de Tabelas

2.1	Classificação de trabalhos com MSA de acordo com o tipo de malha	32
4.1	resultados de distância média da segmentação dos volumes sintéticos utilizando 2500 pontos.	78
4.2	Taxas de acerto, por lobo e geral, obtidas pelo método de inicialização automática.	81
4.3	médias de μ_d , Fit_T e Fit_F , de cada método utilizado, produzidas para cada lobo	98
4.4	média geral de μ_d , Fit_T e Fit_F para cada método testado.	100
C.1	resultados de média, desvio padrão e máxima distâncias baseada na segmentação do cilindro obtida pelo MSA com força de curvatura.	150
C.2	resultados de média, desvio padrão e máximo das distâncias baseada na segmentação do cone, obtida pelo MSA com força de curvatura.	153
C.3	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações do cubo obtidas pelo MSA com força de curvatura	157
C.4	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da pirâmide obtidas pelo MSA com força de curvatura	157
C.5	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da esfera obtidas pelo MSA com força de curvatura	161
C.6	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações do cilindro obtidas pelo MSA com força balão	166
C.7	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações do cone obtidas pelo MSA com força balão	169
C.8	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da pirâmide obtidas pelo MSA com força balão	171
C.9	resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da esfera obtidas pelo MSA com força balão	174

D.1	resultados de μ_d e σ_d obtidos nas segmentações do lobo superior esquerdo para cada método testado.	179
D.2	resultados de μ_d e σ_d obtidos nas segmentações do lobo inferior esquerdo para cada método testado.	179
D.3	resultados de μ_d e σ_d obtidos nas segmentações do lobo superior direito para cada método testado.	180
D.4	resultados de μ_d e σ_d obtidos nas segmentações do lobo médio direito para cada método testado.	180
D.5	resultados de μ_d e σ_d obtidos nas segmentações do lobo inferior direito para cada método testado.	181

Lista de Siglas

ADP	Análise de Densidades Pulmonares
CP	Câncer de pulmão
DPOC	Doença Pulmonar Obstrutiva Crônica
EVP	Efeito de Volume Parcial
GVF	Fluxo de Vetor Gradiente (<i>Gradient Vector Flow</i>)
GGVF	Fluxo de Vetor Gradiente Generalizado (<i>Generalized Gradient Vector Flow</i>)
LBP	Padrões Binários Locais (<i>Local Binary Pattern</i>)
LIDC-IDRI	<i>Lung Image Database Consortium and Image Database Resource Initiative</i>
MCA	Método de Contornos Ativos
MEP	Modelagem Específica de Paciente
MLP	Perceptron Multicamadas (<i>Multilayer Perceptron</i>)
MSA	Método de Superfícies Ativas
NN	Vizinho mais próximo (<i>Nearest Neighbor</i>)
OMS	Organização Mundial de Saúde
PS	Perceptron Simples
RNA	Redes Neurais Artificiais
TC	Tomografia Computadorizada
THR	Transformada de Hilbert Radial
THRGD	Transformada de Hilbert Radial Generalizada Discreta
UH	Unidades Hounsfield
VC	Visão Computacional
VFC	Convolução de Campo de Vetor (<i>Vector Field Convolution</i>)

Sumário

Agradecimentos	iv
Resumo	v
Abstract	vii
Lista de Figuras	viii
Lista de Tabelas	xvi
Lista de Siglas	xviii
1 Introdução	1
1.1 Motivação	4
1.2 Objetivos	9
1.2.1 Objetivos Específicos	9
1.3 Contribuições	10
1.4 Produção Científica	10
1.5 Organização do Trabalho	13
2 Fundamentação Teórica e Estado da Arte	14
2.1 Imagens Médicas Pulmonares	14
2.1.1 Lobos e Fissuras Pulmonares	17
2.2 Modelos Ativos	20
2.2.1 Método de Superfícies Ativas - MSA	22
2.2.1.1 Malhas	24
2.2.1.2 MSA e Malhas	30
2.3 <i>Local Binary Patterns</i> - LBP	33
2.4 Segmentação de Fissuras com Matriz Hessiana	38
3 Metodologia	45
3.1 MSA para Lobos	46
3.1.1 Energia Interna	47
3.1.1.1 Força de Continuidade	47

3.1.1.2	Força de Curvatura	49
3.1.2	Energia Externa	50
3.1.2.1	Energia LBP	51
3.1.2.2	Energia Hessiana	55
3.1.3	Inicialização Automática	57
3.1.4	Dinâmica e Iteração	66
3.1.4.1	Remoção de pontos	67
3.1.4.2	Adição de pontos	67
3.1.4.3	Cr�terios de parada	68
3.2	Avalia�o dos M�todos	69
3.2.1	Testes em Imagens sint�ticas	69
3.2.2	Testes em exames de TC	70
3.2.2.1	Padr�o Ouro	70
3.2.2.2	Avalia�o da Inicializa�o Autom�tica	73
3.2.2.3	Avalia�o da Segmenta�o dos lobos pulmonares	74
3.2.3	M�tricas de avalia�o	74
3.2.3.1	Medidas de ajuste	75
4	Resultados e Discuss�es	77
4.1	Resultados em Imagens Sint�ticas	77
4.2	Resultados em Exames de TC	79
4.2.1	Inicializa�o autom�tica para MSA	79
4.2.2	Segmenta�o dos lobos pulmonares	82
5	Conclus�es, Contribui�es e Trabalhos Futuros	106
	Refer�ncias Bibliogr�ficas	110
	Ap�ndices	126
A	M�todo de Contornos Ativos - MCA	127
A.1	Energias	128
A.1.1	Força de Continuidade	129
A.1.2	Força de Curvatura	130
A.1.3	Força Bal�o	131
A.1.4	Energia externa tradicional	133
A.1.5	Energia externa <i>Gradient Vector Flow</i> - GVF	134
A.1.6	Energia externa Crisp	135
A.2	MCA e suas varia�es	136
B	Rede Neural Artificial - RNA	140
B.1	Rede Neural Perceptron Multicamadas - MLP	141

C	Resultados em Imagens Sintéticas	146
C.1	Energia interna com Força de Curvatura	149
C.1.1	Cilindro	149
C.1.2	Cone	152
C.1.3	Cubo e Pirâmide	155
C.1.4	Esfera	161
C.1.5	Análises e Discussões	163
C.2	Energia interna com Força Balão	166
C.2.1	Cilindro	166
C.2.2	Cone	168
C.2.3	Cubo e Pirâmide	170
C.2.4	Esfera	174
C.2.5	Análises e Discussões	176
D	Resultados da Segmentação dos Lobar	178

Capítulo 1

Introdução

Imagiologia médica está se tornando cada vez mais importante na medicina contemporânea, pois proporciona a visualização de estruturas anatômicas internas e informações para auxílio ao diagnóstico, plano de tratamento e avaliação de forma não invasiva (BI et al., 2012). Nas últimas décadas, a utilização dos exames que fazem uso de imagens médicas tem apresentado um forte crescimento. Os métodos utilizados nestes exames oferecem um vasto campo de modalidades e técnicas, permitindo o estudo de funções e anatomia do corpo humano em detalhes (ELLIS; FLOWER, 2006; SMITH-BINDMAN; MIGLIORETTI; B., 2008; FUSHMAN et al., 2015; BIRKFELLNER, 2015).

O processo de segmentação de imagens é uma tarefa presente e um dos primeiros estágios em diversas aplicações de análise de imagens médicas. Para realizar a análise do estado de um determinado órgão é necessário que o mesmo seja identificado na imagem. Uma segmentação correta fornece meios visuais para inspeção de estruturas anatômicas, para a identificação de doenças e acompanhamento de seu progresso, e até mesmo para o planejamento cirúrgico e simulação. Logo, o papel da segmentação de imagens é extremamente útil em qualquer análise de imagens médicas (HE et al., 2008; HEIMANN; MEINZER, 2009; BARBOSA et al., 2014).

Os avanços de recursos computacionais têm permitido a introdução de imagens médicas em três dimensões (3D) na prática clínica diária. O uso clínico de modalidades de imagens médicas que produzem dados volumétricos está aumentando constantemente. Dessa forma, o processo de segmentação tradicional que se baseia no delineamento manual da estrutura de interesse, por parte do usuário, torna-se uma solução demorada, tediosa e clinicamente ineficiente para a prática de rotina. Além disso, o delineamento manual das estruturas anatômicas é propenso à variabilidade interobservador. Deve também notar-se que o contorno 3D através de processamento 2D não é trivial, pois a continuidade do

contorno na terceira dimensão não é explicitamente aplicada (DELIBASIS et al., 2013b; BARBOSA et al., 2014).

A segmentação de estruturas a partir de imagens 3D é uma tarefa exigente, que encontra inúmeras aplicações em diagnóstico automatizado, sistemas de apoio à decisão médica e planejamento de tratamento médico e avaliação cirúrgica. Naturalmente, a segmentação automática de imagens é altamente desejável, por isso diversas pesquisas abordando novos conceitos, modelos, atlas, dentre outros, têm sido realizadas com o objetivo de obter uma correta segmentação automática em exames 3D de Tomografia Computadorizada (TC) (DELIBASIS et al., 2014).

No entanto, a segmentação de estruturas e objetos em imagens médicas é um processo complexo. Tal fato é devido principalmente a enorme variabilidade de estruturas e órgãos internos, além da possibilidade da ocorrência de diversas doenças que afetam os órgãos de formas distintas (ELLIS; FLOWER, 2006; FUSHMAN et al., 2015).

A finalidade da segmentação em imagens médicas é fornecer informações além da análise visual. Os resultados produzidos neste processo podem ser utilizados no melhoramento da visualização das imagens, bem como no cálculo de medidas quantitativas. Além disso, a segmentação de exames médicos volumétricos permite a reconstrução e visualização da estrutura segmentada a partir de diferentes ângulos e perspectivas. Alguns métodos de segmentação utilizam algoritmos como limiares, análise de componentes conectados e modelos ativos, dentre outros.

Dentre as técnicas de segmentação pesquisadas, a técnica de modelos ativos, ou modelos deformáveis, tem sido bastante utilizada e recorrente na literatura nos últimos anos. Modelos ativos têm sido extensivamente estudados e amplamente utilizados em segmentação de imagens médicas e têm alcançado um sucesso considerável. A ideia básica do modelo ativo é evoluir um determinado contorno ou superfície até os limites do objeto de interesse. Esta evolução é definida pela atuação da energia interna, determinada pela geometria do contorno ou superfície, e da energia externa extraída a partir da imagem (HONG et al., 2014).

Os modelos ativos podem ser divididos em dois grupos, o Método de Contornos Ativos (MCA) que abordam problemas bidimensionais e o Método de Superfícies Ativas (MSA), este por sua vez atua em aplicações tridimensionais (FAN; JIANG; EVANS, 2002). MSAs têm sido bastante utilizados para encontrar a superfície de um objeto 3D, evoluindo sob a influência de suas energias até convergir para a superfície desejada (SLABAUGH; UNAL, 2005; MISHRA; FIEGUTH; CLAUSI, 2010).

Em imagens médicas, a tarefa de identificação de superfícies 3D e contornos 2D, na presença de ruído ou de outras estruturas com características semelhantes à desejada, possui diversas aplicações e vem sendo recorrente na literatura sua resolução por meio de modelos ativos.

Com base no Grupo de Pesquisa em Engenharia Biomédica e Sistemas de Auxílio ao Diagnóstico Médico - BIOAUX com sede no LESC/UFC, é possível citar diversos trabalhos. Félix (2011) apresenta um MCA baseado na transformada Hilbert 2D para realizar a segmentação dos pulmões em imagens de tomografia computadorizada (TC) do tórax, e em seguida, Felix et al. (2012) desenvolvem uma inicialização automática para MCAs aplicados à segmentação dos pulmões.

Rebouças Filho, Cortez e Holanda (2011), utilizando análise de densidades pulmonares (ADP), também apresentam um MCA para segmentação dos pulmões em imagens de TC. Ainda no mesmo ano, Alexandria et al. (2011) fazem uso de um MCA radial, para cálculo de fração de ejeção do ventrículo esquerdo em imagens de ecocardiograma.

Cavalcante et al. (2013) utilizam MCA com ADP para realizar segmentação 2D de vias aéreas em imagens de TC, enquanto Rebouças Filho et al. (2013b) apresenta o MCA Crisp Adaptativo 2D para segmentar os pulmões ainda em imagens de TC.

Alexandria et al. (2014) apresentam um novo MCA radial, denominado pSnakes, para realizar a segmentação do ventrículo esquerdo do pulmão em imagens de ecocardiograma.

Diversas outras pesquisas também são encontradas na literatura. Barbosa et al. (2013) também realizam segmentação em imagens de ecocardiograma, mas por sua vez utilizam MSA e splines. No ano seguinte, Barbosa et al. (2014) apresentam uma segmentação em tempo real e interativa usando técnicas semelhantes em imagens de ecocardiograma.

Skalski et al. (2013) fazem uso do MSA GVF (*gradient vector flow*) com o auxílio de atlas anatômico para segmentar a próstata em imagens de ressonância magnética. Já Harangi e Hajdu (2014) aplicam múltiplos MCA para detecção automática de exsudado ocular.

Bradshaw et al. (2013) propõem um MSA para segmentação de pequenas estruturas em imagens de TC, a validação do método é feita pela segmentação dos canais semicirculares do ouvido interno. Já Delibasis, Kechriniotis e Maglogiannisc (2013a) também utilizam MSA em imagens de TC, todavia a aplicação em questão consiste na segmentação da traqueia e da aorta sem a necessidade de interação com o usuário.

Delgado-Gonzalo, Chenouard e Unser (2013) desenvolvem um MSA baseado em splines e elipses e aplicam o método na segmentação de células do cérebro em imagens de

microscopia confocal. Ainda com MSA, Gu et al. (2013) realizam a segmentação da parede da árvore aérea em imagens de TC, o MSA em questão é inicializado com o resultado da segmentação interna da árvore aérea e se baseia na geometria e densidade característica das vias aéreas.

Desde o trabalho de Kass, Witkin e Terzopoulos (1987), que define a formulação original do MCA, é notória a popularidade na literatura dos modelos ativos. Popularidade plenamente justificável pela acurácia e qualidade dos resultados obtidos em diversas aplicações, dentre elas as de imagiologia médica.

Neste sentido, tendo em vista que a extração de superfície é essencial para a obtenção de uma correta segmentação, possibilitando a obtenção de dados quantitativos em uma imagem volumétrica e o auxílio ao diagnóstico bem sucedido, é fundamental realizar um estudo sobre o Método de Superfícies Ativas (MSA). Deve-se identificar suas vantagens e limitações, e propor em seguida um novo MSA que vise vencer algumas das limitações e apresente resultados importantes quando utilizado na segmentação de lobos pulmonares em imagens de TC.

1.1 Motivação

Os algoritmos que realizam o processamento, segmentação e análise de imagens médicas 3D estão ganhando maior atenção. Imagens 3D são produzidas por uma variedade de métodos de imagem como Tomografia Computadorizada (TC) e ressonância magnética. Consequentemente, existe uma demanda de métodos computacionais que possam processar e modelar de forma precisa e anatômica as estruturas e dados da imagem 3D (DELIBASIS et al., 2013b).

A Modelagem Específica de Paciente (MEP) é uma área emergente na engenharia biomédica que visa aplicar as ferramentas e técnicas desenvolvidas ao longo dos últimos anos para o benefício do paciente. Tais ferramentas e técnicas costumam gerar reconstruções 3D ou modelos matemáticos de tecidos ou órgãos de interesse de um determinado paciente, baseados em imagiologia médica. Em seguida, os resultados gerados são utilizados em algoritmos de auxílio ao diagnóstico, podendo sugerir diagnósticos, prognósticos ou até possíveis tratamentos (GEFEN, 2012).

MEP pode ser combinada com exames comuns de imagem como ressonância magnética, TC, ultrassom, como também pode incorporar informações complementares de exames clínicos para o auxílio ao diagnóstico. Esta nova área surge com potencial para

ser parte integrante e padrão da medicina moderna. A MEP vem sendo utilizada para auxiliar várias especialidades médicas, como em ortopedia, cardiologia, neurologia, oncologia, oftalmologia, pneumologia, dentre outros (GEFEN, 2012).

Uma das aplicações de MEP que vem ganhando destaque é a modelagem de pulmões e lobos a partir de exames de TC do tórax. Isto se justifica pelo fato de parte considerável das doenças que afetam a população mundial incidir nos pulmões. Deste modo, aplicações de MEP para modelagem, reconstrução, visualização com diferentes perspectivas, levantamento de dados quantitativos dos pulmões e lobos possuem grande importância na saúde, pois existe uma preocupação constante com doenças como a Doença Pulmonar Obstrutiva Crônica (DPOC), o câncer de pulmão (CP), de traqueia, de brônquios, e infecções respiratórias como bronquite e pneumonia (MATHERS; LONCAR, 2006; ALMEIDA, 2011; CAVALCANTI NETO, 2014).

A DPOC, juntamente com as infecções respiratórias e com o câncer de pulmão, traqueia e brônquios é responsável por 14,4% das causas de mortes da população mundial, estimadas pela Organização Mundial de Saúde (OMS) para o ano de 2030. Cada uma dessas doenças ocupa uma posição no ranking das dez principais causas de mortes nesta mesma estimativa, sendo a DPOC responsável por 7,8% das causas de morte figurando em quarto lugar, as infecções respiratórias responsáveis por 3,5% e ocupando a quinta posição, enquanto o câncer de pulmão responde por 3,1% das causas de mortes e ocupa a sexta posição (MATHERS; LONCAR, 2006; INCA, 2014).

O CP por exemplo é a causa mais comum de morte do mundo por câncer indicado pela presença de nódulos. A taxa de sobrevivência está relacionada com o estágio da doença, uma vez que a detecção precoce e a ressecção do câncer pode melhorar o prognóstico significativamente (SOLTANINEJAD; KESHANI; TAJERIPOUR, 2012).

No Brasil, o CP foi responsável por 24.424 mortes em 2011, sendo o câncer que mais fez vítimas. Para o ano de 2014 foram estimados 27.330 novos casos de CP, sendo destes 16.400 em homens e 10.930 em mulheres. Para 2016, estimam-se 28.220 casos novos de câncer de traqueia, brônquios e pulmões no Brasil, sendo 17.330 casos entre homens e 10.890 entre mulheres. O que corresponde aproximadamente à 17,49 casos a cada 100 mil homens e 10,54 a cada 100 mil mulheres (INCA, 2014, 2016).

O tratamento inicial de CP é a lobectomia, cirurgia realizada no pulmão na qual é retirado um lobo pulmonar. Desta forma, a partir de informações anatômicas das estruturas dos pulmões é possível realizar o planejamento correto para uma cirurgia de lobectomia. Em geral, a anatomia típica do pulmão humano possui cinco divisões distintas, denominadas de lobos, e seus limites são determinados por membranas denominadas de fissuras ou

cisuras, surgindo desta forma a necessidade de identificá-las (KUMAR.; KAVITHA, 2011).

Nesse sentido, um método para a identificação 3D dos lobos fornece os meios para avaliar parâmetros quantitativos locais para o planejamento e monitoramento do tratamento. Embora radiologistas experientes sejam capazes de identificar limites lobares e as vezes até segmentares na TC, a delimitação manual de um exame, que costuma conter mais de 300 imagens de TC, é impensável na rotina clínica (SOLTANINEJAD; KESHANI; TAJERIPOUR, 2012).

Usando as informações locais, os parâmetros funcionais, tais como volume, densidade pulmonar média, décimo quinto percentil, índice de pixel, índice de bula, percentuais de aeração, tipo de enfisema, dentre outros, podem ser extraídos para cada lobo. Isso aumenta a importância de uma previsão da função pulmonar baseada em TC de pós-operatório nos casos de ressecção de um pulmão, lobo, ou segmento (KUHNIGK et al., 2005).

Atualmente, a cintigrafia de perfusão é realizada a fim de obter um prognóstico funcional. Todavia a cintigrafia não permite a análise de imagens em 3D, logo adquirir estimativas precisas para a função lobar torna-se inviável. Além disso, vale ressaltar que a análise da cintigrafia é realizada juntamente com testes de função pulmonar e exames de TC. Uma vez que existem dados quantitativos de cada lobo e segmento do pulmão do paciente em questão, obtidos de exames de TC previamente realizados, exames adicionais de cintilografia podem até ser dispensados (KUHNIGK et al., 2005).

A abordagem mais comum para realizar a segmentação lobar em exames de TC, consiste em segmentar os pulmões e realizar uma detecção prévia das fissuras pulmonares ou até mesmo aplicar um filtro que as realce para então obter o volume e superfície dos lobos pulmonares. Fissuras pulmonares são membranas que se encontram dentro dos pulmões e separam os lobos pulmonares.

A detecção de fissuras pulmonares é desafiadora, pois sua densidade se assemelha à densidade de outras estruturas como a de pequenos vasos sanguíneos. Além disso, algumas partes das fissuras podem não estar corretamente representadas nas imagens de TC por causa do Efeito de Volume Parcial (EVP), podendo estar incompletas. Para superar estas dificuldades, diversos trabalhos na literatura fazem uso de informações anatômicas dos pulmões para auxiliar na segmentação de fissuras pulmonares.

O método mais recorrente da literatura para detecção de fissuras pulmonares é baseada nos autovalores da matriz Hessiana. Vários autores propuseram modificações neste método, aplicando a retirada dos vasos proposta por Frangi et al. (1998) para melhorar as estruturas das fissuras (SATO et al., 2000; LI et al., 2003). O uso destes filtros foi proposto

pela primeira vez por Wiemker, Bülow e Blaffert (2005), que apresentaram dois filtros para o aperfeiçoamento de fissuras pulmonares. Um com base na análise dos valores da estrutura tensora e outro com base nos valores da matriz Hessiana de cada *voxel*. Nenhuma análise quantitativa foi realizada, pois, de acordo com os autores, por observação visual percebe-se que os resultados dos filtros foram semelhantes.

Zhang, Hoffman e Reinhardt (2006) utilizaram um atlas anatômico construído a partir de dados de exames de TC de pulmão de 16 indivíduos para inicializar a segmentação dos lobos. Este método, não automático, utiliza ainda um sistema *fuzzy* para auxílio na inicialização e emprega um outro sistema *fuzzy*, juntamente com pontos inseridos manualmente que servem como base para identificar a fissura pulmonar. Assim, este método depende diretamente do atlas anatômico do pulmão e da interação com o usuário que insere pontos para segmentação final. Uma avaliação em 22 exames de TC do tórax foi realizada comparando as fissuras em termos do erro quadrático médio.

Wang, Betke e Ko (2006) apresentaram um método para segmentar as fissuras lobares com a inicialização manual em uma seção axial de TC de tórax localizada na metade inferior do pulmão. Na região da fissura, um mapa de picos é computado e combinado com a imagem de entrada em um método de crescimento de curva para delinear a fissura na seção. Este processo é repetido até que as fissuras, em todas as seções, sejam segmentadas para então ser aplicada uma interpolação linear 3D para segmentar a fissura por completo. O método foi avaliado em dez exames de TC em que fissuras foram traçadas manualmente. A distância média entre a fissura delineada automaticamente e a traçada manual foi de 1,01 *mm*, porém em alguns setores uma correção manual fez-se necessária.

Rikxoort et al. (2008) propuseram uma abordagem de reconhecimento de padrões para enfatizar as fissuras pulmonares. Os valores da matriz Hessiana foram utilizados como atributos em combinação com as derivadas de primeira e de segunda ordem da imagem. O classificador foi treinado a partir de fissuras delineadas manualmente. O método foi avaliado quantitativamente em um conjunto de 22 exames com segmentações manuais das fissuras e ilustrou um bom desempenho, todavia a segmentação dos lobos em *scans* com fissura incompletas apresentou frequentemente erros de segmentação. Para tentar corrigir este problema, Rikxoort et al. (2010) adicionaram a segmentação dos lobos informações da árvore aérea, e do formato prévio dos lobos, além de informações de atlas. A validação deste método foi realizada com 120 imagens provenientes de 4 exames de TC.

Wei et al. (2009) apresentam uma metodologia para segmentação dos lobos que inicia por uma varredura adaptativa para detecção de fissuras que se baseia em filtros passa-baixas, limiarização automática do histograma local e operações morfológicas, e por fim

aplica transformada *wavelet* 2D discreta, limiarização de Otsu e interpolação para segmentar os lobos pulmonares em imagens de TC.

Ukil e Reinhardt (2009) combinaram a transformada da distância aplicada em vasos segmentados e a imagem de TC do tórax original de forma a servir como uma imagem de custo para a transformada *watershed* guiada pelas vias aéreas, vasos sanguíneos e informações de atlas anatômico. Com base na segmentação de *watershed*, uma área de pesquisa inicial para as fissuras pulmonares é determinada. Na área de interesse, uma medida de *ridgeness* baseada na análise da estrutura do tensor é aplicada em fatias transversais, seguida por uma procura através de grafo 3D para localizar a superfície ótima dentro da área de busca para encontrar a fissura pulmonar. O método foi avaliado comparando os traçados manuais das fissuras em exames de 12 indivíduos normais na inspiração e expiração e em 17 pacientes com enfisema em plena inspiração.

Lassen et al. (2013) apresentaram uma segmentação dos lobos pulmonares semelhante ao método proposto por Ukil e Reinhardt (2009), uma vez que também utilizam informações provenientes da segmentação de vias aéreas, vasos sanguíneos para auxílio na detecção da fissura e da transformada de *watershed* para segmentação dos lobos. Todavia, diferencia-se por não utilizar informações de atlas anatômico e utilizar, juntamente com a segmentação dos vasos e vias aéreas, autovalores da matriz Hessiana e transformada da distância para finalizar a detecção da fissura e gerar uma imagem custo para a transformada de *watershed*.

Ross et al. (2013) adotam um conjunto de superfícies usando análise de componentes principais para treinamento e ajustam estas superfícies às fissuras a fim de obterem os lobos. O ajuste das superfícies é feito a partir da classificação do discriminante linear de Fisher. O problema do método proposto é que em alguns casos as superfícies são ajustadas em outras estruturas do pulmão e não nas fissuras, gerando uma segmentação distorcida dos lobos.

Qi et al. (2014) realizam a segmentação dos lobos, buscando por regiões candidatas a conterem fissuras de acordo com o espaçamento de vasos e vias aéreas. De posse destas regiões, utilizam técnicas baseada na matriz Hessiana para a detecção de fissuras e obtendo, em sequência, as superfícies de fissuras e lobos baseado em funções de base radiais. Já Wei e Hu (2014) utilizam técnicas para detecção de fissuras em 2D e 3D em conjunto, aplicando análise de texturas para identificá-las. Em seguida, geram a superfície da fissura aplicando técnicas de regressão e por fim obtêm a segmentação dos lobos.

Com base neste levantamento da literatura especializada, constata-se que a segmentação dos lobos pulmonares em muitos dos métodos propostos é baseada em um modelo

genérico ou atlas anatômico pré-definido que não considera a individualidade da anatomia de cada paciente. Além disso, há pacientes que não estão contemplados com dados de um atlas anatômico, agravando-se a imprecisão de tais métodos.

Também é possível perceber que métodos para segmentação dos lobos pulmonares que utilizam como entrada o resultado da segmentação de outras estruturas pulmonares, principalmente vias aéreas e vasos sanguíneos, são bastante recorrentes. Apesar de possuir informação útil e facilitar o processo de detecção de fissuras e segmentação dos lobos, estas segmentações prévias podem apresentar erros, principalmente devido a variabilidade de pacientes e a afecção de doenças. Estes erros, por sua vez, influenciam de maneira significativa a segmentação dos lobos. Além disso, com esta limitação, a segmentação dos lobos está sempre condicionada à segmentação de outras estruturas, acarretando em um processo mais longo e menos eficiente, pois os erros se propagam em cada processo.

No entanto, não se encontra na literatura pesquisada um método para realizar uma segmentação automática dos lobos pulmonares independente de atlas anatômicos, modelos pré-definidos e segmentações de outras estruturas pulmonares como vasos sanguíneos e vias aéreas. Também não há nesta literatura um Método de Superfícies Ativas combinado com algoritmos baseados em *Local Binary Pattern* (LBP) e matriz Hessiana.

Nesse contexto, com o objetivo de obter um método para a segmentação 3D dos lobos, que seja automático, independente em relação à segmentação de outras estruturas e que permita o cálculo e avaliação de parâmetros quantitativos locais para o auxílio ao diagnóstico, planejamento, monitoramento e tratamento de doenças que afetam os pulmões, esta tese se propõe realizar esta segmentação baseada em MSA, LBP e matriz Hessiana.

1.2 Objetivos

O principal objetivo desta tese consiste em desenvolver um novo Método de Superfícies Ativas para malhas estruturadas e não estruturadas, que seja capaz de realizar uma segmentação 3D automática e eficaz dos lobos pulmonares em imagens de TC do tórax.

1.2.1 Objetivos Específicos

Os objetivos específicos que devem ser alcançados neste trabalho são:

- aplicar e avaliar desempenho do novo MSA com as malhas estruturada regular, NN

- e Crust, em diferentes estruturas sintéticas;
- propor e avaliar um novo método de inicialização automática para o MSA aplicado à segmentação de lobos pulmonares;
- aplicar e avaliar o novo MSA com energia externa baseada em LBP na segmentação dos lobos pulmonares em imagens de TC;
- aplicar e avaliar o novo MSA com energia externa baseada em matriz Hessiana na segmentação dos lobos pulmonares em imagens de TC; e
- validar as segmentações dos lobos realizadas pelos MSAs com padrão ouro obtido junto a médicos especialistas.

1.3 Contribuições

As principais contribuições desta tese são as propostas de:

- MSA adaptado à malhas estruturadas e não estruturadas;
- força de curvatura, continuidade e balão para MSA;
- método de inicialização automática de MSA para lobos pulmonares;
- critérios de parada, adição e remoção de pontos para MSA;
- energia externa para MSA baseada em LBP para segmentação de lobos pulmonares; e
- energia externa para MSA baseada em autovalores de matriz Hessiana para segmentação de lobos pulmonares.

1.4 Produção Científica

Seguem as produções científicas realizadas na área de imagens médicas e modelos ativos durante o desenvolvimento desta pesquisa.

- Trabalhos publicados em periódicos:

CAVALCANTI NETO, E.; CORTEZ, PAULO CÉSAR; CAVALCANTE, T. S.; SILVA FILHO, V.E.R.; HOLANDA, M. A.; Segmentação de Fissura 3D em imagens de TC baseadas em Texturas. *Revista IEEE América Latina*, v. 14, 2016.

CAVALCANTE, T.S.; CORTEZ, P.C.; ALMEIDA, T.M.; FELIX, J.H.S.; HOLANDA, M.A. Segmentação automática 2D de vias aéreas em imagens de tomografia computadorizada do tórax. *Revista Brasileira de Engenharia Biomédica*, v. 29, p. 389-403, 2013.

REBOUÇAS, P.P.; CORTEZ, P.C.; FELIX, J.H.S.; CAVALCANTE, T.S.; HOLANDA, M.A. Modelo de Contorno Ativo Crisp Adaptativo 2D aplicado na segmentação dos pulmões em imagens de TC do tórax de voluntários sadios e pacientes com enfisema pulmonar. *Revista Brasileira de Engenharia Biomédica*, v. 29, p. 363-376, 2013.

FELIX, J.H.S.; CORTEZ, P.C.; CAVALCANTE, T.S.; ALEXANDRIA, A.R. ; HOLANDA, M.A. AUTOIN: Method of Automatic Initialization of Active Contours Applied to Lungs in CT Images. *Revista IEEE América Latina*, v. 10, p. 1954-1960, 2012.

- Trabalhos publicados em capítulo de Livro:

CAVALCANTI NETO, E.; CORTEZ, P.C.; CAVALCANTE, T.S. ; SILVA FILHO, V.E.R. ; REBOUÇAS FILHO, P.P.; HOLANDA, M.A. Supervised Enhancement Filter Applied to Fissure Detection. *IFMBE Proceedings*. 1ed.: Springer International Publishing, 2015, v. 49, p. 337-340.

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. *IFMBE Proceedings*. 1ed.: Springer Berlin Heidelberg, 2013, v. 33, p. 1051-1053.

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. *IFMBE Proceedings*. 1ed.: Springer Berlin Heidelberg, 2013, v. 33, p. 1019-1022.

- Trabalhos publicados em eventos científicos:

VALENTE, I.; CORTEZ, P.C.; CAVALCANTE, T.S.; ANSELMO, F.J.; CAVALCANTI NETO, E.; RIBEIRO, A.B.N.; SILVA FILHO, V.E.R.; HOLANDA, M.A. LISA - *Lung Image System Analysis*. In: VII Simpósio de Instrumentação e Imagens Médicas (SIIM) / VI Simpósio de Processamento de Sinais da UNICAMP (SPS-UNICAMP), 2015, Campinas. VII SIIM, 2015.

RIBEIRO, A.B.N.; CORTEZ, P.C.; CAVALCANTE, T.S.; SILVA FILHO, V.E.R.; CAVALCANTI NETO, E.; HOLANDA, M.A. Crescimento de Regiões 3D Aplicado na Segmentação de Vasos Sanguíneos em Imagens de TC do Tórax. In: VII Simpósio de Instrumentação e Imagens Médicas / VI Simpósio de Processamento de Sinais da UNICAMP, 2015, Campinas. VII SIIM / VI SPS, 2015.

CAVALCANTI NETO, E.; CORTEZ, P.C.; CAVALCANTE, T.S.; SILVA FILHO, V.E.R.; MARINHO, L.S.; HOLANDA, M.A. Segmentação 3d De Fissuras Pulmonares Em Imagens De Tc Do Tórax Utilizando Texturas. In: XXIV Congresso Brasileiro de Engenharia Biomédica, 2014, Uberlandia. XXIV CBEB, 2014.

CAVALCANTI NETO, E.; CORTEZ, P.C.; CAVALCANTE, T.S.; SILVA FILHO, V.E.R.; REBOUÇAS FILHO, P.P. *Neural Filter Applied To Fissure Detection*. In: X Workshop de Visão Computacional, 2014, Uberlandia. X WVC, 2014.

REBOUÇAS FILHO, P.P. ; CORTEZ, P.C. ; RIBEIRO, A.B.N. ; CAVALCANTE, T.S.; FELIX, J.H.S.; HOLANDA, M.A. Segmentação, reconstrução e visualização 3D dos pulmões utilizando Crescimento de Regiões 3D aplicado em imagens de Tomografia Computadorizada do tórax. In: XI Simpósio Brasileiro de Automação Inteligente, 2013, Fortaleza. XI SBAI, 2013.

RIBEIRO, A.B.N.; CORTEZ, P.C.; CAVALCANTE, T.S.; REBOUÇAS FILHO, P.P. Segmentação de Vasos Sanguíneos do Pulmão em Imagens de Tomografia Computadorizada do Tórax. In: Computer on the Beach, 2012, Florianópolis. Computer on the Beach, 2012.

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

- Patentes depositadas:

CORTEZ, P.C.; CAVALCANTE, T. S.; FELIX, J.H.S.; HOLANDA, M.A.; CAVALCANTI NETO, E.; SILVA FILHO, V. E. R.; RIBEIRO, A. B. N.; ALMEIDA, T. M.; NOGUEIRA, I. C. Segmentação de Vasos Sanguíneos Pulmonares em Imagens de Tomografia Computadorizada do Tórax Utilizando Análise de Densidade Pulmonar - PROTOCOLO BR 10 2015 029771 8, 2015.

CORTEZ, P.C.; RIBEIRO, A. B. N.; CAVALCANTE, T. S.; HOLANDA, M.A.; CAVALCANTI NETO, E.; SILVA FILHO, V. E. R.; ALMEIDA, T. M.; Inicialização Automática

de Modelos Ativos 3D para Segmentação Lobar em Imagens de TC do Tórax - PROTOCOLO BR 10 2015 029768 8, 2015.

- Registros de software:

CORTEZ, P.C.; CAVALCANTE, T. S.; FELIX, J.H.S.; ANSELMO, F.J.; HOLANDA, M.A.; PERERIRA, E.D.B.; NOGUERIA, I.C.; MARINHO, L. S.; Sistema de Análise de Imagens Pulmonares - PROTOCOLO BR5120150015826, 2015.

1.5 Organização do Trabalho

Esta tese está organizada em 5 Capítulos. No Capítulo 2, inicialmente são descritas as características dos pulmões em imagens TC, bem como são apresentados os conceitos e o estado da arte de Modelos Ativos. Além disso, ainda no mesmo Capítulo são abordadas texturas em imagens digitais com foco em LBP, bem como são apresentados os conceitos de MLP e a detecção das fissuras pulmonares por matriz Hessiana. No Capítulo 3 é descrita a metodologia proposta para realizar a segmentação automática dos lobos em imagens de TC do Tórax, bem como são destacadas e detalhadas as contribuições deste trabalho e os procedimentos para avaliação da metodologia proposta. No Capítulo 4, por sua vez, são apresentados e discutidos os resultados dos testes realizados, em imagens sintéticas e em exames de TC para validar o método proposto. Por fim, no Capítulo 5, são apresentadas as conclusões, contribuições, considerações e trabalhos futuros.

Capítulo 2

Fundamentação Teórica e Estado da Arte

Neste Capítulo, inicialmente, são apresentadas características dos pulmões e suas estruturas em imagens médicas de TC. Em seguida, é descrito um estudo contendo conceitos, características, estrutura e composição de Modelos Ativos e estado da arte sobre a evolução destas técnicas. Após o referido estudo são abordadas texturas aplicadas em imagens digitais com foco em LBP, bem como é descrita a aplicação de matriz Hessiana para a detecção das fissuras pulmonares.

2.1 Imagens Médicas Pulmonares

A descoberta dos raios-X em 1885 pelo físico Wilhelm Conrad Röntgen permitiu realizar radiografias do corpo humano e representar imagens de duas dimensões. No início da década de 70, foi desenvolvida por Hounsfield, a primeira geração da TC, introduzida comercialmente em 1973, chamada de EMI Markuma. Esta máquina de tomografia permitia computar imagens em seções cruzadas de alta qualidade e adquirir uma imagem com grande precisão (HOUNSFIELD, 1973; KALENDER, 2006).

A TC é um método de aquisição de imagens no plano axial, mas permite uma visualização em outros planos de cortes, através da reconstrução da imagem, como é possível visualizar na Figura 2.1.

A estimativa do cálculo de atenuação de raios-X é feita de forma precisa pela TC. Para realizar esta tarefa, a TC faz diversas medições de atenuação radiográfica, por meio de um plano com 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,

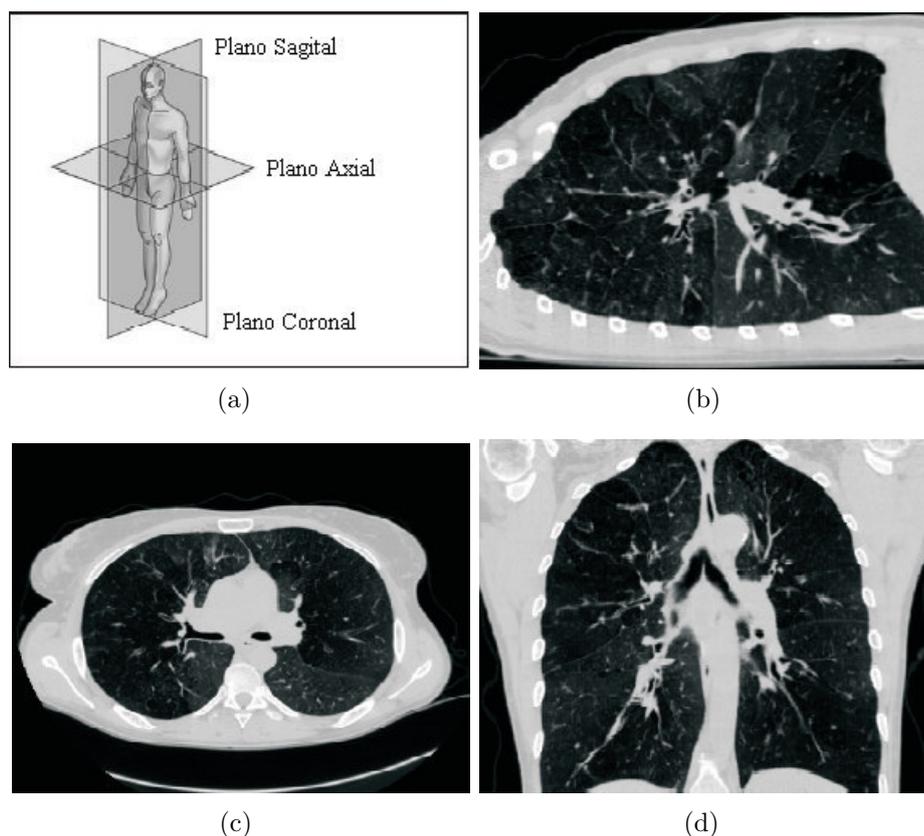


Figura 2.1: imagens de seções do pulmão adaptada de Sluimer, Prokop e Ginneken (2005), (a) planos de corte em relação ao corpo humano; (b) seção sagital; (c) seção axial; e (d) seção coronal.

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 se estende pela espessura da seção. Um voxel, ou menor elemento de volume, corresponde ao valor real de uma imagem em 3D ($p \times p \times e$) (HOUNSFIELD, 1973; BONTRAGER, 2000).

A dimensão p é referente à resolução da TC e a dimensão e refere-se à espessura da fatia da seção, conforme é ilustrado na Figura 2.2. O valor de cada voxel da imagem corresponde à atenuação da intensidade dos raios-X incidentes no tecido do órgão analisado (MAHESH, 2002).

O coeficiente de atenuação ou absorção quantifica a tendência de um corpo absorver os raios-X e é definido por (EPSTEIN, 2007; MAHESH, 2002)

$$UH_{tecido} = 1000 \times \frac{(\mu_{tecido} - \mu_{\acute{a}gua})}{(\mu_{\acute{a}gua})}, \quad (2.1)$$

em que μ_{tecido} é a medida do coeficiente de absorção, na região representada por um voxel, de um determinado tecido do corpo e $\mu_{\acute{a}gua}$ o coeficiente de absorção para a água. Neste caso, o coeficiente de atenuação da água, assim como também o do ar, é usado como

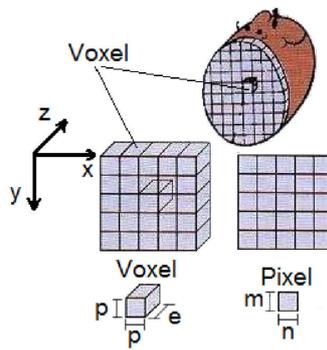


Figura 2.2: representação de um elemento de volume voxel no lado esquerdo e de um pixel no lado direito, adaptada de Bontrager (2000).

referência no processo de calibração de um tomógrafo.

A TC possui uma escala de densidade radiográfica representada em Unidades Hounsfield (UH). Nesta escala, diferentes tipos de tecidos apresentam valores distintos em UH, permitindo a determinação de faixas de densidade para cada tipo de tecido, inclusive os patológicos. Os valores em UH para determinados tipos de tecidos e órgãos do corpo humano são apresentados na Figura 2.3.

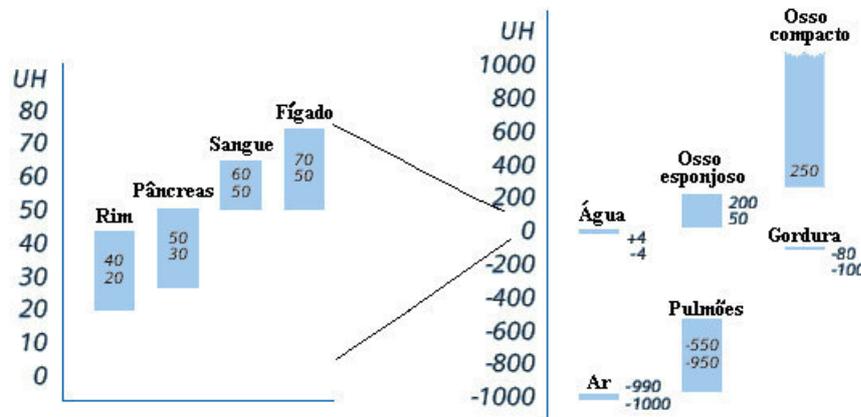


Figura 2.3: escala em unidades Hounsfield de estruturas do corpo humano, adaptada de Siemens (2004).

A TC trabalha tipicamente em uma escala de 16 bits, porém na prática são medidos valores entre -3000 a 1000 UH. Para o pulmão, com todas as suas estruturas, a faixa da escala está compreendida entre -1000 UH a $+100$ UH (SLUIMER; PROKOP; GINNEKEN, 2005). Esta faixa pode ser subdividida de forma que possibilite a identificação e caracterização de estruturas e regiões pulmonares. Deste modo, as principais faixas de densidade para caracterização de regiões pulmonares são (GEVENOIS; YERNAULT, 1995):

- de -1000 a -900 UH para áreas hiperaeradas;
- de -900 a -500 UH para áreas normalmente aeradas;

- de -500 a -100 UH para áreas pouco aeradas; e
- de -100 a 100 UH para áreas não aeradas.

Uma imagem de TC de pulmões e sua representação em faixas de densidade UH é ilustrada na Figura 2.4. Na Figura 2.4(b), cada cor representa uma faixa de densidade citada anteriormente, em que vermelho representa regiões hiperaeradas, azul as normalmente aeradas, verde as áreas pouco aeradas, amarelo representa as não aeradas e preto áreas não classificadas.

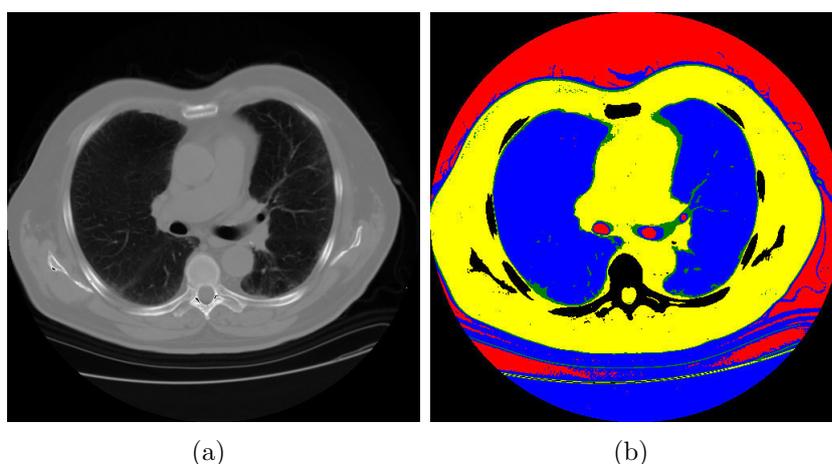


Figura 2.4: imagem de TC do tórax no eixo axial, (a) imagem original e (b) representação colorida em faixas de densidade UH.

A avaliação clínica de um paciente com suspeita de doença do pulmão pode ser um problema difícil. Sintomas semelhantes e, em alguns casos, achados radiológicos do tórax podem se associar a uma variedade de doenças agudas ou crônicas. Neste contexto, exames de TC juntamente com avaliações clínicas têm assumido um papel cada vez mais importante na avaliação e no diagnóstico de pacientes (STRZELECKI et al., 2013).

2.1.1 Lobos e Fissuras Pulmonares

Os pulmões estão localizados na cavidade torácica e são revestidos externamente por uma membrana denominada pleura. O pulmão esquerdo é dividido em um lobo superior e um lobo inferior por uma fissura oblíqua. O pulmão direito possui uma fissura horizontal, menor, que separa os lobos superior e médio, e uma fissura oblíqua que separa o lobo inferior dos lobos superior e médio. As fissuras interlobares são depressões profundas que se estendem a partir da superfície externa do pulmão para o seu centro (GODWIN; TARVER, 1985; UKIL; REINHARDT, 2009).

A pleura visceral, que cobre toda a superfície do pulmão, também penetra profundamente nas fissuras para que nestas áreas, a pleura visceral de lobos adjacentes entre em contato. Devido a este revestimento pleural, é possível que os lobos individuais se movam livremente um em relação ao outro. É possível observar a fissura oblíqua e a horizontal dividindo o pulmão direito em três lobos na Figura 2.5(a). Já na Figura 2.5(b) observa-se o pulmão esquerdo com a existência da fissura oblíqua separando-o em dois lobos (UGALDE; CAMARGO; DESLAURIERS, 2007).

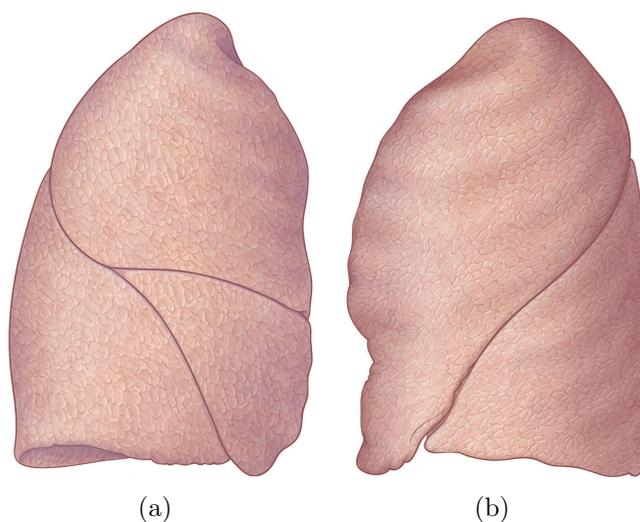


Figura 2.5: imagens 3D do pulmão, (a) direito com evidência da fissura; e (b) esquerdo com evidência da fissura (UGALDE; CAMARGO; DESLAURIERS, 2007).

Todavia, a variabilidade anatômica entre os seres humanos permite variações na definição dessas fissuras. Em alguns casos é comum a presença de outra fissura, denominada de fissura acessória, que apenas se faz presente nos pulmões porém não cria um novo lobo. Outra variação possível é a inexistência de alguma das três fissuras normais ou interlobares. Neste caso, a fissura que geralmente não existe é a fissura horizontal do pulmão direito que separa os lobos superior e médio. Além das variações anatômicas, a variabilidade das fissuras também acontece por intervenção cirúrgica. Após uma lobectomia, quando um lobo é retirado do paciente, por exemplo, a fissura que dividia o lobo removido pode se tornar a borda deste pulmão (GODWIN; TARVER, 1985; CRONIN et al., 2010).

A segmentação dos lobos por meio da detecção das fissuras pulmonares em imagens de TC tornou-se viável com o advento dos tomógrafos de múltiplos detectores, permitindo a obtenção de imagens de todo o pulmão com espessura reduzida, uma vez que as fissuras são superfícies finas nos pulmões. Fissuras podem muitas vezes ser observadas como curvas finas com altos valores de atenuação, em comparação com os tecidos circundantes (WEBB; MÜLLER; NAIDICH, 2008). É possível observar duas imagens de TC em que as fissuras são

destacadas no interior de retângulos na Figura 2.6.

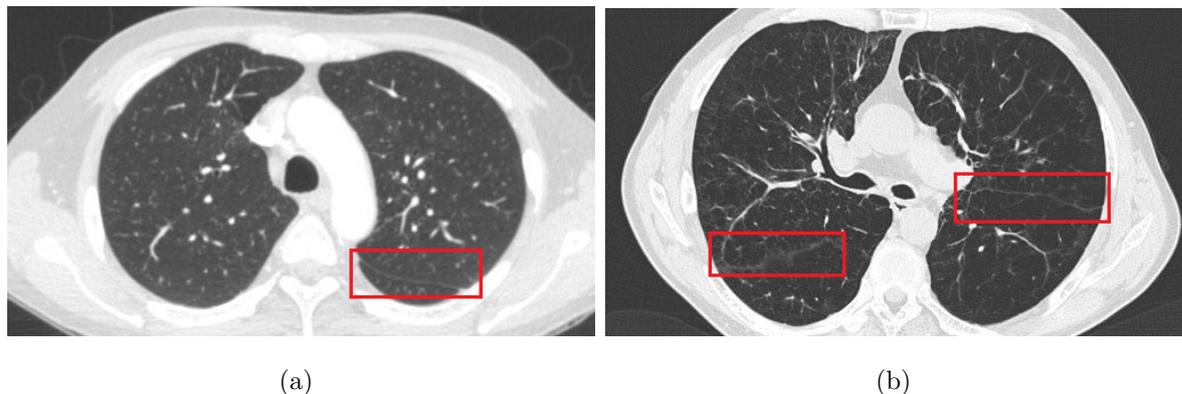


Figura 2.6: imagens de TC com ênfase nas fissuras.

Cronin et al. (2010) realizaram um estudo sobre as fissuras normais e acessórias, em um banco de 150 exames de TC, com a finalidade de estabelecer uma frequência para a presença das fissuras normais e acessórias, a continuidade ou a integralidade das fissuras além de outras características. Com o banco utilizado, Cronin et al. (2010) constataram a presença das fissuras oblíquas esquerda e direita em 100% dos exames, enquanto a fissura horizontal do pulmão direito se fez presente em 96,7% dos exames. Além disso, no mesmo estudo observou-se que fissuras acessórias estiveram presentes em 40% dos exames.

Nesse sentido, conclui-se que a detecção de fissuras é uma tarefa extremamente complexa, pois a densidade destas se assemelha bastante à densidade de outras estruturas como, por exemplo, pequenos vasos sanguíneos. O efeito de volume parcial, causado pela interpolação realizada pela TC para representar uma fatia do corpo humano em uma única imagem, deteriora a representação de algumas partes das fissuras, deixando-as incompletas. Além disso, a presença de fissuras acessórias, que não compõem os limites dos lobos, podem gerar detecções falso positivas. Nas Figuras 2.7(a) e 2.7(c), são ilustrados exemplos de fissura incompletas, pois as mesmas possuem trecho não representado na imagem. Já nas Figuras 2.7(e) e 2.7(g) é possível visualizar a semelhança das fissuras com outras estruturas pulmonares.

Dada a complexidade na detecção de fissuras pulmonares, diversas técnicas têm sido empregadas, dentre as quais se destacam os modelos ativos.

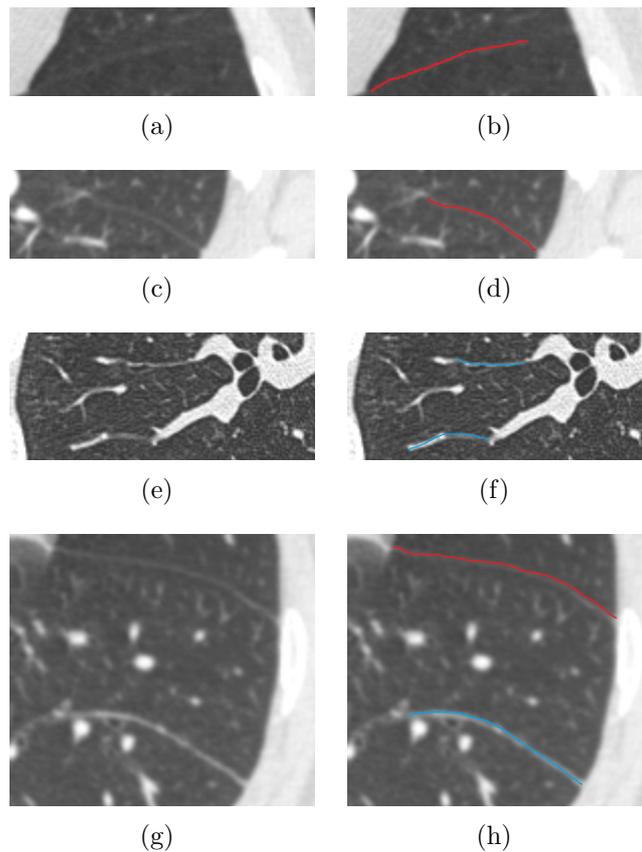


Figura 2.7: recortes de imagens de TC (a), (c), (e) e (g) recortes originais, (b), (d), (f) e (h) recortes com fissura destacada em vermelho e estruturas semelhantes as fissuras destacadas em azul.

2.2 Modelos Ativos

Modelos ativos, também conhecidos como modelos deformáveis, são uma família extremamente popular de métodos de segmentação e suas aplicações em imagens médicas são inúmeras. Desde o trabalho pioneiro de Kass, Witkin e Terzopoulos (1987), uma quantidade considerável de pesquisas tem sido realizada sobre diversos aspectos dos modelos ativos (MCINERNEY; TERZOPOULOS, 1996; MOORE; MOLLOY, 2007; SURI, 2007; HE et al., 2008).

Modelos ativos são tradicionalmente classificados em dois tipos dependendo da forma como o contorno ou superfície é representado, sendo estes os modelos ativos paramétricos ou explícitos e os modelos ativos geométricos ou implícitos (HONG et al., 2014).

Os modelos paramétricos originalmente introduzidos por Kass, Witkin e Terzopoulos (1987) parametrizam explicitamente contornos ou superfícies. Dessa forma, possuem uma estrutura de dados leve, possibilitando cálculos rápidos e maior eficiência computacional,

porém possuem certa dependência em relação à parametrização, além de limitada flexibilidade topológica quando comparado aos modelos ativos geométricos (FAN; JIANG; EVANS, 2002). Os modelos geométricos, por sua vez, baseiam-se na teoria de evolução da curva e no método level set, sendo capazes de lidar automaticamente com adaptações topológicas, porém apresentam custo computacional bem mais elevado (DUFOUR et al., 2011).

Os modelos ativos geométricos são independente de inicialização e são capazes de lidar com regiões de alta curvatura. No entanto, este tipo de modelo não é capaz de extrair os limites dos objetos que têm as bordas abertas ou quebradas. Além disso, são mais lentos e mais sensíveis ao ruído em comparação aos modelos paramétricos. Em geral, os modelos paramétricos podem ser aplicados diretamente no domínio desejado, permitindo interação direta e alta eficiência. Logo, para aplicações em que as características da topologia devem ser preservadas, os modelos ativos paramétricos são mais adequados (MISHRA; FIEGUTH; CLAUSI, 2010; FAN; JIANG; EVANS, 2002).

Nesse contexto, uma vez que se deseja preservar as características topológicas dos lobos segmentados, e ressaltando que as fissuras em exames de TC geralmente não são apresentadas de forma completa, conforme abordado na seção 2.1, causando falhas em partes da superfície do lobo, esta tese concentra seus esforços na abordagem dos modelos ativos paramétricos.

O princípio de funcionamento dos modelos ativos consiste em evoluir uma curva ou superfície deformando-a, sob a influência das energias interna e externa para captar a superfície do objeto ou região de interesse. Este processo pode ser realizado por iterações sucessivas atuando diretamente em cada ponto de controle do modelo, realizando uma busca pela energia mínima (MCINERNEY; TERZOPOULOS, 1996; FÉLIX, 2011).

Tipicamente, a energia interna é relacionada às propriedades e características geométricas do modelo, priorizando por manter a suavidade e uniformidade da curva. Já a energia externa é calculada considerando o espaço em que o modelo ativo é aplicado, seja uma imagem digital 2D, ou um conjunto de dados volumétricos em 3D (COHEN; COHEN, 1993).

Geralmente, a energia externa é definida utilizando um gradiente de imagem ou outras métricas de interesse, sendo a menor energia externa encontrada onde o gradiente for máximo ou onde as outras métricas indicarem a região de interesse. Dessa forma, o modelo ativo é atraído para as bordas e regiões de interesse, realizando a segmentação do objeto.

Para melhor definição e apresentação de propriedades e características dos modelos

ativos, o MCA é abordado no Apêndice A, enquanto o MSA é descrito a seguir.

2.2.1 Método de Superfícies Ativas - MSA

A extensão do Método de Contornos Ativo para 3D foi criada como Método das Superfícies Ativas (MSA), todavia alguns trabalhos na literatura também se referem ao MSA como MCA 3D ou como Modelos Deformáveis 3D. A representação computacional do MSA também é conhecida como Método das Malhas Ativas, pois computacionalmente as superfícies são discretizadas e representadas como malhas (JAOUEN et al., 2013).

Semelhante ao MCA, a ideia central do MSA é evoluir um modelo deformável iterativamente, também sob a influência das energias interna e externa para captar a superfície de um objeto 3D. Desta forma, a superfície ativa se desenvolve de tal modo que esta se modela para adequar-se a forma que reduz sua mínima energia (COOK et al., 2015; SLABAUGH; UNAL, 2005).

A energia interna do MSA deve ser definida de tal forma que lhe permita representar a topologia e formato da região de interesse. Tipicamente, a energia interna mantém a suavidade da superfície e é definida utilizando restrições elásticas.

Enquanto isso a energia externa, responsável por induzir o modelo deformável para os limites do objeto 3D, deve possuir informações e características que melhor descrevam esse objeto no espaço de dados volumétrico. É geralmente definida utilizando um gradiente de imagem ou, possivelmente, outras métricas na imagem de interesse (COOK et al., 2015; MISHRA; FIEGUTH; CLAUSI, 2010).

De forma análoga à parametrização do MCA na Equação A.1, o MSA consiste na parametrização 3D de uma superfície geométrica v da forma (COHEN; COHEN, 1993)

$$\begin{cases} [0, 1] \times [0, 1] \rightarrow R^3 \\ v(s, r) = [x(s, r), y(s, r), z(s, r)], \end{cases} \quad (2.2)$$

na qual a posição de cada ponto $v(s, r)$ é determinada pelas coordenadas $x(s, r)$, $y(s, r)$ e $z(s, r)$. Conseqüentemente, a energia E associada à superfície é definida por

$$E = \int_0^1 E_s [v(s, r)] ds = \int_0^1 \{E_{int} [v(s, r)] + E_{ext} [v(s, r)]\} ds, \quad (2.3)$$

em que o termo E_s representa a energia total de um ponto, E_{int} e E_{ext} representam a energia interna e a energia externa, respectivamente.

A energia interna, por sua vez, é dada por (COHEN; COHEN, 1993)

$$E_{\text{int}} [v(s, r)] = \alpha_1(s) \left| \frac{\partial}{\partial s} v(s, r) \right|^2 + \alpha_2(s) \left| \frac{\partial}{\partial r} v(s, r) \right|^2 + \beta_1(s) \left| \frac{\partial^2}{\partial s^2} v(s, r) \right|^2 + \beta_2(s) \left| \frac{\partial^2}{\partial r^2} v(s, r) \right|^2, \quad (2.4)$$

em que $\alpha_1(s)$, $\alpha_2(s)$, $\beta_1(s)$ e $\beta_2(s)$ determinam a relevância de cada termo da energia interna no ponto $v(s, r)$. Geralmente, a energia interna é composta por mais de um termo, na equação 2.4 os termos que contêm α representam a força de continuidade, enquanto os termos que contêm β representam a força de curvatura.

Assim como no MCA, a energia externa do MSA pode ser definida utilizando um gradiente da imagem ou outras métricas de interesse, como por exemplo métricas baseadas em texturas LBP ou autovalores da matriz Hessiana.

Da mesma forma que os objetivos e características do MSA são semelhantes ao MCA, o princípio de funcionamento e iteração também são definidos da mesma forma. Um dos maiores desafios na passagem de curvas 2D para superfícies 3D é o crescimento significativo da quantidade de pontos de controle e de dados a serem processados, gerando, conseqüentemente, um aumento significativo no tempo de processamento (MISHRA; FIEGUTH; CLAUSI, 2010).

Cohen e Cohen (1993) classificam trabalhos de modelos ativos aplicados em conjuntos de dados tridimensionais em modelos ativos 3D e $2 \frac{1}{2}$ D. Nesta classificação, os modelos ativos $2 \frac{1}{2}$ D consistem em um conjunto de contornos 2D independentes, em que cada contorno é aplicado em um nível diferente da terceira dimensão. Desta forma, não há influência nenhuma de um contorno sobre o outro.

Já os modelos ativos 3D, segundo a mesma classificação de Cohen e Cohen (1993), consistem em um conjunto de contornos 2D interligados entre si, em que a energia calculada para um ponto de um contorno específico sofre influência não só dos pontos do próprio contorno, mas também dos pontos dos contornos adjacentes. Todavia, essa classificação não costuma ser encontrada em outros trabalhos da literatura.

Entretanto, baseado na revisão bibliográfica realizada, é possível classificar as variações de MSA paramétricos propostas na literatura em basicamente três grupos:

- conjunto de contornos 2D independentes, em que cada contorno é aplicado em um nível diferente da terceira dimensão, não existindo relação entre os mesmos (TERZOPOULOS; WITKIN; KASS, 1987, 1988);
- conjunto de contornos 2D interligados entre si, formando uma malha estruturada, em que a energia calculada para um ponto de um contorno específico sofre influência

não só dos pontos do próprio contorno, mas também dos pontos dos contornos adjacentes, cuja movimentação de contornos se restringe ao plano em que o mesmo é aplicado (COHEN; COHEN, 1993; REBOUÇAS FILHO et al., 2013b, 2015);

- conjunto de pontos representados em 3D que se ligam de acordo com a regra de formação do tipo de malha adotada. A energia de cada ponto sofre influência dos pontos aos quais este é ligado, bem como o movimento do ponto não se restringe ao plano em que foi aplicado, podendo o mesmo ser deslocado em qualquer um dos três eixos existentes (PONS; BOISSONNAT, 2007; JAOUEN et al., 2013; FETITA et al., 2014).

Tanto para o segundo como para o terceiro grupo de MSA é necessária a utilização de malhas computacionais. O tipo de estrutura de malha adotada pode influenciar nas características, comportamento e conseqüentemente nos resultados obtidos. Nesse sentido, uma breve discussão sobre malhas abordando suas principais características e tipos é apresentada a seguir.

2.2.1.1 Malhas

Gerar uma malha consiste em dividir o domínio físico em subdomínios ou elementos. Superfícies podem ser subdividida em triângulos ou quadriláteros por exemplo, enquanto volumes em formatos tetraedros ou hexaedros. A criação de malhas geralmente é necessária para facilitar soluções numéricas de uma equação diferencial, como por exemplo para análise de elementos finitos (LO, 2014).

Basicamente existem dois tipos de geração de malhas, sendo um para malhas estruturadas e outro para malhas não estruturadas. As técnicas para geração de malhas estruturadas são baseadas em regras para subdivisões geométricas. Malhas estruturadas têm uma divisão clara e podem ser reconhecidas pelo fato de todos os pontos de controle, ou nós, da malha possuírem a mesma quantidade de elementos adjacentes. São mais simples e de fácil implementação. Já as malhas não estruturadas não limitam a quantidade de elementos adjacentes de cada ponto de controle e quando comparada com as malhas estruturadas possuem melhor representação de geometrias complexas (KALLEMEYN et al., 2012).

As malhas estruturadas apresentam diversas limitações quando aplicadas em geometrias irregulares. Fato este que costuma inviabilizar sua aplicação, uma vez que a geometria de problemas reais costuma ser complexa e irregular.

Além disso, o refinamento para aumento de acurácia e precisão, para este tipo de malha, depara-se no problema de otimização de recursos, pois não é possível refinar apenas uma região de maior interesse ou com mais detalhes em sua geometria sem refinar todo o restante da malha. Este problema se agrava bastante em espaços 3D, pois esse tipo de malha não permite que um nó possua quantidade de nós interligados (nós vizinhos) diferente dos demais. Dessa forma, todos os contornos 2D em cada plano devem possuir a mesma quantidade de pontos (GOURDON, 1995; GONÇALVES, 2007).

As malhas não estruturadas, por permitirem que cada nó possua qualquer quantidades de nós vizinhos, possui maior flexibilidade e conseqüentemente melhor adaptação às superfícies irregulares, sendo bastante útil na modelagem de problemas práticos, pois todos os detalhes geométricos podem ser incorporados de uma forma precisa, e as propriedades da malha podem ser controladas para captar características úteis em regiões de interesse. Todavia esse tipo de malha é muito mais complexa do ponto de vista de estrutura e armazenamento de dados e necessita de maior tempo de processamento para que as ligações sejam estabelecidas (GOURDON, 1995; GONÇALVES, 2007).

Os métodos de malhas não estruturadas surgiram como uma alternativa para as técnicas de malha estruturadas, com o intuito de representar geometrias complexas. Tais métodos proporcionam maior flexibilidade para discretização de domínios complexos e permitem uma implementação simples de técnicas adaptativas, sendo possível adicionar ou excluir nós, enquanto a conectividade da malha é atualizada localmente, a fim de melhorar a precisão da solução (BONO; AWRUCH, 2007).

Vergel (2013) demonstra que a utilização de malhas não estruturadas fornecem bons resultados, pois, detalhes de geometrias complexas não permitem que malhas estruturadas sejam sempre empregadas. Em muitos problemas, as malhas estruturadas conseguem uma discretização adequada do domínio do problema. Contudo, as malhas não estruturadas são mais versáteis, com maior facilidade para adaptar-se e adequada na discretização de geometrias irregulares.

Diversas pesquisas são realizadas para melhorar os métodos de geração de malhas e os adaptar às diversas aplicações propostas na literatura, principalmente na área de imagiologia médica.

Zhang (2013) realiza um estudo sobre os desafios e técnicas de geração de malhas aplicado em exames de TC e ressonância magnética. Chen, Tu e Lu (2013) aplica malhas triangulares para modelar superfícies biomoleculares.

Park, Shontz e Drapaca (2013) também apresentam uma aplicação utilizando malhas para acompanhar a evolução do cérebro e do líquido cefalorraquidiano em pacientes com hidrocefalia. Já Bayat (2014) realiza estudo comparativo entre tipos de malha para modelagem da aorta em imagens médicas tridimensionais.

Chernikov et al. (2013) avalia três abordagens de geração de malha em relação à adequação destes para uso em um sistema de simulação de cirurgia. A avaliação sobre o desempenho dos métodos foi realizada baseada na fidelidade da malha e no tempo de computação de cada método.

Zubair, Abdullah e Arifin (2013) realizam estudos sobre o fluxo de ar nasal empregando malhas não estruturadas, comparando os resultados obtidos entre os tipos de malha abordados e analisando o efeito sobre os parâmetros de fluxo no interior da cavidade nasal.

É notório que a área de pesquisa exclusivamente sobre malhas é ampla e apresenta vários desafios a serem superados. Todavia, por não se tratar do objetivo deste trabalho, abordagens mais complexas sobre o desenvolvimento de malhas não são realizadas. A seguir são descritos alguns métodos de geração de malhas, populares na literatura, que são utilizados nos algoritmos propostos nesta tese.

Malha Estruturada Regular

Existem dois tipos de malhas estruturadas, as geometricamente estruturadas e as topologicamente estruturadas. Um exemplo de uma malha geometricamente estruturada é a malha estruturada regular, na qual todos os elementos possuem o mesmo espaçamento nas dimensões existentes no domínio.

Malhas estruturadas são fáceis de gerar e manipular, além de permitir o uso de uma estrutura de dados simples, simplificando a implementação computacional. Entretanto, o uso deste tipo de malha não é aconselhado para aplicações com geometrias complexas.

Para a obtenção de uma malha estruturada regular, basta realizar a divisão do espaço geométrico pela quantidade de volumes que se deseja, obtendo dessa forma os pontos de controle na interseção das divisões. Quanto mais pontos, mais precisa é a solução obtida pela malha e maior também é o esforço computacional, em termos de processamento e de memória, necessário para obtê-la.

Malha kNN (*k* - *Nearest Neighbor*)

Nesta abordagem, sugerida por Bercovier, Pironneau e Sastri (1983), para cada ponto ou nó do domínio são estabelecidas ligações da malha para os k pontos mais próximos (vizinhos mais próximos). Além da simplicidade, este método também possui requisitos de configuração e armazenamento extremamente simples, em que a tabela de pesquisa

pode ser reduzida a um vetor de pontos que apontam elementos deste próprio vetor. Entretanto, o custo computacional para calcular as distâncias entre todos os pontos cresce exponencialmente com a quantidade de pontos presente no domínio (KHOSHNIAT; STUHNE; STEINMAN, 2003).

Nesse tipo de malha deve-se limitar o valor de k . Além disso, com o intuito de reduzir a quantidade de cálculos, um raio de proximidade, representado pela distância máxima a ser considerada entre dois pontos também pode ser limitado. Algoritmos que usam conjunto de pontos, ou nuvem de pontos, geralmente utilizam este método para construção de malhas ou até mesmo outras operações. Todavia, mesmo com a limitação de distância máxima, a grande quantidade de pontos presente nos conjuntos de dados exige métodos mais eficientes de calcular os k pontos mais próximos, pois a quantidade de pontos dentro do raio de proximidade ainda é considerável (SANKARANARAYANAN; SAMET; VARSHNEY, 2007; KHOSHNIAT; STUHNE; STEINMAN, 2003).

Nesse contexto, diversos trabalhos vem buscando otimizar este método, bem como propor novas abordagens para torná-lo mais eficiente, com o intuito de não inviabilizar a utilização do mesmo (SANKARANARAYANAN; SAMET; VARSHNEY, 2007)

Malha Delaunay

Das muitas possíveis triangulações 3D de pontos, a triangulação de Delaunay é uma das estruturas de base em geometria computacional. Bastante popular, a triangulação de Delaunay geralmente é a primeira escolha para a construção de malhas. Uma das propriedades que a torna desejável é a minimização do raio de contenção dos triângulos. O raio de contenção é definido como o raio da menor esfera que circunscreve o tetraedro, quanto menor este raio mais compacta torna-se a triangulação, o que a torna inestimável para a geração de malha (DELAUNAY, 1934; NANJAPPA, 2012).

A triangulação de Delaunay como metodologia geradora de malhas se destaca por permitir a criação de polígonos com ângulos máximos semelhantes a partir de quaisquer pontos. Isto é, dado um conjunto de pontos geradores de uma malha, existe um elevado número de maneiras de uni-los formando um conjunto de triângulos. Contudo, o matemático Boris Delaunay provou que existe apenas uma única solução para unir esses pontos de modo que o menor ângulo do triângulo seja maximizado tornando-os assim os mais equiláteros possíveis, conforme ilustrado na Figura 2.8 (DELAUNAY, 1934; PONS; BOISSONNAT, 2007).

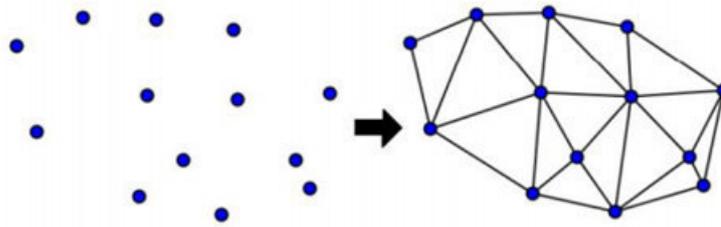


Figura 2.8: exemplo de malha Delaunay.

Para gerar a malha Delaunay a partir de um conjunto de P pontos, faz-se necessário atender a determinadas condições de Delaunay. Essas condições tem como premissa básica a construção de uma triangulação se, e somente se, nenhum ponto permanecer interno ao círculo que circunscreve qualquer outro simplex ¹ da triangulação dado que já exista algum. Sakamoto (2007) define formalmente uma triangulação de Delaunay de um domínio Ω , limitado e poliédrico, como um conjunto τ de triângulos, de modo que, para esse conjunto, as seguintes condições são válidas:

- a interseção de dois triângulos é vazia ou se reduz a um vértice, a uma aresta ou a uma face, para os casos 2D e 3D, respectivamente;
- a união de todos os triângulos implica no domínio;
- os elementos de τ devem ser regulares com ângulos máximos; e
- o circuncírculo (2D) ou circunsfera (3D) de um elemento é vazio.

A fim de atender a essas condições, define-se um simplexo K como uma lista ordenada dos vértices P_i , em que $i = 1, 2, \dots, d + 1$ e d é a dimensão do espaço.

Para a adição de um novo ponto P_{i+1} ao conjunto de P pontos numa malha deve-se, primeiramente, analisar a situação geométrica deste ponto, sendo possível três situações (SAKAMOTO, 2007; PONS; BOISSONNAT, 2007):

1. P_{i+1} se encontra no interior de algum simplexo;
2. P_{i+1} não satisfaz a primeira situação, mas se encontra no interior de alguma circunferência que circunscreve algum simplexo; ou
3. P_{i+1} não satisfaz nenhuma das situações anteriores.

¹um simplex é uma generalização do conceito de triângulo a outras dimensões. É definido desta forma por ser sempre o polígono mais simples de uma dada dimensão, como por exemplo um triângulo em 2D e o tetraedro em 3D.

Para cada situação, há uma triangulação específica que envolve P_{i+1} . Para a primeira situação, são determinados os simplexos cujo circuncírculo contém o ponto P_{i+1} . Em seguida, a aresta comum entre esses simplexos é removida e os vértices que compunham esses simplexos são ligados ao ponto P_{i+1} , formando novos simplexos.

Na segunda situação, o ponto P_{i+1} é ligado aos vértices dos simplexos cujo circuncírculo contém o ponto P_{i+1} , as arestas dos simplexos que se sobrepõem às novas arestas são removidas, e então novos simplexos são gerados.

Na terceira e última situação, o ponto P_{i+1} é ligado aos vértices mais externos, desde que as novas arestas não se sobreponham às existentes.

É possível visualizar a inserção de um ponto em uma malha Delaunay na Figura 2.9, para cada uma das três situações descritas, o ponto P se enquadra na primeira situação e os pontos T e Q na segunda e terceira situações, respectivamente.

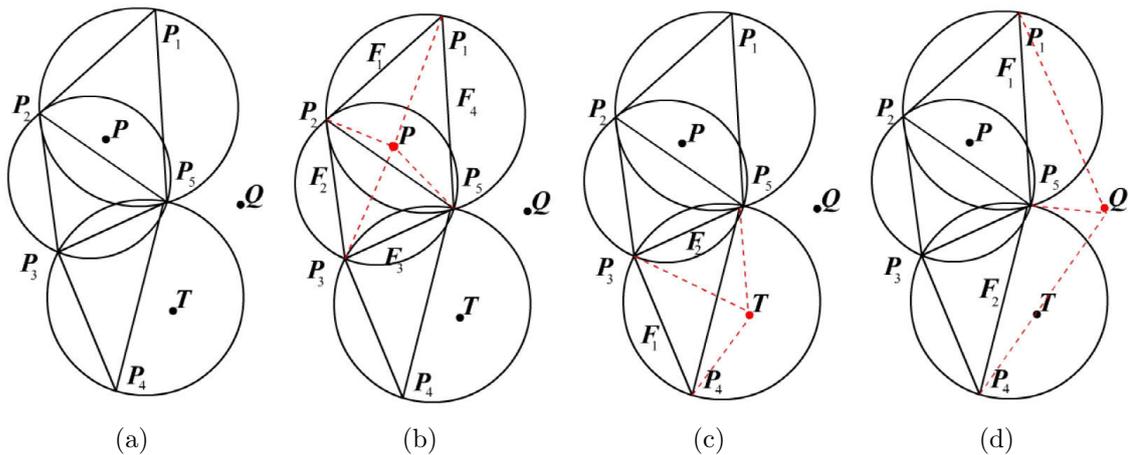


Figura 2.9: exemplos de adição de pontos em uma malha Delaunay (SAKAMOTO, 2007), (a) situação geométrica dos pontos, (b) situação 1, adição do ponto P ; (c) situação 2, adição do ponto T ; e (d) situação 3, adição do ponto Q .

Em um espaço 3D a malha Delaunay, em vez de triângulos como no caso 2D, é composta por tetraedros. Entretanto, a malha composta por tetraedros não se aplica ao estudo abordado nesta tese, uma vez que os pontos distribuídos no espaço 3D devem compor uma superfície e não um volume maciço.

Por mais que os pontos sejam dispostos compondo nitidamente a superfície de algum objeto, o algoritmo Delaunay realiza ligações internas até entre pontos de extremos opostos para compor os tetraedros.

Como o objetivo desta análise é comparar malhas superficiais ou malhas que se assemelham a uma superfície, foi utilizado nesta tese o algoritmo *Crust* (AMENTA; BERN;

KAMVYSSELIS, 1998), que é derivado do Delaunay 3D. O algoritmo *Crust*, em vez de uma malha tetraédrica, forma uma malha triangular no espaço, diferenciando-se basicamente por selecionar as faces dos tetraedros que se encontram na superfície de uma malha Delaunay tridimensional.

2.2.1.2 MSA e Malhas

Conforme relatado anteriormente, os MSAs que utilizam conjunto de contornos 2D interligados entre si ou um conjunto de pontos representados em 3D, utilizam malhas computacionais.

Na literatura, o tipo de malha mais comum utilizado em MSA é a malha estruturada regular. Bradshaw et al. (2013), por exemplo, propõe a reconstrução 3D dos canais semicirculares do ouvido interno através de um MSA que utiliza uma malha estruturada regular, inicializada em formato cilíndrico.

Delibasis, Kechriniotis e Maglogiannisc (2013a) propõem um MSA para segmentação de imagens médicas 3D utilizando a técnica de cilindros generalizados (SHANI; BALLARD, 1984), e também adota uma malha estruturada regular em formato cilíndrico. Ainda no mesmo ano Delibasis et al. (2013b) propõem outro MSA adicionando a transformada de Fourier durante a evolução da superfície, para segmentação de imagens médicas. Assim como o anterior, o MSA proposto utiliza uma malha estruturada regular em formato cilíndrico.

Delibasis et al. (2014) propõem outro MSA utilizando um filtro de resposta ao impulso infinita para as coordenadas dos pontos da superfície e assim como anteriormente proposto, a malha estruturada regular em formato cilíndrico se faz presente.

Delgado-Gonzalo, Chenouard e Unser (2013) propõe um MSA para segmentação 3D interativa de imagens médicas. O MSA baseia-se na deformação de elipses e, para representar as mesmas, faz uso de malha estruturada regular. Também Skalski et al. (2013) realizam a segmentação da próstata em imagens de ressonância magnética através de MSA com malhas estruturadas regulares.

Rebouças Filho (2013a) e Rebouças Filho et al. (2015) propõem um MSA para segmentação 3D dos pulmões em imagens de TC utilizando MSA, que por sua vez também adotam malha estruturada regular.

Barbosa et al. (2012, 2013, 2014) utilizam MSA com malhas estruturadas regulares para realizar a segmentação de imagens médicas em um sistema interativo e inferir dados volumétricos. Arroyo e DeSimone (2014) propõem um MSA inspirado no movimento dos

euglenóides, utilizando malhas estruturadas regulares. Fan, Jiang e Evans (2002) utilizam na segmentação do cérebro em imagens de ressonância magnética, um MSA baseado em algoritmos genéticos, que também adota uma malha estruturada regular.

Como discutido anteriormente na Subseção 2.2.1.1, as malhas estruturadas apresentam diversas limitações quando aplicadas em geometrias irregulares. Fato este que costuma inviabilizar algumas aplicações, tendo em vista que é comum encontrar geometrias complexas e irregulares em problemas reais.

A árvore aérea do sistema respiratório, por exemplo, é uma estrutura real que possui uma geometria extremamente complexa com diversas ramificações em vários sentidos. Para realizar a segmentação da árvore aérea em imagens de TC, motivado pela complexa geometria, Gu et al. (2013) propõem um MSA que utiliza uma malha não estruturada triangular. Dessa forma, os detalhes e pontos de alta curvatura podem ser corretamente representados. Todavia, para o cálculo da energia interna não foram consideradas as distribuições dos pontos. Neste caso, a energia interna proposta tomou como base a secção transversal da árvore aérea na imagem.

Fetita et al. (2014) também realizam a segmentação da árvore aérea em imagens de TC e, assim como Gu et al. (2013), utilizam MSA com malha não estruturada, bem como utilizam informações provenientes das vias aéreas para calcular a energia interna.

Jaouen et al. (2013) propõem um MSA para segmentação de imagens de tomografia por emissão de pósitrons. A malha utilizada neste MSA é não estruturada, porém sua energia total é definida exclusivamente pela energia externa. Zeng et al. (2013), para segmentação de tumores também em imagens de tomografia por emissão de pósitrons, utilizam um MSA com malha não estruturada, porém deriva uma função de energia que pode ser minimizada através de otimização convexa.

Uma classificação dos trabalhos citados de acordo com o tipo de malha adotada é realizada na Tabela 2.1. Nesse contexto, percebe-se que malhas não estruturadas não são tão presentes em MSA, por mais que apresentem determinadas vantagens e permitam resolver problemas que malhas estruturadas regulares não são capazes. Uma das dificuldades em utilizar malhas não estruturadas em MSA, consiste na formulação da energia interna. Uma vez que as malhas não estruturadas permitem que cada nó presente possua qualquer quantidade de vizinhos, além de permitirem que esta quantidade varie entre os nós da mesma malha, uma aproximação genérica e representação discreta das derivadas parciais necessárias para calcular a energia interna, conforme Equação 2.4, torna-se uma tarefa extremamente complexa.

Tabela 2.1: Classificação de trabalhos com MSA de acordo com o tipo de malha

Trabalho	Malha	Aplicação
Fan, Jiang e Evans (2002)	estruturada regular	segmentação do cérebro em imagens de ressonância magnética
Barbosa et al. (2012)	estruturada regular	segmentação de imagens de TC e ecocardiograma
Barbosa et al. (2013)	estruturada regular	segmentação de imagens de ecocardiograma
Bradshaw et al. (2013)	estruturada regular	reconstrução 3D dos canais semicirculares
Delibasis, Kechriniotis e Maglogiannisc (2013a)	estruturada regular	segmentação de estruturas cilíndricas em TC
Delibasis et al. (2013b)	estruturada regular	segmentação de bexiga em imagens de TC
Delgado-Gonzalo, Chenouard e Unser (2013)	estruturada regular	segmentação 3D interativa de imagens médicas
Gu et al. (2013)	estruturada triangular	segmentação da árvore aérea em imagens de TC
Jaouen et al. (2013)	não estruturada	segmentação de imagens de TC por emissão de pósitrons
Rebouças Filho (2013a)	estruturada regular	segmentação 3D dos pulmões em imagens de TC
Zeng et al. (2013)	não estruturada	segmentação de tumores em TC por emissão de pósitrons
Skalski et al. (2013)	estruturada regular	segmentação da próstata em imagens de ressonância magnética
Arroyo e DeSimone (2014)	estruturada regular	segmentação de euglenoida em imagens microscópicas
Barbosa et al. (2014)	estruturada regular	segmentação de imagens de ecocardiograma
Delibasis et al. (2014)	estruturada regular	segmentação de imagens médicas
Fetita et al. (2014)	não estruturada	segmentação da árvore aérea em imagens de TC
Rebouças Filho et al. (2015)	estruturada regular	segmentação 3D dos pulmões em imagens de TC

Além disso, de acordo com o Apêndice A, percebe-se que também é comum propor novos modelos ativos por meio da elaboração de como a energia deste é composta. É possível propor novas abordagens tanto para a energia interna como para a externa. Algumas energias externas propostas na literatura abordam áreas e aplicações específicas, fato este plenamente justificável por se tratar da energia que representa a imagem na qual o modelo ativo deve ser aplicado. Nesta tese, uma das formulações para energia externa proposta, para a segmentação dos lobos pulmonares, é baseada em texturas LPB.

2.3 *Local Binary Patterns - LBP*

A textura é uma importante característica na percepção visual de imagens, pois contém informações geralmente utilizadas pelo ser humano para a interpretação e análise de vários tipos de imagens, podendo ser interpretada como relações espaciais e arranjos de elementos básicos de uma imagem (GONZALEZ; WOODS, 2008).

Em uma imagem, textura se resume a um conjunto de métricas calculadas para representar e quantificar a textura real percebida pelo ser humano. Tais métricas fornecem informações sobre o arranjo espacial de cores ou intensidades em uma imagem ou região desta. Um exame de raio-x de um tecido com doença, por exemplo, pode aparecer com textura diferente devido aos diferentes coeficientes de absorção das células saudáveis e doentes dentro do tecido (SHAPIRO; STOCKMAN, 2001).

Texturas podem desempenhar um papel fundamental em uma ampla variedade de aplicações de visão computacional (VC). Dentre as áreas tradicionais em que é utilizada análise de texturas, é possível citar análise de imagens biomédicas, inspeção industrial, análise de imagens de satélite ou imagens aéreas, análise de imagens de documentos, e síntese de textura para computação gráfica ou animação (PIETIKAINEN et al., 2011).

Análise de texturas tem sido objeto de estudo de diversas pesquisas desde a década de 1960. Diversas técnicas e algoritmos para discriminar texturas foram propostos, todavia a maioria das técnicas propostas não apresenta uma representatividade satisfatória para texturas do mundo real, além de serem computacionalmente complexas (PIETIKAINEN et al., 2011). Nos últimos anos, descritores de textura locais representativos e computacionalmente eficientes foram propostos, tais como os padrões binários locais (LBP), conduzindo a um progresso significativo na aplicação de métodos de textura para vários problemas de VC (OJALA; PIETIKAINEN; HARWOOD, 1996; OJALA; PIETIKAINEN; MAENPAA, 2002). Tais descritores permitiram a ampliação das áreas de pesquisa de análises de texturas 2D para análises de texturas 3D e análises de texturas dinâmicas (vídeos) (CULA; DANA,

2001; LEUNG; MALIK, 2001; SAISAN et al., 2001; VARMA; ZISSERMAN, 2002).

LBP é um descritor simples e eficiente que rotula os pixels de uma imagem, atribuindo um número binário a cada um deles. Estes rótulos compõem um histograma que descreve a textura da imagem ou região em questão.

A representação por LBP tem sido vista como uma abordagem para unificar os modelos estatísticos e estruturais, tradicionalmente divergentes de análise de textura. O operador LBP proposto originalmente por Ojala, Pietikainen e Harwood (1996), atua em uma vizinhança 3×3 , usando o valor central como limiar. Após a limiarização, é gerado um código proveniente da soma dos produto entre os valores selecionados.

Alguns anos depois, Ojala, Pietikainen e Maenpaa (2002) apresentam uma formulação mais genérica para o operador LBP. Nesta formulação, adotada como padrão para o operador, o tamanho da vizinhança juntamente com a quantidade de amostras analisada nesta vizinhança podem assumir diversos valores.

Nesse contexto, para uma imagem em níveis de cinza $I(x, y)$, define-se g_c como o nível de cinza do pixel nas coordenadas (x, y) , e g_p como o nível de cinza de um ponto de amostra. Estes pontos são distribuídos em uma vizinhança circular com raio R centrada em (x, y) , em um total de P amostras. Dessa forma (OJALA; PIETIKAINEN; MAENPAA, 2002)

$$g_c = I(x_c, y_c), \quad (2.5)$$

$$g_p = I(x_p, y_p), \quad p = 0, \dots, P - 1, \quad (2.6)$$

em que,

$$x_p = x_c + R \cos(2\pi p/P) \quad (2.7)$$

e

$$y_p = y_c - R \sin(2\pi p/P). \quad (2.8)$$

São ilustrados exemplos das vizinhanças circulares mais utilizadas no operador LBP na Figura 2.10.

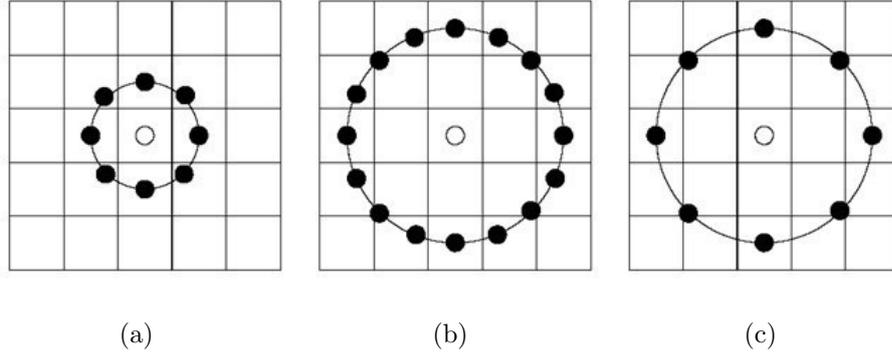


Figura 2.10: exemplos de vizinhança circulares, (a) $P = 8, R = 1$; (b) $P = 16, R = 2$; e (c) $P = 8, R = 2$ (PIETIKAINEN et al., 2011).

A textura T em uma vizinhança local de uma imagem monocromática é então definida como a distribuição conjunta dos níveis de cinza de P , sendo $P > 1$ (OJALA; PIETIKAINEN; MAENPAA, 2002),

$$T = t(g_c, g_0, g_1, \dots, g_{P-1}). \quad (2.9)$$

Para tornar a distribuição independente do nível de cinza, preservando as informações de textura, é realizada uma subtração nos valores da vizinhança circular g_p , do valor de g_c , logo (PIETIKAINEN et al., 2011)

$$T = t(g_c, g_0 - g_c, g_1 - g_c, \dots, g_{P-1} - g_c). \quad (2.10)$$

Em seguida, considerando que o pixel central é estatisticamente independente das diferenças, é possível realizar uma fatoração, obtendo a seguinte aproximação

$$T \approx t(g_c) t(g_0 - g_c, g_1 - g_c, \dots, g_{P-1} - g_c). \quad (2.11)$$

Vale ressaltar que, na prática, pode não existir uma independência, sendo a distribuição fatorada apenas uma aproximação. Desta forma, obtém-se certa invariância em relação às alterações nos níveis de cinza, pois a distribuição $t(g_c)$ na Equação 2.11 representa a luminosidade total da imagem, que não está relacionada com a textura local, não possuindo informação útil para a análise de textura.

Neste sentido, grande parte da informação útil da distribuição conjunta dos níveis de cinza da equação 2.9 é mantida pela diferença da distribuição conjunta (MAENPAA; PIETIKAINEN, 2005; PIETIKAINEN et al., 2011)

$$T \approx t(g_0 - g_c, g_1 - g_c, \dots, g_{P-1} - g_c). \quad (2.12)$$

A textura representada nesta equação é discriminativa, pois registra as ocorrências de vários padrões na vizinhança de cada pixel em um histograma de dimensão P . Nas regiões uniformes e constantes, as diferenças, $g_p - g_c$, são iguais a zero em todas as direções. Já nas regiões de borda, por exemplo, o operador registra a maior diferença na direção de gradiente e de valores iguais a zero ao longo das bordas.

Apesar da formulação apresentada na equação 2.12 ser invariável às alterações nos níveis de cinza, esta ainda é afetada pelo tamanho escala de cinza da imagem. Para também obter invariância em relação a qualquer escala de cinza, apenas os sinais das diferenças são consideradas (MAENPAA; PIETIKAINEN, 2005; PIETIKAINEN et al., 2011)

$$T \approx t[s(g_0 - g_c), s(g_1 - g_c), \dots, s(g_{P-1} - g_c)], \quad (2.13)$$

em que

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.14)$$

Por fim, um peso 2^p é atribuído a cada sinal $s(g_p - g_c)$, transformando as diferenças em um código LBP único. Este código caracteriza a textura de imagem local em torno do ponto na coordenada (x_c, y_c)

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p. \quad (2.15)$$

Esta equação define como um número binário de P bits os sinais das diferenças de uma vizinhança, resultando em 2^P possíveis valores para o código de LBP. Desta forma, a distribuição conjunta local, ou seja, a textura, pode ser aproximada como uma distribuição binária de códigos LBP (PIETIKAINEN et al., 2011),

$$T \approx t[LBP_{P,R}(x_c, y_c)]. \quad (2.16)$$

Uma extensão do operador apresentado usa os chamados padrões uniformes. Neste sentido, é necessário calcular a uniformidade U do padrão binário obtido. Assim, é atribuído a U um número relativo à quantidade de transições entre os bits de 0 para 1 ou de 1 para 0. Logo, um padrão binário é considerado uniforme caso U seja menor ou igual

a 2. Uma vez estabelecido a uniformidade do padrão binário, é atribuído um rótulo de saída para cada padrão uniforme, enquanto todos os padrões não uniformes recebem o mesmo rótulo. Assim, o número de rótulos nP para o mapeamento de padrões com P bits é definido

$$nP = P(P - 1) + 3, \quad (2.17)$$

ou seja, para uma vizinhança $P = 8$ o mapeamento de padrões uniformes possui apenas 58 rótulos, enquanto o mapeamento que não considera uniformidade apresenta 256 rótulos. São ilustrados os 58 padrões uniformes para vizinhança $P = 8$ na Figura 2.11 (OJALA; PIETIKAINEN; MAENPAA, 2002).

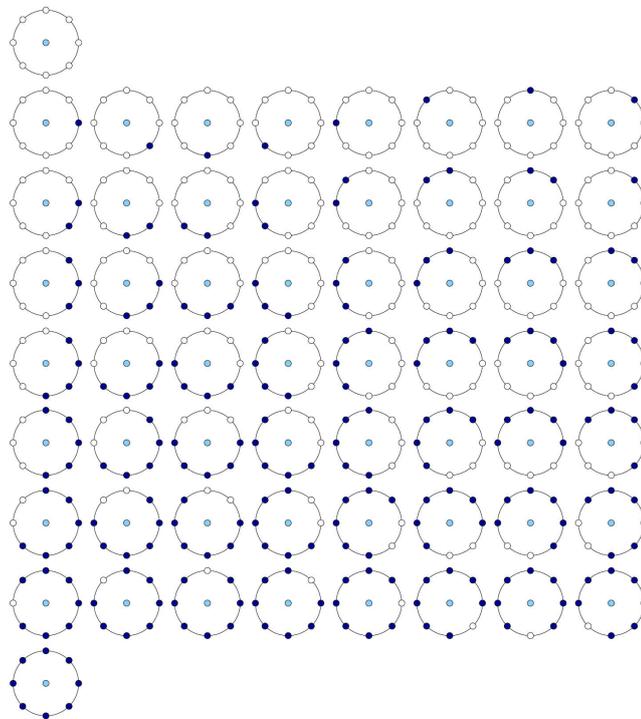


Figura 2.11: padrões uniformes para vizinhança $P = 8$ bits, bits com valor igual a 1 representados em escuro e com valor igual a 0 representados em claro. Adaptado de Pietikainen et al. (2011).

Ojala, Pietikainen e Maenpaa (2002) observam que a maioria dos padrões binários locais em imagens naturais são uniformes, quantificando-os em aproximadamente 90% dos padrões calculados quando se utiliza $P = 8$ e $R = 1$ e cerca de 70% com $P = 8$ e $R = 2$.

Considerar padrões uniformes proporciona robustez estatística, tornando os padrões mais representativos do conjunto de dados em questão. Pietikainen et al. (2011) relata que diversos trabalhos na literatura obtêm melhores resultados quando utilizados apenas os

padrões uniformes, em vez de todos os possíveis padrões. Além disso, os padrões uniformes são mais estáveis, menos propensos a ruído, e reduzem significativamente a quantidade de rótulos dos padrões, diminuindo conseqüentemente a quantidade de amostras para estimar uma determinada textura (PIETIKAINEN et al., 2011).

LBP com padrões uniformes podem ser interpretados como uma abordagem que contempla modelos estatísticos e estruturais (MAENPAA; PIETIKAINEN, 2005). Cada pixel é marcado com um rótulo de textura primitiva que corresponde à vizinhança local. Estas texturas primitivas incluem manchas, áreas planas, bordas, pontas de borda, curvas e assim por diante. A parcela estrutural do LBP corresponde à distribuição das texturas primitivas em uma região, sendo esta uma regra de posicionamento estatístico. Sendo assim, a distribuição LBP possui as texturas primitivas e as regras de posicionamento como propriedades de um método de análise estrutural.

Por outro lado, a distribuição pode ser considerada uma estatística de uma imagem filtrada de forma não linear, tornando o método também estatístico. Por estas razões, a distribuição LBP pode ser utilizada com sucesso em reconhecer uma grande variedade de texturas diferentes, para as quais os métodos estatísticos e estruturais normalmente são aplicados separadamente (PIETIKAINEN et al., 2011).

2.4 Segmentação de Fissuras com Matriz Hessiana

Matrizes Hessianas desempenham um papel importante em muitas áreas, como por exemplo, em problemas de otimização em larga escala dentro de métodos newtonianos. Na Seção 1.1 são citadas algumas pesquisas que realizam a segmentação de fissuras baseada nos autovalores das matrizes Hessianas extraídos dos exames de TC do tórax.

A matriz Hessiana é uma matriz quadrada das derivadas parciais de segunda ordem de uma função f . Se as segundas derivadas de f são contínuas em uma região D , então a Hessiana de f é uma matriz simétrica ao longo de D . Como f é muitas vezes evidente a partir do contexto, neste caso a imagem, $H[f(x)]$ é frequentemente abreviada como $H(x)$ (LANG, 1975; LIMA, 1985).

Dada uma função real de várias variáveis, $F : R^m \rightarrow R^n$ com $F(X) = (f_1(X), \dots, f_n(X))$, define-se a matriz jacobiana do gradiente denominada de matriz Hessiana de f . Assim, (LANG, 1975; LIMA, 1985; CHEN, 2012)

$$H [f(x_1, \dots, x_n)] = J \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix} = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \cdots & \frac{\partial^2 f}{\partial x_n \partial x_1} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_1 \partial x_n} & \cdots & \frac{\partial^2 f}{\partial x_n \partial x_n} \end{bmatrix}. \quad (2.18)$$

Para a detecção da fissura pulmonar, a função f em questão representa a imagem 3D do exame de TC do tórax, sendo $f(x, y, z)$ a densidade em UH do voxel. Neste sentido, para cada voxel com densidade em UH, semelhante à densidade das fissuras, uma matriz Hessiana local é construída usando as derivadas independentes de segunda ordem (WIEMKER; BÜLOW; BLAFFERT, 2005)

$$H = \begin{bmatrix} g_{xx} & g_{xy} & g_{xz} \\ g_{yx} & g_{yy} & g_{yz} \\ g_{zx} & g_{zy} & g_{zz} \end{bmatrix}, \quad (2.19)$$

em que utilizando diferenças finitas, obtém-se

$$\begin{aligned} g_{xx} &= f(x-1, y, z) - 2 \times f(x, y, z) + f(x+1, y, z), \\ g_{yy} &= f(x, y-1, z) - 2 \times f(x, y, z) + f(x, y+1, z), \\ g_{zz} &= f(x, y, z-1) - 2 \times f(x, y, z) + f(x, y, z+1), \\ g_{xy} = g_{yx} &= \frac{f(x+1, y+1, z) + f(x-1, y-1, z) - f(x+1, y-1, z) - f(x-1, y+1, z)}{4}, \\ g_{xz} = g_{zx} &= \frac{f(x+1, y, z+1) + f(x-1, y, z-1) - f(x+1, y, z-1) - f(x-1, y, z+1)}{4}, \text{ e} \\ g_{yz} = g_{zy} &= \frac{f(x, y+1, z+1) + f(x, y-1, z-1) - f(x, y+1, z-1) - f(x, y-1, z+1)}{4} \end{aligned} \quad (2.20)$$

Em seguida, os autovalores da matriz Hessiana são determinados, sendo $|\lambda_0| \geq |\lambda_1| \geq |\lambda_2|$. Analisando os autovalores obtidos é possível extrair as principais direções em que a estrutura de segunda ordem local podem ser decompostas. Usando esta informação, características de curvatura da estrutura são inspecionadas.

Em uma estrutura plana, como a fissura, é esperada uma grande variação de densidade UH na direção perpendicular ao plano, devido à diferença de densidades entre a fissura e o parênquima pulmonar, além de duas pequenas variações nas direções paralelas ao plano da fissura. Deste modo, os três autovalores contêm informações que podem ser usadas para distinguir os voxels de fissuras dos demais voxels (WIEMKER; BÜLOW; BLAFFERT, 2005; RIKXOORT et al., 2008).

Portanto, costuma-se utilizar uma combinação dos dois maiores autovalores (λ_0 e λ_1) para determinar um coeficiente P que mensura o quão plana é a estrutura. Neste caso, assume-se o valor 1 quando o maior autovalor é significativamente maior do que os outros autovalores e 0 se os dois maiores autovalores são iguais. Para estruturas com alta

intensidade em fundos de baixa intensidade, deve-se considerar apenas os casos em que o maior autovalor é negativo. Assim, (WIEMKER; BÜLOW; BLAFFERT, 2005)

$$P = \begin{cases} \frac{|\lambda_0 - \lambda_1|}{|\lambda_0 + \lambda_1|}, & \text{para } \lambda_0 < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2.21)$$

Por fim, como as fissuras apresentam níveis de densidades UH dentro de um determinado intervalo, P é multiplicado por uma função Gaussiana. Este produto resulta em um coeficiente $S_{fissura}$ que mensura a similaridade da estrutura em questão com uma fissura, dado por (WIEMKER; BÜLOW; BLAFFERT, 2005)

$$S_{fissura} = \exp\left(-\frac{f(x, y, z) - \mu_f^2}{2\sigma_f^2}\right) \times P \quad (2.22)$$

em que μ_f e σ_f são a densidade média para as fissuras e seu desvio padrão, respectivamente.

O termo ponderação definido pela função exponencial, que relaciona a densidade média em Hounsfield das fissuras, é crucial para suprimir outras estruturas planares como, por exemplo, as paredes do pulmão. Uma segmentação prévia do volume do pulmão é utilizada para estabelecer o histograma do parênquima do pulmão. A média de densidade da fissura, bem como o desvio padrão é então definida como certa quantidade acima do parênquima. Estes valores devem ser estimados para cada exame (WIEMKER; BÜLOW; BLAFFERT, 2005).

Lassen et al. (2013) propõem outra abordagem para o cálculo do coeficiente de similaridade de fissura $S_{fissura}$. Inicialmente, são calculados dois descritores, sendo estes

$$F_{estrutura} = \Theta(-\lambda_0) \exp\left[-\left(\frac{\lambda_0 - \alpha}{\beta}\right)^6\right] \quad (2.23)$$

e

$$F_{folha} = \exp\left[-\left(\frac{\lambda_1}{\gamma}\right)^6\right] \quad (2.24)$$

em que $F_{estrutura}$ avalia a força relacionada à estrutura na imagem. Como a densidade das fissuras variam tanto entre pacientes, como também dentro de um único conjunto de dados em regiões distintas, é definido um maior intervalo de densidade com probabilidade alta para fissura. Isso é feito por meio do cálculo da sexta potência que resulta numa curva retangular suavizada.

Os valores de α e β são baseados em análise empírica de um conjunto de exames de TC, sendo $\alpha = 50$ e $\beta = 35$. O termo Θ representa uma função degrau que assume zero para valores de λ_0 positivos (LASSEN et al., 2013).

Já F_{folha} distingue uma estrutura plana e com pouca espessura, semelhante a uma folha, das demais estruturas como nódulos ou vasos, uma vez que estas possuem valores maiores de λ_1 . Assim, como α e β , γ também é empiricamente definida com valor igual a 25 (LASSEN et al., 2013). Com os valores de α , β e γ definidos, são ilustrados os valores de F_{folha} e $F_{estrutura}$ em função dos autovalores λ_1 e λ_0 , respectivamente, na Figura 2.12.

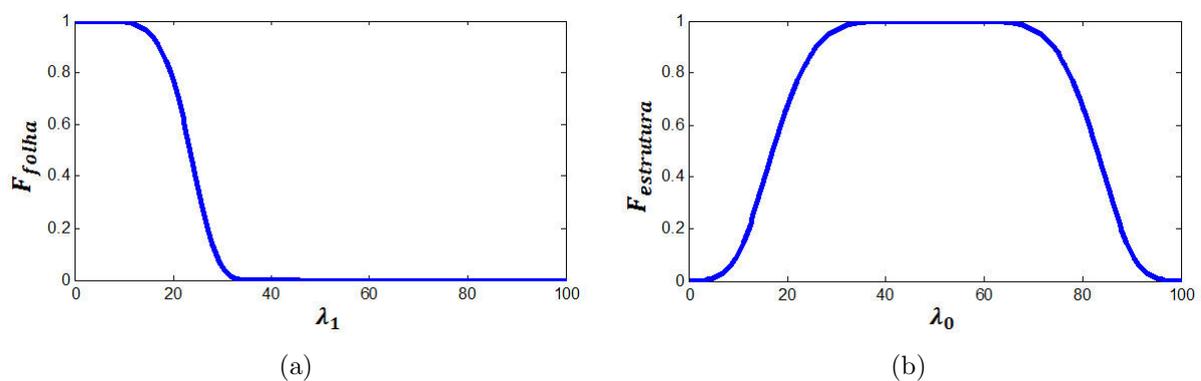


Figura 2.12: distribuição dos descritores de fissuras definidos nas Equações 2.23 e 2.24 com $\alpha = 50$, $\beta = 35$ e $\gamma = 25$, (a) F_{folha} ; e (b) $F_{estrutura}$.

Os valores obtidos de F_{folha} e $F_{estrutura}$ para as imagens de TC da Figura 2.6, são ilustrados na Figura 2.13.

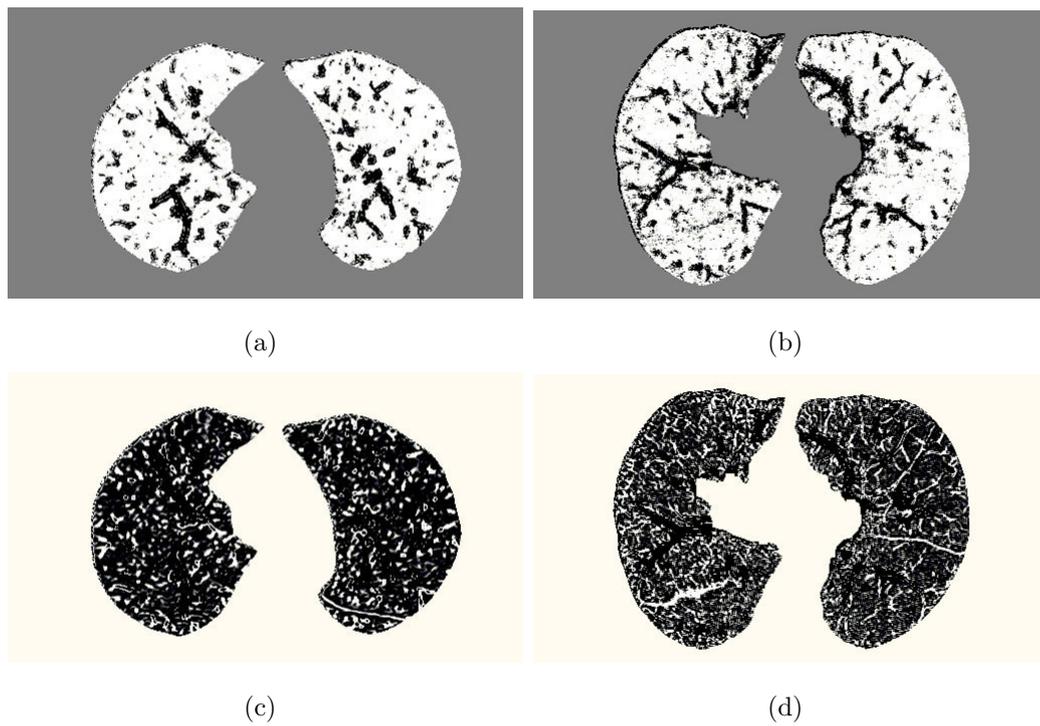


Figura 2.13: ilustração dos descritores de fissuras pulmonares, (a) e (b) descritor F_{folha} ; e (c) e (d) descritor $F_{estrutura}$.

Em seguida, $F_{estrutura}$ e F_{folha} são então combinados para gerar o coeficiente de similaridade de fissura ($S_{fissura}$),

$$S_{fissura} = F_{estrutura} \times F_{folha}, \quad (2.25)$$

que assume valores entre 0 e 1 e funciona basicamente como um filtro de realce para fissura, como pode ser observado na Figura 2.14.

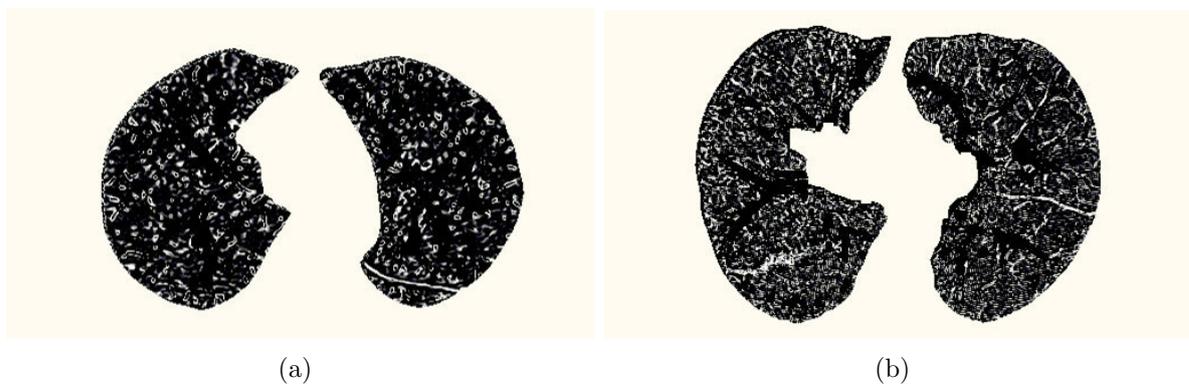


Figura 2.14: exemplos distintos do coeficiente de similaridade de fissura $S_{fissura}$ definido na Equação 2.25.

A partir do realce das fissuras obtidos com $S_{fissura}$, é possível realizar a segmentação

destas para ser utilizada como entrada para a segmentação do lobo. Para isto, alguns trabalhos realizam um pós-processamento para eliminação das demais estruturas presentes, e obtenção apenas das fissuras.

Inicialmente, é construída uma máscara C que contém todos os voxels candidatos à fissura. Os voxels que compõem C devem satisfazer à seguinte regra (RIKXOORT et al., 2010; LASSEN et al., 2013)

$$C = [S_{fissura} > 0, 1] \wedge [f(x, y, z) < (\mu_{vasos} - 2\sigma_{vasos})] \quad (2.26)$$

em que $f(x, y, z)$ é o valor do voxel em UH, μ_{vasos} e σ_{vasos} são a média e desvio padrão da densidade dos vasos sanguíneos, respectivamente. Estes parâmetros devem ser calculados para cada exame, logo uma segmentação preliminar dos vasos sanguíneos é necessária. Esta filtragem objetiva eliminar vasos que eventualmente não são excluídos pelo descritor $F_{estrutura}$. Na Figura 2.15 é ilustrado o resultado desse processamento.

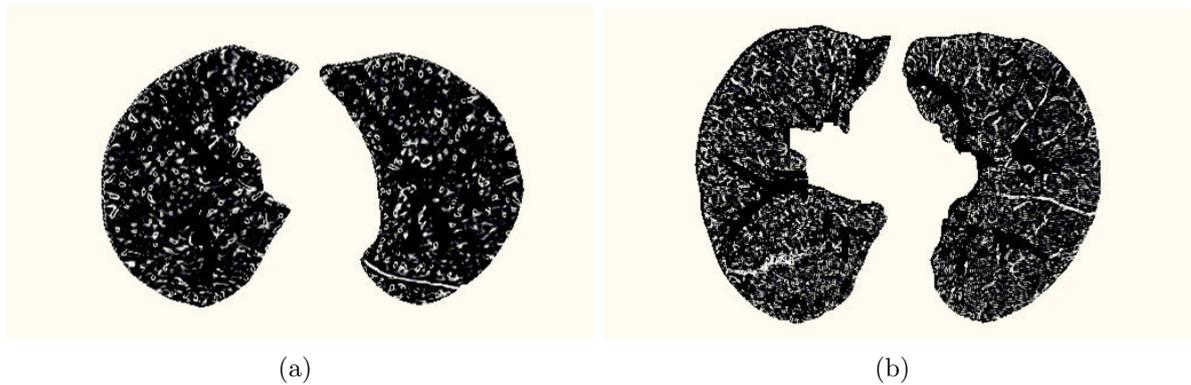


Figura 2.15: ilustração da máscara C definida na Equação 2.26.

Na etapa seguinte do pós-processamento é realizada uma segunda filtragem utilizando análise de componentes conectados baseado nos autovetores da matriz Hessiana. O autovetor, correspondente ao maior autovalor da matriz, armazena a orientação da estrutura em questão. Como a fissura possui baixa curvatura, principalmente quando analisada em pequenos segmentos, os voxels adjacentes ao voxel analisado que também pertencem à fissura devem possuir autovetores semelhantes.

Conforme descrito anteriormente, a análise de componentes conectados agrupa os voxels que apresentarem determinado grau de similaridade, que é calculado pelo produto interno dos autovetores normalizados. Como as fissuras são ligeiramente curvadas, Lassen et al. (2013) determinaram com base em testes empíricos que agrupar voxels adjacentes, cujos produtos internos sejam maiores que 0,8, apresentam resultados satisfatórios.

Após agrupar todos os voxels válidos de C , o volume dos mesmos é verificado e em seguida aqueles agrupamentos que possuem volume menor que 0,1 ml são excluídos de C , Removendo dessa forma o ruído restante e detecções falso positivas. O resultado desta etapa pode ser visualizado na Figura 2.16.

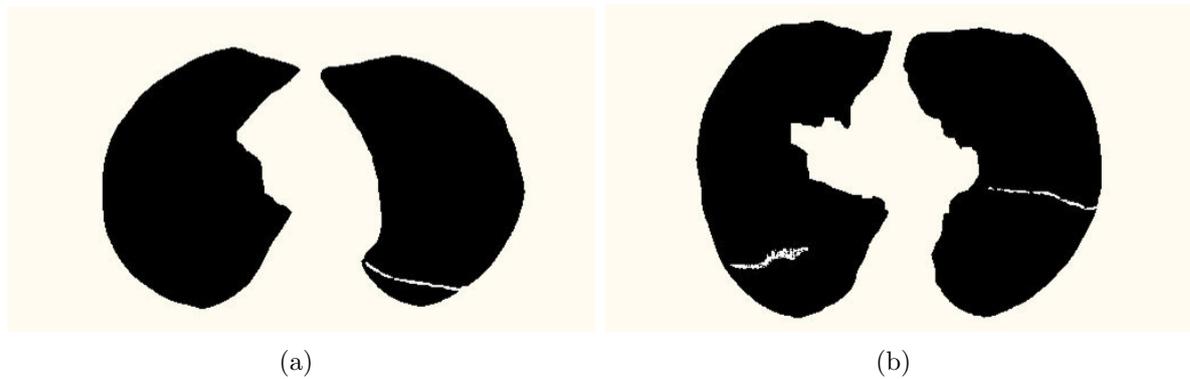


Figura 2.16: exemplos da máscara C após remoção de agrupamentos com volume menor que 0,1 ml.

Por fim, uma operação morfológica de fechamento com elemento estruturante em forma de cubo é aplicada com a finalidade de preencher pequenos espaços entre os agrupamentos, obtendo uma fissura mais contínua, conforme ilustrado na Figura 2.17.

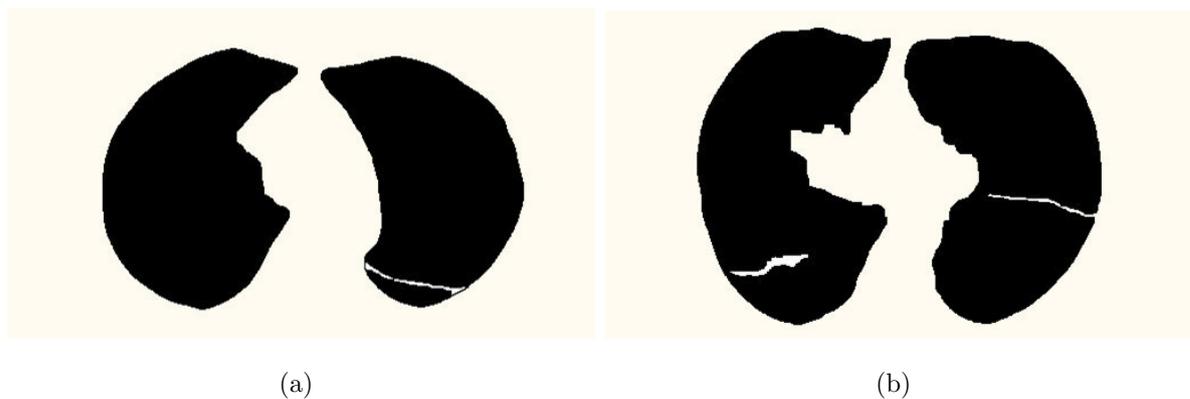


Figura 2.17: segmentação de fissuras pulmonares após aplicação de operação morfológica.

Com base nos conceitos e características apresentados neste capítulo sobre imagens de TC, pulmões e fissuras, além de modelos ativos, textura LBP e matriz Hessiana, são elaborados e propostos processos para realizar a segmentação automática dos lobos pulmonares.

Capítulo 3

Metodologia

Toda a metodologia proposta para realizar a segmentação automática dos lobos em imagens de TC do tórax é descrita neste Capítulo, baseada nas técnicas abordadas no Capítulo 2. As contribuições deste trabalho são destacadas e explicadas em detalhe. Os parâmetros e configurações inerentes à metodologia proposta também são abordados, bem como os procedimentos para avaliação e validação da metodologia em diferentes aspectos.

Nesse contexto, de posse dos exames volumétricos de TC do tórax, para realizar o processo de segmentação dos lobos pulmonares é necessário inicialmente realizar a segmentação da região dos pulmões.

Devido à diferença de alta densidade entre as regiões do pulmão e de outros tecidos presentes em imagens de TC, o espaço aéreo pulmonar costuma ser identificado com facilidade, conforme pode ser percebido na Figura 2.4 nas regiões normalmente aeradas representadas em azul.

As principais dificuldades na segmentação dos pulmões consistem na separação dos pulmões esquerdo e direito e na segmentação das estruturas pulmonares de alta densidade. Enquanto em indivíduos saudáveis os pulmões são geralmente separados por alguns milímetros, os pulmões de pacientes doentes mais enfisematosos, por exemplo, são hiperinsuflados, podendo resultar em contato dos pulmões (KUHNIK, 2008).

Por se tratar de uma etapa anterior à segmentação dos lobos, é utilizado para a segmentação dos pulmões um método baseado no algoritmo de Kuhnigk (2008) que utiliza técnicas simples tais como limiarização, crescimento de região e morfologia matemática.

Por fim, após obter a segmentação dos pulmões em exames de TC, é iniciada a segmentação dos lobos, que nesta tese é realizada pelo MSA proposto e detalhado a seguir. Vale ressaltar, que todo o desenvolvimento dos métodos de segmentação descritos nesta

tese são desenvolvidos em C/C++ com auxílio das bibliotecas DCMTK e OPENCV.

3.1 MSA para Lobos

O MSA proposto nesta tese contempla novas formulações para as energias interna e externa. A energia interna proposta é composta por novas abordagens para a força de continuidade, força de curvatura e força balão. Já para a energia externa são propostas duas novas formulações: uma baseada na textura LBP e outra em autovalores da matriz Hessiana, porém, ambas dedicadas exclusivamente à detecção de fissuras pulmonares e representação dos lobos. Este MSA considera para o cálculo de sua energia as três dimensões e permite que os pontos da superfície possam ser deslocados em qualquer sentido e direção no espaço, o que o define no terceiro grupo da classificação realizada na seção 2.2.1.

Além das contribuições nas formulações das energias interna e externa, é proposto um método para inicialização automática do MSA para cada lobo. Também são propostas funcionalidades que permitem alterar a topologia do MSA, adicionando e removendo pontos de controle durante o processo de evolução, além de critérios de parada por ponto de controle ou por toda superfície que encerram o processo de evolução do MSA.

O processo de segmentação dos lobos pulmonares pelo MSA proposto segue o fluxograma ilustrado na Figura 3.1, em que primeiramente é calculada uma das formulações da energia externa para o MSA. Na sequência são calculados os pontos de inicialização e definidas as superfícies iniciais.

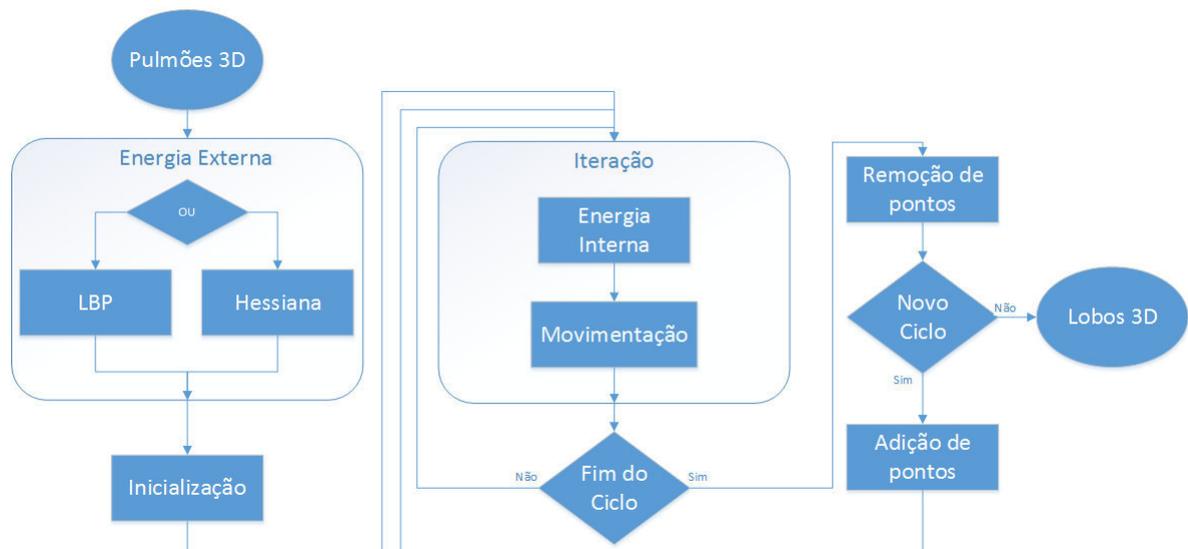


Figura 3.1: fluxograma do processo de segmentação dos lobos pulmonares por MSA.

Em seguida é iniciado o ciclo de evolução, composto por n iterações, para minimização de energia. Em cada iteração é calculada a energia interna para cada ponto de controle. Posteriormente é realizada a movimentação dos pontos adequando à superfície para o formato e posição de menor energia.

Critérios de parada são calculados para determinar o fim do ciclo e a necessidade de um novo ciclo. Caso um novo ciclo se inicie, as funcionalidades de remoção e adição de pontos são executadas. Caso não sejam necessários novos ciclos, a segmentação dos lobos é concluída.

3.1.1 Energia Interna

De acordo com o descrito na Seção 2.2.1, o MSA proposto nesta tese adota um conjunto de pontos representados em 3D, que se ligam de acordo com a regra de formação do tipo de malha adotada. Além disso, as energias sofrem influência do formato da superfície, considerando informações nas três dimensões, além de movimentar os pontos em qualquer direção do espaço 3D.

Tais características permitem a utilização de malhas não estruturadas, que conforme visto na Seção 2.2.1.1, surgiram com o intuito de representar geometrias complexas, possuindo maior flexibilidade, melhor adaptação a superfícies irregulares e possibilitando adicionar ou excluir nós, enquanto a conectividade da malha é atualizada localmente, a fim de melhorar a precisão da solução.

Todavia, uma das maiores dificuldades para a utilização de malhas não estruturadas em MSA consiste na formulação da energia interna, pois por permitir que cada nó da malha possua qualquer quantidade de nós vizinhos em qualquer plano e direção, torna-se complexa uma abordagem genérica e discreta que permita calcular, para todos os pontos de controle, a energia interna composta pelas primeiras e segundas derivadas parciais, conforme Equação 2.4.

Nesse contexto, abordagens genéricas para as forças de continuidade e de curvatura são propostas a seguir.

3.1.1.1 Força de Continuidade

Tradicionalmente, a força de continuidade, também conhecida como força elástica, define a capacidade de um ponto da curva se distanciar ou se aproximar dos pontos vizinhos, atuando no contorno para torná-lo uniformemente espaçado.

Com o intuito de manter o mesmo comportamento, todavia substituindo a formulação tradicional por uma que permita considerar qualquer quantidade de pontos em um universo discreto e tridimensional, define-se (BOTSCH et al., 2010)

$$v_i(s, r) = [x_i(s, r), y_i(s, r), z_i(s, r)], \quad (3.1)$$

em que $v_i(s, r)$ é o i -ésimo vizinho do ponto $v(s, r)$, doravante denominados v_i e v respectivamente. Dessa forma, tem-se a distância euclidiana d_i entre o ponto de controle v e seu i -ésimo vizinho v_i . Logo, é possível definir a distância média d_μ , média entre o ponto de controle v e seus vizinhos, como a média das distâncias d_i obtidas.

Por fim, a força de continuidade 3D para cada ponto de controle do MSA é dada por

$$F_{cont}(v) = \frac{1}{N} \sum_{i=1}^N (d_i - d_\mu)^2. \quad (3.2)$$

Percebe-se que a força de continuidade para um ponto de controle do MSA é definida como a variância das distâncias entre o ponto de controle e seus vizinhos. Quanto maior esta variância, maior a força de continuidade que deve ser minimizada durante o processo de evolução do MSA. Assim, independentemente da quantidade de vizinhos que o ponto de controle possua, a força de continuidade definida deve atuar uniformemente, sempre atraindo o ponto de controle em questão para uma posição em que a distância entre seus vizinhos seja a mais uniforme possível, tornando os pontos de controle do MSA uniformemente espaçados, conforme o objetivo da força de continuidade.

É ilustrado um exemplo da atuação da força de continuidade na Figura 3.2, em que o ponto vermelho na Figura 3.2(a), ligado a oito pontos, é submetido à atuação da força de continuidade, definida na equação 3.2, que o atrai para a localização representada na Figura 3.2(b).

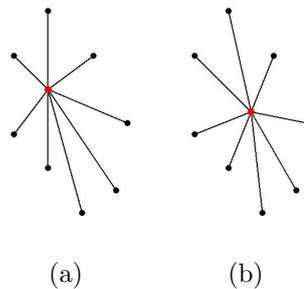


Figura 3.2: exemplo da atuação da força de continuidade, (a) disposição antes da atuação da força de continuidade; e (b) disposição depois da atuação da força de continuidade.

3.1.1.2 Força de Curvatura

Curvatura é definida como a quantidade que um objeto geométrico se desvia do plano (ANTON; BIVENS; DAVIS, 2005). Neste sentido, observa-se que a força de curvatura é responsável pela suavização da superfície. Tradicionalmente se baseia nos ângulos internos e tende a deixar a superfície contínua e suave, em detrimento de trechos irregulares e pontiagudos.

Todavia, com a utilização de malhas não estruturadas que permitem qualquer quantidade de vizinhos em qualquer plano do espaço para cada ponto de controle, é proposta uma formulação que se adapte a tais condições e atue de maneira uniforme em todos os pontos.

Mantendo o mesmo comportamento da força de curvatura, é possível substituir a formulação tradicional por uma que permita em um universo discreto e 3D considerar qualquer quantidade de pontos. Desta forma, define-se

$$v_{\mu}(s, r) = [x_{\mu}(s, r), y_{\mu}(s, r), z_{\mu}(s, r)], \quad (3.3)$$

em que $v_{\mu}(s, r)$ é o ponto médio, doravante denominado v_{μ} , calculado pela média das coordenadas dos vizinhos do ponto v .

Por fim, a força de curvatura 3D para cada ponto de controle do MSA é definida como a distância entre o ponto de controle v e o ponto médio v_{μ} , calculada por

$$F_{curv}(v) = \sqrt{(x - x_{\mu})^2 + (y - y_{\mu})^2 + (z - z_{\mu})^2} \quad (3.4)$$

O ponto médio v_{μ} atua como uma projeção de v no plano médio determinado pelos vizinhos de v . Dessa forma, ao se calcular a distância entre v e v_{μ} , está-se medindo indiretamente a curvatura do ponto v em relação aos seus vizinhos.

É ilustrado um exemplo da atuação da força de continuidade por algumas iterações, na Figura 3.3, em que o ponto vermelho, ligado a outros quatro pontos, é submetido à atuação da força de curvatura, definida na Equação 3.4.

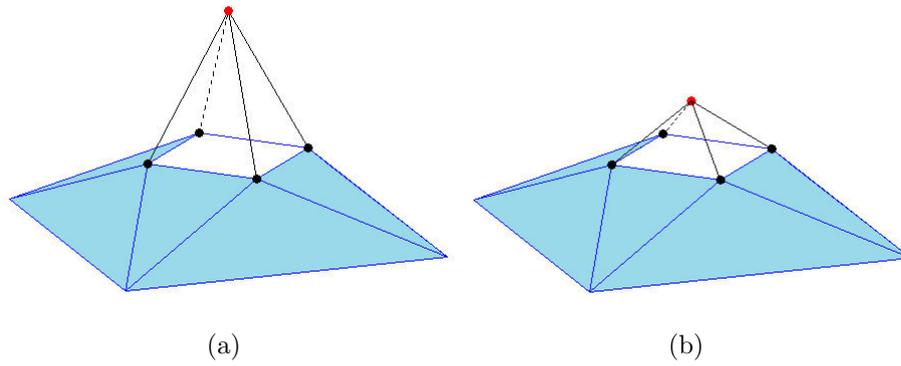


Figura 3.3: exemplo da atuação da força de curvatura, (a) disposição antes da atuação da força de curvatura; e (b) disposição depois da atuação da força de curvatura.

Uma outra aplicação para esta força de curvatura é como força balão para volumes convexos. Logo, tem-se

$$F_{bal}(v) = 1 - F_{curv}(v). \quad (3.5)$$

Desta forma, o ponto de controle v em vez de atraído pelo ponto médio v_μ , realiza movimento contrário, expandindo a superfície. Todavia, a constante 1 presente na equação 3.5, determina a condição para expansão a superfície. Caso a posição do ponto de controle esteja bastante discrepante do posicionamento de seus vizinhos, a curvatura deste ponto assume valores maiores que a constante, fazendo com que a força balão passe a agir de forma semelhante à força de curvatura. Assim, pontos com a curvatura muito alta, em vez de serem expandidos, são retraídos, beneficiando a suavidade da superfície.

Frisa-se porém que para superfícies com concavidades, uma vez que o ponto médio v_μ em regiões côncavas se encontra na região externa à superfície, a força balão definida tende a expandir a concavidade para dentro da superfície. Neste sentido, caso o intuito seja somente a expansão da superfície, recomenda-se o uso desta força balão em superfícies convexas. Caso a superfície possa apresentar alguma concavidade, recomenda-se a utilização da funcionalidade de remoção de pontos para verificar se todos os pontos apresentam comportamento adequado.

3.1.2 Energia Externa

Conforme abordado na seção A.1, a energia externa é a responsável por trazer, ao modelo ativo, informações provenientes da imagem. Tais informações devem ser representadas em um mapa, de tal forma que a região de interesse, onde se deseja que o modelo

ativo convirja, deve possuir energia mínima em detrimento das demais.

Nesse contexto, a presente tese propõe duas novas formulações de energia externa para segmentação de lobos pulmonares através de MSA. Ambas as formulações pretendem atribuir menor energia à superfície dos lobos, que consistem nas bordas dos pulmões e fissuras pulmonares. Por se tratarem de formulações independentes e com o mesmo objetivo, apenas uma formulação por vez deve ser atribuída ao MSA.

3.1.2.1 Energia LBP

A energia externa LBP, dedicada à segmentação dos lobos pulmonares, é baseada na classificação de texturas, utilizando para isso as técnicas descritas na Seção 2.3 e Apêndice B, conforme ilustrado no fluxograma da Figura 3.4.

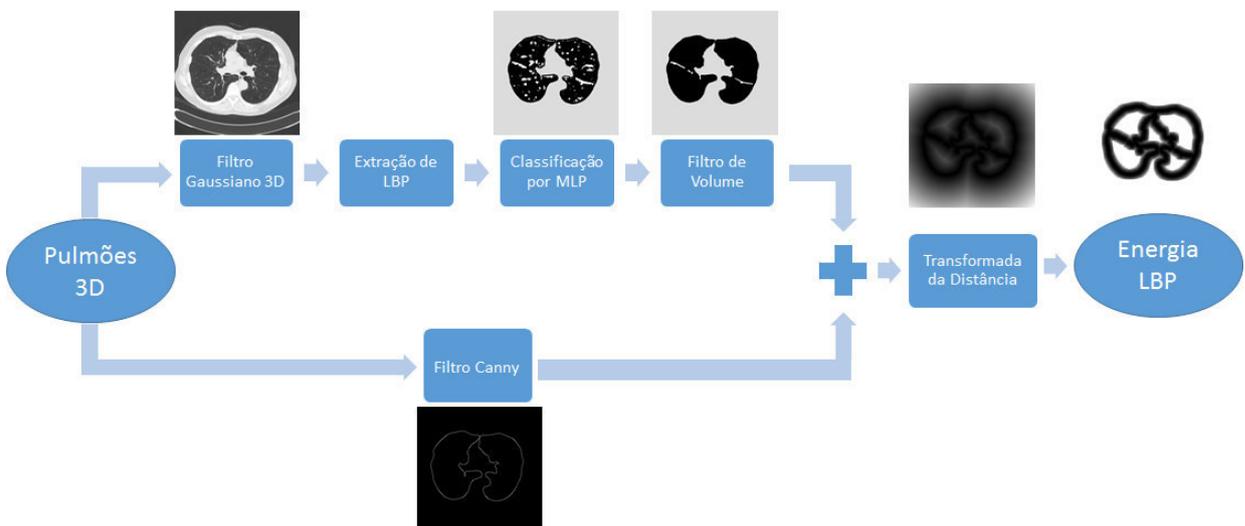


Figura 3.4: processo para obtenção da energia externa LBP para MSA aplicado à segmentação dos lobos pulmonares.

Inicialmente é aplicado no exame de TC um filtro gaussiano 3D com $\mu = 1 \text{ mm}$ e máscara de $3 \times 3 \times 3$, para diminuir artefatos de alta frequência que por ventura possam ter alguma característica de textura semelhante às fissuras.

Em seguida para cada voxel interno aos pulmões é estabelecida uma vizinhança e calculada a distribuição local de padrões binários uniformes $LBP_{P,R}^{u2}$, em que $u2$ significa que são considerados padrões uniformes com até duas transições entre bits, conforme equação 2.15. Nesta tese, a vizinhança adotada, bem como os parâmetros P e R , são definidos baseado em Cavalcanti Neto (2014), que utiliza abordagem semelhante para realizar segmentação das fissuras pulmonares. Logo, a vizinhança adotada possui dimensões 15×15 e para P e R são atribuídos os valores 8 e 2, respectivamente.

Segundo Rikxoort et al. (2008), a classificação de fissuras pulmonares em imagens de TC pode ser realizada através de rede MLP. Conceitos sobre redes neurais e rede MLP são abordados no apêndice B. Logo, para a classificação das distribuições de LBP obtidas é utilizada uma rede MLP. A rede utilizada possui camada de saída com dois neurônios para indicar se o voxel representa parte de uma fissura ou se pertence a qualquer outra estrutura pulmonar.

Nesse sentido, para que a rede MLP realize a classificação de cada voxel, um vetor com a distribuição LBP relativa à vizinhança do voxel é submetido à entrada da rede. Por se tratar de uma distribuição $LBP_{8,2}^u$, o vetor de entrada é composto pelos 58 padrões considerados uniformes, conforme definido na equação 2.17.

A determinação da quantidade de neurônios na camada oculta é uma tarefa complexa em que geralmente faz-se uso de heurísticas (MURATA; YOSHIZAWA; AMARI, 1994). Assim é utilizada quantidade de neurônios na camada oculta igual a duas vezes o número de dados de entrada. Logo, a rede MLP utilizada possui 116 neurônios na camada oculta. A função de ativação utilizada na camada oculta é a função sigmoide logística devido à compatibilidade da saída e os valores dos dados normalizados. Desta forma, a topologia utilizada é 58/116/2, ou seja, 58 entradas, 116 neurônios na camada oculta e 2 neurônios na camada de saída.

Uma vez definida a topologia da rede MLP, antes de utilizá-la na etapa de classificação, é preciso que a mesma seja submetida a uma etapa de treinamento. Para o treinamento da rede é utilizado o algoritmo de retropropagação do erro, descrito no apêndice B. Quanto aos pesos iniciais, são gerados números aleatórios entre -1,5 e +1,5. No treinamento da rede é utilizada uma taxa de aprendizagem decrescente com valor inicial de 0,5.

O critério de parada do treinamento é definido ou pela estagnação da rede, caracterizada após 10 épocas do treinamento sem apresentar diminuição do erro quadrático médio, ou pelo aumento do valor do erro quadrático médio em relação à época anterior. Para evitar que sejam adotados os pesos de um treinamento que tenha finalizado em um mínimo local, são realizados vários treinamentos com pontos de início diferentes. Para o treinamento da rede é utilizado o banco de dados disponibilizado no trabalho de Cavalcanti Neto (2014).

Em relação à eficácia da rede MLP adotada, ressalta-se que por se tratar de apenas uma etapa do processo de obtenção da energia externa, falhas na classificação não chegam a comprometer o mapa de energia. O resultado esperado para esta etapa são regiões que se aproximem das fissuras, sem haver a necessidade de uma segmentação perfeita das mesmas. É ilustrado o resultado da classificação dos voxels, de acordo com a distribuição

LBP, realizada pela rede MLP descrita na Figura 3.5.

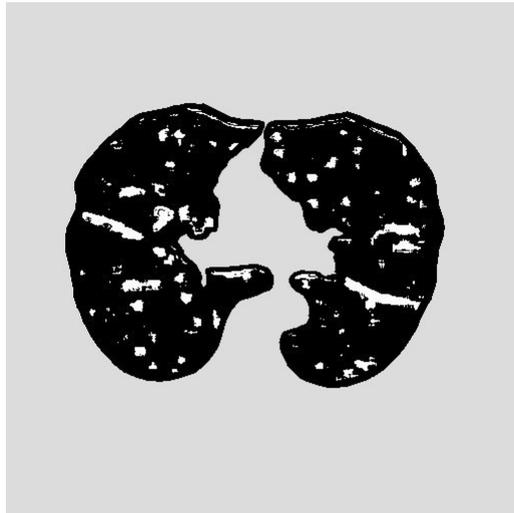


Figura 3.5: exemplo de resultado da classificação dos voxels pela rede MLP. Regiões em branco são classificadas como fissuras, demais estruturas são representadas em preto.

A etapa seguinte ao processo de classificação consiste em um pós-processamento deste resultado, no qual são filtrados pequenos volumes que correspondem a classificações falso positivas da rede MLP. Para tal, é realizada uma análise de componentes conectados, em que todos os voxels conectados e classificados como fissura são agrupados em volumes distintos. Em seguida, os volumes menores que 0,1 ml são descartados. O valor de 0,1 ml foi obtido do empiricamente, após um levantamento realizado em vários exames por Lassen et al. (2013). É ilustrado um exemplo do resultado obtido após o filtro de volume descrito na Figura 3.6.

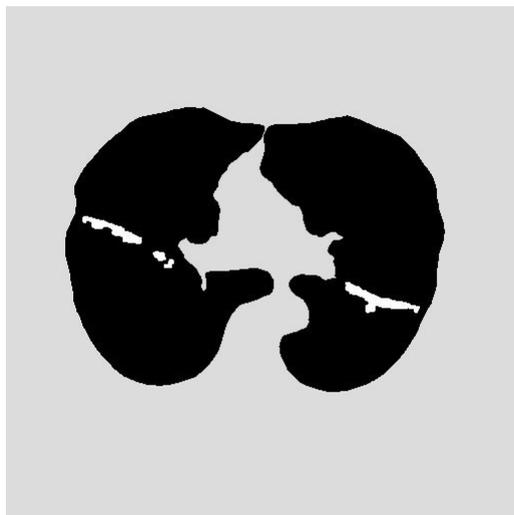


Figura 3.6: resultado do filtro de volume para a classificação da rede MLP, regiões classificadas como fissuras em branco e demais estruturas em preto.

Como a energia externa em questão possui o objetivo de representar à superfície dos

lobos, que consistem nas bordas dos pulmões e fissuras pulmonares, deve-se adicionar ao resultado obtido às bordas dos pulmões segmentados. Para isso um filtro detector de bordas deve ser aplicado à imagem binária da região dos pulmões, possibilitando que o resultado do mesmo seja somado ao resultado do filtro de volume. Nesta tese é adotado o filtro de Canny (CANNY, 1986), porém como o mesmo é aplicado em uma imagem binária, outros filtros detectores de bordas podem ser utilizados. Ao fim desta etapa, obtém-se uma representação da superfície dos lobos pulmonares. É ilustrado o resultado deste processo na Figura 3.7. Os voxels representados em branco são considerados voxels válidos para compor a energia externa.

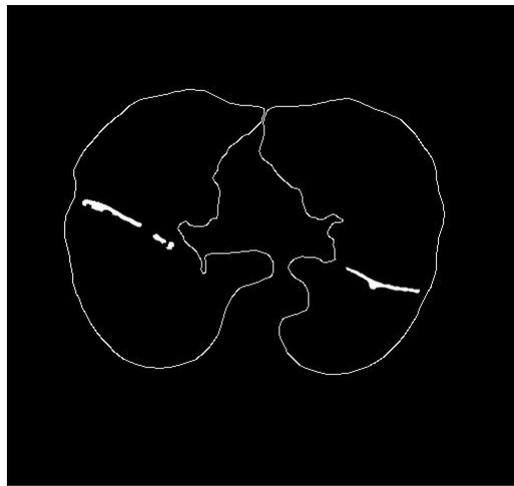


Figura 3.7: resultado da soma da detecção de fissura e detector de bordas do pulmão.

Por fim, para de se obter uma maior área de atuação da energia externa, é aplicada uma transformada da distância 3D, em que se considera a distância euclidiana de um voxel qualquer para o voxel válido mais próximo. Na Figura 3.8 é ilustrado o resultado deste processo que resulta na energia externa LBP proposta nesta tese.

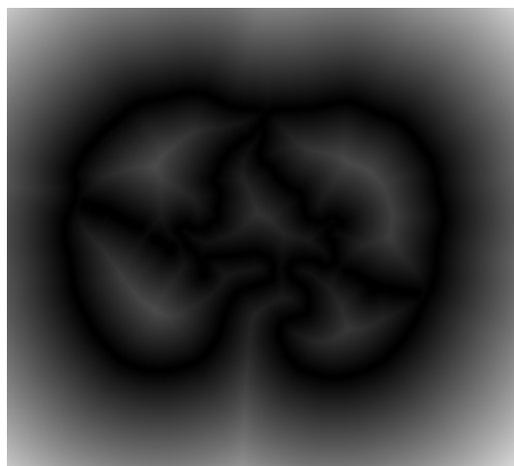


Figura 3.8: resultado da transformada da distância.

A imagem ilustrada na Figura 3.8 é uma representação de uma seção bidimensional do mapa da energia externa aplicada ao MSA proposto. Verifica-se que, quanto mais próximo da superfície dos lobos pulmonares, menor é a energia, sendo conseqüentemente mais escuro o nível de intensidade do mapa.

Para obter uma maior eficiência, uma vez que não há necessidade de expandir a área de atuação da energia externa para todo o espaço 3D, pois a energia interna do MSA deve atuar guiando-o para a região de interesse, é possível otimizar o processo de obtenção da energia externa LBP, limitando o raio de atuação da transformada da distância. Por esta razão, não são calculadas informações desnecessárias, obtendo maior eficiência no cálculo desta energia.

Nesse sentido, pode-se limitar o raio de atuação da transformada da distância a 50 voxels por exemplo. Assim, apenas os voxels que estiverem dentro do raio de atuação, considerando um voxel válido, devem possuir valores diferentes do máximo. É ilustrado um exemplo da energia externa LBP com o raio de atuação da transformada da distância limitado à 50 voxels na Figura 3.9.

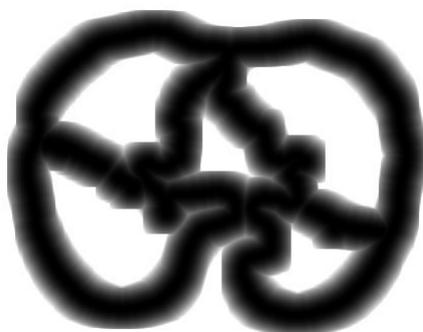


Figura 3.9: energia externa LBP em um *slice* 2D.

3.1.2.2 Energia Hessiana

A energia Hessiana é uma energia externa para MSA dedicada à segmentação 3D dos lobos pulmonares em imagens de TC. Assim como a energia LBP, esta energia tem como finalidade prover ao MSA informações sobre a localização da superfície dos lobos no espaço 3D.

A diferença entre a energia Hessiana e a energia LBP consiste basicamente na forma de se obter a representação das fissuras. Para a energia Hessiana, a representação das

fissuras é obtida pela técnica de segmentação descrita na Seção 2.4. Um fluxograma do processo para obtenção da energia externa Hessiana é ilustrado na Figura 3.10.

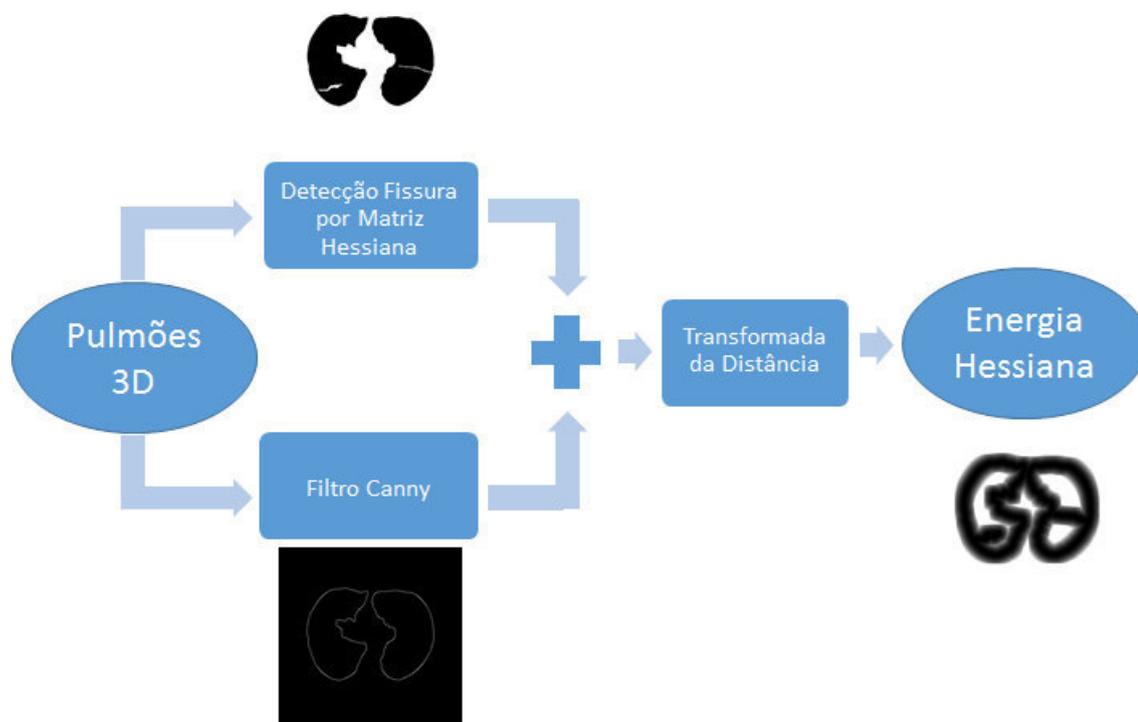


Figura 3.10: processo para obtenção da energia externa Hessiana para MSA aplicado à segmentação dos lobos pulmonares.

De posse do resultado da segmentação das fissuras, semelhante à energia LBP, um filtro detector de bordas é aplicado à imagem binária da região dos pulmões. Para esta energia também é adotado o filtro de Canny (CANNY, 1986), assim como outros filtros detectores de bordas também podem ser utilizados, por se tratar de uma imagem binária.

O resultado desta etapa é a representação da superfície dos lobos pulmonares, que por fim é submetida à transformada da distância 3D para se obter uma maior área de atuação da energia externa. Na Figura 3.11(a) é ilustrada a soma do resultado do filtro de Canny aplicado aos pulmões com o resultado da detecção da fissura por matriz Hessiana. Na Figura 3.11(b) é ilustrado a aplicação da transformada da distância limitada a 50 voxels.

O resultado deste processo consiste na energia externa Hessiana proposta. Observando a Figura 3.11(b), percebe-se que para as regiões distantes das superfícies dos lobos a energia é máxima, representada em branco, para as demais regiões, quanto mais próxima desta superfície menor a energia, e mais escuro é o tom utilizado para representá-la.

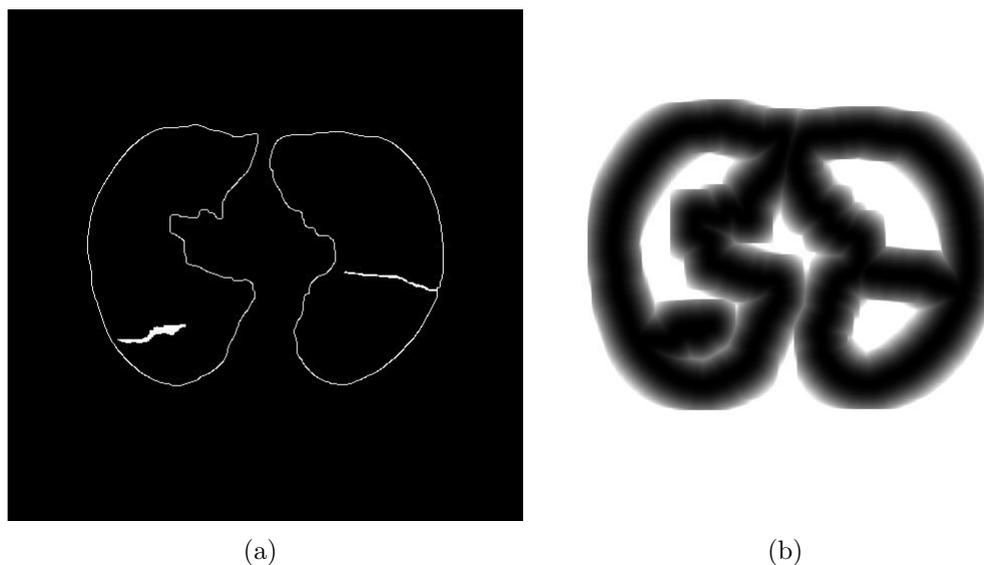


Figura 3.11: energia Hessiana, (a) soma do resultado do filtro de canny aplicado aos pulmões com o resultado da detecção da fissura por matriz Hessiana; e (b) aplicação da transformada da distância em (a), limitada a 50 voxels.

3.1.3 Inicialização Automática

Uma desvantagem dos Modelos Ativos tradicionais consiste na dependência da inicialização do contorno ou superfície. Geralmente esta inicialização é realizada por intervenção manual pelo usuário, tornando desta forma os métodos dependentes dos operadores, ocasionando impactos significativos no resultado, aumentando o tempo de processamento e gerando eventuais imprecisões (FELIX et al., 2012).

Nas últimas décadas, diversos métodos de inicialização automática foram propostos em diversos tipos de imagem, como por exemplo imagens de face humana (DELMAS; COULON; FRISTOT, 1999; ZHOU; GENG, 2003), imagens de ressonância magnética do coração (PLUEMPITIWIRIYAWAJ; SOTTHIVIRAT, 2005; LIANG; DING; WU, 2008), imagens de ultrassom do coração (TAUBER; BATATIA; AYACHE, 2005), imagens de TC abdominais (SHEN; KASSIM, 2007) e inclusive imagens de TC do tórax (REBOUÇAS FILHO, 2013a; FELIX et al., 2012). Todavia, as inicializações propostas para imagens de TC do tórax visam exclusivamente a inicialização de Modelos Ativos para os pulmões.

Para tornar o processo de segmentação dos lobos pulmonares automático e independente do usuário, é proposto nesta tese um método de inicialização automática para MSA aplicado na segmentação de lobos em imagens de TC.

O método proposto tem como objetivo identificar um ponto interno a cada um dos lobos, totalizando cinco pontos, e em seguida estimar uma superfície para o MSA, possibilitando o início do processo iterativo para minimização da energia.

Para atingir tal objetivo, o método de inicialização se baseia em funções de projeções híbridas (FENG; YUEN, 1998; ZHOU; GENG, 2003). Estas funções permitem a identificação do centro de massa de objetos presentes na imagem, obtendo desta forma, pontos de referência que podem ser utilizados para a inicialização automática de Modelos Ativos, principalmente quando se tem mais de um objeto de interesse na imagem em estudo (FELIX et al., 2012).

Uma imagem 2D geralmente é representada por duas funções de projeção ortogonais 1D. A redução de dimensão de 2D para 1D também reduz a carga computacional. Devido a esta vantagem, o método de projeção tem sido adotado com sucesso na extração de características em diversas aplicações.

Sendo $I(x, y)$ a intensidade de um pixel na posição (x, y) , a função de projeção integral vertical $FPI_V(x)$ e a função de projeção integral horizontal $FPI_H(y)$ podem ser dadas por (ZHOU; GENG, 2003)

$$FPI_V(x) = \int_{y_1}^{y_2} I(x, y) dy \quad (3.6)$$

e

$$FPI_H(y) = \int_{x_1}^{x_2} I(x, y) dx, \quad (3.7)$$

em que y_1 e y_2 , bem como x_1 e x_2 , delimitam o intervalo considerado para as funções de projeção vertical e horizontal, respectivamente. Para o espaço abordado em 3D é possível definir três funções de projeção integral para um espaço tridimensional, em que $I(x, y, z)$ é a intensidade de um voxel na posição (x, y, z) , dada por

$$FPI_z(x, y) = \int_{z_1}^{z_2} I(x, y, z) dz, \quad (3.8)$$

$$FPI_y(x, z) = \int_{y_1}^{y_2} I(x, y, z) dy, \quad (3.9)$$

e

$$FPI_x(y, z) = \int_{x_1}^{x_2} I(x, y, z) dx, \quad (3.10)$$

em que os pares x_1 e x_2 , y_1 e y_2 , e z_1 e z_2 delimitam o intervalo considerado para as funções de projeção FPI_x , FPI_y e FPI_z , respectivamente.

Nesse contexto, para se obter automaticamente as cinco coordenadas internas a cada um dos lobos, as funções de projeção são aplicadas ao espaço 3D do exame de TC. Entretanto, em vez de se considerar os valores de densidade UH, são considerados os valores provenientes do mapa de energia externa descrito na Seção 3.1.2. Exemplos das funções de projeção descritas nas Equações 3.8, 3.9 e 3.10, aplicadas no mapa de energia externa Hessiana, são ilustrados na Figura 3.12.

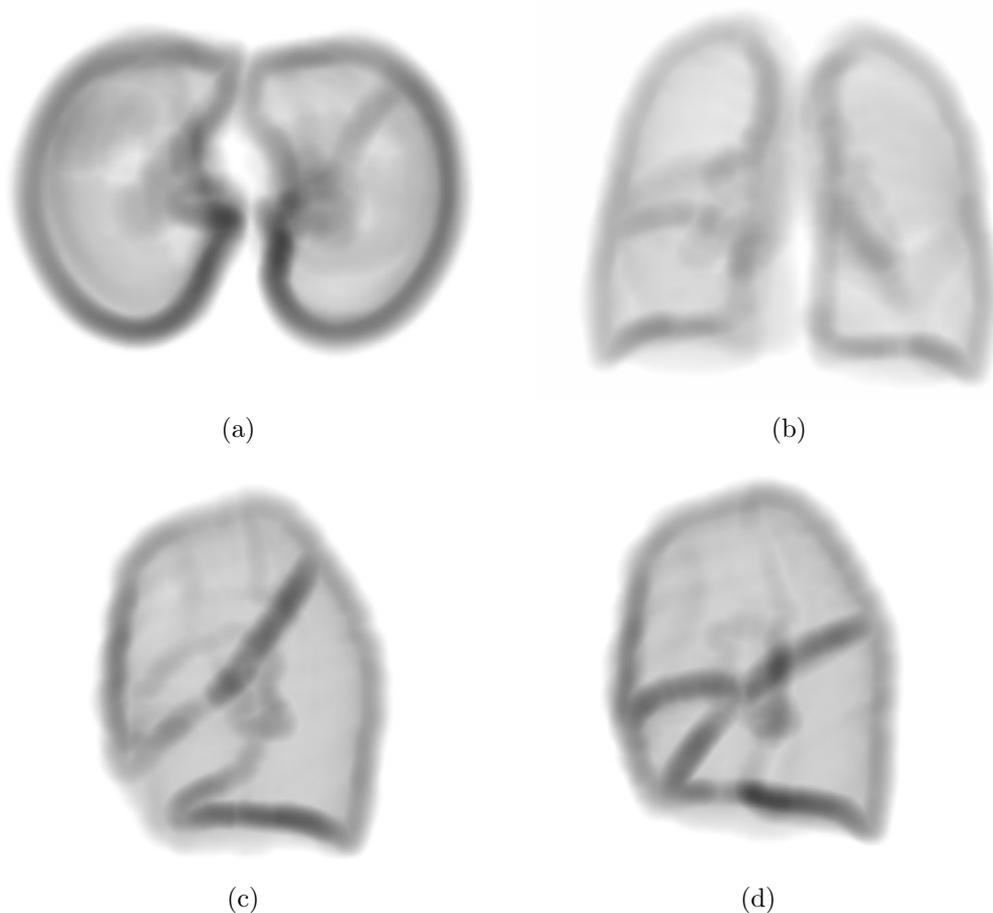


Figura 3.12: funções de projeção de um mapa de energia externa para lobos, (a) $FPI_z(x, y)$; (b) $FPI_y(x, z)$; (c) $FPI_x(y, z)$ para o pulmão esquerdo; e (d) $FPI_x(y, z)$ para o pulmão direito.

Baseado nas funções de projeções 2D e 1D, é proposto um método para determinar de forma automática uma coordenada (x, y, z) para cada um dos cinco lobos pulmonares.

Inicialmente, baseado em $FPI_y(x, z)$ define-se a coordenada z . Para isto, os pulmões devem ser considerados de forma individual, dado que as projeções de um não devem influenciar nas projeções do outro. Assim, depois de obtida a $FPI_y(x, z)$ para cada um

dos pulmões, é calculada para as mesmas a projeção 1D, definida na equação 3.7. Na Figura 3.13 é ilustrado o resultado deste processo, em que o gráfico à esquerda de cada Figura representa a projeção $FPI_H(y)$ das mesmas.

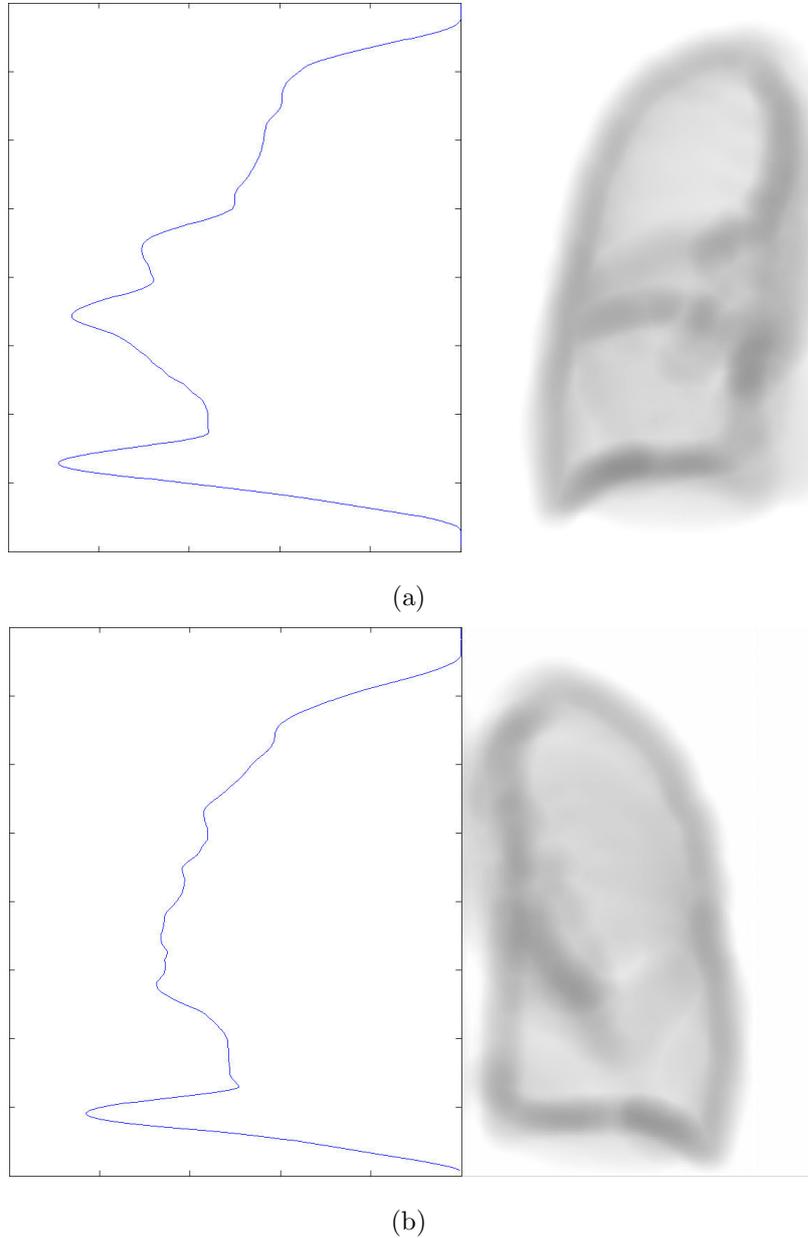


Figura 3.13: $FPI_H(y)$ a partir de $FPI_y(x, z)$, (a) pulmão direito; e (b) pulmão esquerdo.

Para estabelecer a coordenada z para os três lobos do pulmão direito, é estimada a derivada da projeção $FPI_H(y)$ por diferenças finitas obtendo-se

$$FPI'_H(y) = \frac{d(FPI_H(y))}{dy} \approx \frac{FPI_H(y) - FPI_H(y - \Delta)}{\Delta} \quad (3.11)$$

São ilustradas $FPI'_H(y)$ com $\Delta = 1$, para o pulmão direito, na Figura 3.14.

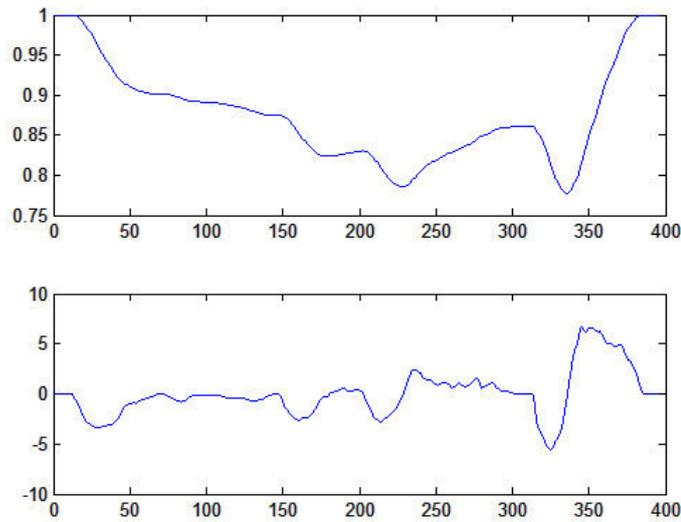


Figura 3.14: $FPI_H(y)$ acima e $FPI'_H(y)$ abaixo para o pulmão direito com $\Delta = 1$.

Em seguida, são detectados os quatro maiores vales que representam as regiões em que se inicia e se encerra o pulmão, bem como as duas regiões que apresentam maior concentração de fissuras. Os índices dos menores valores de cada um dos quatro vales são representados em ordem crescente como z_{d1} , z_{d2} , z_{d3} e z_{d4} . Na Figura 3.15 é ilustrada a projeção $FPI_y(x, z)$, para o pulmão direito, com destaque nas linhas que correspondem aos vales de $FPI'_H(y)$.

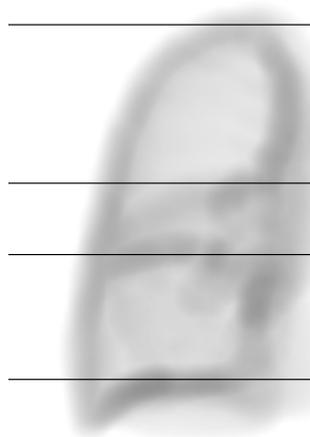


Figura 3.15: $FPI_y(x, z)$ para o pulmão direito marcada nos vales de $FPI'_H(y)$.

De posse de coordenadas iniciais dentro do pulmão direito, é possível definir a coordenada z dos pontos internos a cada um dos lobos direitos, dadas por

$$l_{sd_z} = \frac{z_{d1} + z_{d2}}{2}, \tag{3.12}$$

$$lmd_z = \frac{z_{d2} + z_{d4}}{2}, \quad (3.13)$$

e

$$lid_z = \frac{z_{d3} + z_{d4}}{2}, \quad (3.14)$$

em que lsd_z , lmd_z e lid_z representam a coordenada z do lobo superior direito, do lobo médio direito e do lobo inferior direito, respectivamente.

Um método análogo é adotado para estabelecer a coordenada z dos dois lobos do pulmão esquerdo. Inicialmente é calculada a $FPI'_H(y)$ baseada na $FPI_y(x, z)$ extraída do mapa de energia externa do pulmão esquerdo. É ilustrado $FPI'_H(y)$ para o pulmão esquerdo na Figura 3.16.

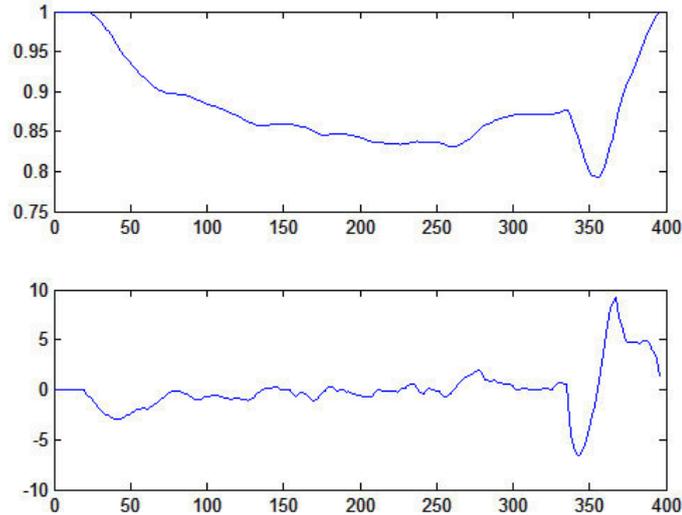


Figura 3.16: $FPI'_H(y)$ acima e $FPI'_H(y)$ abaixo para o pulmão esquerdo com $\Delta = 1$.

Em seguida, são detectados o primeiro e o último vale de $FPI'_H(y)$, que correspondem ao início e fim do pulmão. Na sequência também é detectado o maior pico entre os dois vales correspondendo à região de maior concentração de fissuras. Os índices dos menores valores dos dois vales, bem como o índice de maior valor do pico detectado são representados em ordem crescente por z_{e1} , z_{e2} e z_{e3} . É ilustrada a projeção $FPI_y(x, z)$ do pulmão esquerdo com destaque nas linhas que correspondem aos vales e ao pico detectados em $FPI'_H(y)$ na Figura 3.17.

Por fim, assim como no pulmão direito, é possível definir a coordenada z dos pontos internos a cada um dos lobos esquerdos, por $lse_z = \frac{z_{e1} + z_{e2}}{2}$ e $lie_z = \frac{z_{e2} + z_{e3}}{2}$

Após estabelecidas as cinco coordenadas no eixo z , para cada um dos lobos, é realizado o processamento para determinação das coordenadas no eixo x e no eixo y .



Figura 3.17: $FPI_y(x, z)$ para o pulmão esquerdo marcada nos pontos z_{e1} , z_{e2} e z_{e3} .

Logo, é selecionada uma imagem 2D da energia externa relativa à coordenada z estabelecida para cada lobo e as projeções 1D definidas nas equações 3.6 e 3.7 são calculadas para cada imagem selecionada. São ilustradas as imagens da energia externa selecionadas para cada um dos lobos, bem como as projeções horizontal e vertical das mesmas na Figura 3.18.

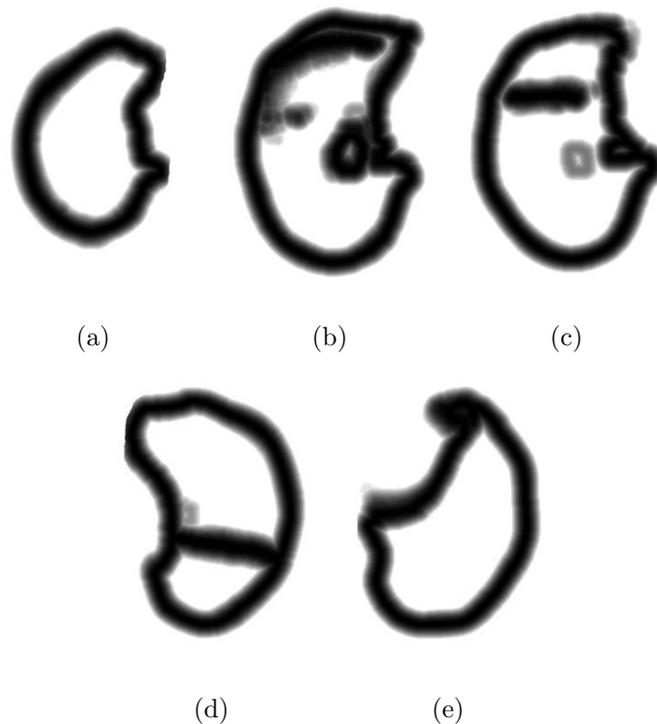


Figura 3.18: imagem 2D da energia externa Hessiana considerada para os lobos (a) superior direito; (b) médio direito; (c) inferior direito; (d) superior esquerdo; e (e) inferior esquerdo.

Para a imagem relativa ao lobo superior direito, são detectados os dois maiores vales de $FPI_H(y)$, tendo os índices dos mesmos representados em ordem crescente por y_{sd1} e

y_{sd2} . Assim, define-se a coordenada lsd_y , relativa ao eixo y para o lobo superior direito $lsd_y = \frac{y_{sd1} + y_{sd2}}{2}$.

Para a imagem relativa ao lobo médio direito, são detectados os quatro maiores vales de $FPI_H(y)$, tendo seus índices representados em ordem crescente por y_{md1} , y_{md2} , y_{md3} e y_{md4} , tornando possível definir a coordenada lmd_y , relativa ao eixo y para o lobo médio direito $lmd_y = \frac{y_{md1} + y_{md2}}{2}$.

Apenas os índices y_{md1} e y_{md2} são considerados para a coordenada y do lobo direito médio, pois estes se referem ao início do pulmão e a região da fissura oblíqua, englobando o lobo em questão.

Por fim, ainda em relação ao pulmão direito, para determinar a coordenada lid_y , relativa ao eixo y para o lobo inferior direito, são detectados os quatro maiores vales de $FPI_H(y)$. Os índices dos menores valores de cada um dos quatro vales são representados em ordem crescente por y_{id1} , y_{id2} , y_{id3} e y_{id4} . Assim, define-se a coordenada lid_y , relativa ao eixo y para o lobo inferior direito $lid_y = \frac{y_{id2} + y_{id4}}{2}$.

Somente os índices y_{id2} e y_{id4} são considerados para a coordenada lid_y , pois estes se referem à região da fissura oblíqua e ao fim do pulmão, que delimitam o lobo inferior direito.

Para os lobos do pulmão esquerdo, tanto para o lobo superior como para o lobo inferior, os três maiores vales das funções $FPI_H(y)$ são detectados. Para o lobo superior esquerdo, os índices dos vales são representados por y_{se1} , y_{se2} e y_{se3} , enquanto para o lobo inferior esquerdo os índices são representados por y_{ie1} , y_{ie2} e y_{ie3} . Em seguida, são calculadas as coordenadas lse_y e lie_y , relativas ao eixo y para os lobos superior esquerdo e inferior esquerdo $lse_y = \frac{y_{se1} + y_{se2}}{2}$ e $lie_y = \frac{y_{ie2} + y_{ie3}}{2}$, respectivamente.

Por fim, para completar as coordenadas para os lobos, resta apenas definir a coordenada do eixo x , que por sua vez, possui método semelhante para os cinco lobos. Considerando a projeção $FPI_V(x)$ de cada lobo, basta detectar o primeiro e último vale da projeção, tendo seus índices representados por x_{sd1} e x_{sd2} , x_{md1} e x_{md2} , x_{id1} e x_{id2} para os lobos, superior, médio e inferior direito, respectivamente. Assim x_{se1} e x_{se2} , e x_{ie1} e x_{ie2} para os lobos superior e inferior esquerdo, respectivamente. Desta forma as coordenadas para o eixo x são definidas por $lsd_x = \frac{x_{sd1} + x_{sd2}}{2}$, $lmd_x = \frac{x_{md1} + x_{md2}}{2}$, $lid_x = \frac{x_{id1} + x_{id2}}{2}$, $lse_x = \frac{x_{se1} + x_{se2}}{2}$ e $lie_x = \frac{x_{ie1} + x_{ie2}}{2}$.

Na Figura 3.19 são ilustradas, nas imagens de TC correspondentes as coordenadas lsd_z , lmd_z , lid_z , lse_z e lie_z , os cinco pontos de coordenadas (lsd_x, lsd_y) , (lmd_x, lmd_y) , (lid_x, lid_y) , (lse_x, lse_y) e (lie_x, lie_y) , calculados para a inicialização automática.



Figura 3.19: pontos calculados para inicialização automática dos MSAs para os lobos (a) superior direito; (b) médio direito; (c) inferior direito; (d) superior esquerdo; e (e) inferior esquerdo.

Finalmente, para concluir a inicialização automática, deve-se estabelecer uma superfície inicial para cada MSA. Nesta tese, é utilizada como superfície inicial, para cada MSA, uma esfera com raio de 10 voxels e centrada nas coordenadas calculadas automaticamente para cada lobo. O formato esférico é escolhido por possuir superfície uniforme, enquanto o valor de apenas 10 voxels é definido com o intuito de que nenhum trecho da superfície fique fora do pulmão. É ilustrada a inicialização automática de cada um dos MSAs na Figura 3.20.

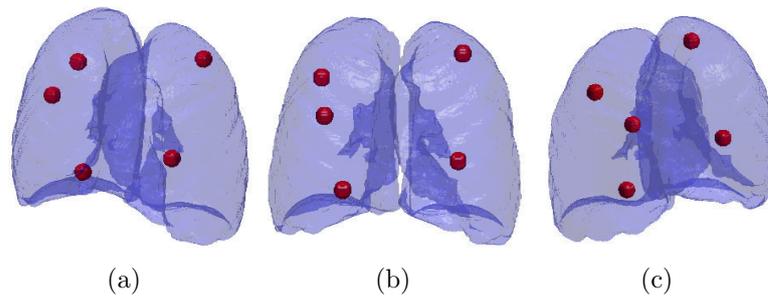


Figura 3.20: visualização 3D da inicialização do MSA para cada um dos lobos pulmonares em diferentes pontos de vista.

3.1.4 Dinâmica e Iteração

Como descrito anteriormente, é nesta etapa que os pontos são reorganizados, posicionando-se de tal forma que a energia total da superfície seja minimizada. Uma vez que a energia externa é calculada e a superfície inicial é estabelecida, inicia-se o processo de evolução do MSA.

Uma região de busca em torno de cada ponto é estabelecida. Em seguida, o ponto é projetado em cada coordenada dessa região e a energia desta projeção é calculada, considerando a energia externa na coordenada em questão e a energia interna em relação aos vizinhos deste ponto. Este processo deve se repetir até que a superfície atinja uma forma que possua uma energia mínima, estabilizando assim o ciclo de evolução.

A fim de atribuir maior versatilidade ao modelo ativo, costuma-se utilizar algumas funções que interferem diretamente nesse processo de evolução. Geralmente, estas funções adicionam ou removem pontos, como também podem definir critérios de parada em vários níveis do processo de evolução (ALEXANDRIA et al., 2011; REBOUÇAS FILHO, 2013a).

Para os MCAs, as funções de remoção e adição de pontos costumam ser executadas após cada iteração. Todavia, para MSAs, por possuírem uma quantidade extremamente maior de informação e pontos para processamento, além de ser necessário em alguns casos

recalcular a malha utilizada, recomenda-se iterar o modelo até a sua superfície convergir, finalizando o ciclo, para só então executar as funções de adição e remoção de pontos e reiniciar o ciclo de evolução.

Vale ressaltar que as funções de adição e remoção descritas a seguir se aplicam somente às malhas não estruturadas, pois em malhas estruturadas não é permitido a adição ou remoção de pontos individuais. Para alterar a quantidade de pontos em malhas estruturadas, deve-se alterar sua resolução inicial, adicionando ou removendo uma fila completa de pontos ao longo de algum dos planos.

3.1.4.1 Remoção de pontos

A remoção de pontos é uma importante função que pode atuar eliminando pontos redundantes da superfície e pontos que tenham se fixado há um mínimo local como algum ruído no mapa de energia externa por exemplo. Basicamente, os pontos são removidos em duas situações.

A primeira situação determina a remoção de pontos que ocupam o mesmo lugar no espaço, ou seja, caso um conjunto de pontos tenha convergido para uma mesma coordenada (x, y, z) , apenas um destes deve permanecer.

A segunda situação prevista para remoção de pontos consiste em um limite máximo de curvatura que se baseia em um limiar configurável da força de curvatura. Caso algum ponto possua força de curvatura que ultrapasse o limiar especificado, este deve ser removido. Tal situação trata de cantos pontiagudos, como no caso de um ponto que possa ficar preso em algum mínimo local de energia durante a evolução, ou não tenham passado por nenhuma região com energia externa, ou até mesmo alguma região côncava quando utilizada a força balão definida na equação 3.5.

3.1.4.2 Adição de pontos

A adição de pontos em tempo de execução proporciona duas grandes vantagens. A primeira consiste em refinar a superfície em determinadas regiões, seja porque o objeto em questão possui uma maior complexidade geométrica nesta região, ou até mesmo por causa de uma concentração de pontos em alguma região em detrimento de outras. Tal refinamento permite maior precisão e exatidão na segmentação dos objetos.

A segunda vantagem diz respeito ao desempenho. Neste caso, se é possível adicionar pontos a qualquer momento, pode-se iniciar a superfície do MSA com uma quantidade de pontos reduzida. Assim, nas primeiras iterações a quantidade de informação a ser

processada é bem menor, tornando o processo mais rápido computacionalmente.

Para realizar a adição de pontos na superfície em questão, deve-se estabelecer um limiar configurável para representar a maior distância permitida entre os pontos existentes. Desta forma, define-se a resolução da superfície a ser obtida no final do processo de evolução.

A função de adição, cada vez que é executada, verifica a distância de cada ponto com seus vizinhos e adiciona um novo ponto quando esta distância é maior do que o limiar definido.

3.1.4.3 Critérios de parada

O MSA proposto nesta tese possui três tipos de critério de parada. O primeiro diz respeito à movimentação de um ponto individualmente, o segundo trata de finalizar o ciclo de evolução do MSA e o terceiro determina o fim do processo ou início de um novo ciclo.

Critério de parada de ponto - Este critério desempenha um importante papel otimizando o desempenho do MSA, pois tem como objetivo identificar os pontos que já atingiram seu posicionamento de menor energia e em seguida os estacionar. Ou seja, os pontos identificados deixam de participar do processo de iteração.

Tal procedimento economiza bastante processamento, pois para cada ponto removido, a energia deste ponto e de todas as projeções possíveis contidas na região de busca deixam de ser calculadas. Vale ressaltar que mesmo que tenha sido removido do processo iterativo, o ponto ainda deve ser submetido aos critérios de remoção de pontos, pois o mesmo pode estar em um mínimo local ou região ruidosa.

Enfim, para estacionar um ponto, podem ser considerados dois critérios. O primeiro verifica a quantidade de iterações em que o ponto não foi movido, ou seja, por quantas iterações a energia da coordenada em que o ponto se encontra foi menor do que as energias das projeções da área de busca. Caso o número de iterações atinja um limite inicialmente fixado, este ponto é estacionado.

O segundo critério observa apenas a energia externa. Caso a energia externa da coordenada deste ponto seja mínima, o ponto é estacionado. Este critério é bastante eficiente, pois à medida que os pontos atingem a região de interesse, geralmente a borda do objeto, estes devem ser estacionados e a superfície converge rapidamente. Todavia, estes pontos podem não se espalhar sobre todo o objeto, resultando em uma segmentação de baixa qualidade. Logo, não é recomendado a utilização deste segundo critério, caso não seja utilizada a função da adição de pontos ou caso a quantidade de pontos seja reduzida.

Critério de fim de ciclo - Em relação ao critério de parada que trata de finalizar o ciclo de evolução do MSA, é possível adotar duas regras que atuam conjuntamente seguindo a função lógica "ou". Para a primeira regra, o usuário deve estabelecer um limite máximo de iterações. Quando a quantidade de iterações chegar a esse limite o processo é finalizado.

Já para a segunda regra, é definido também pelo usuário um percentual que deve representar um número mínimo de pontos de controle estacionados. Quando a quantidade de pontos estacionados atingir tal percentual, o processo iterativo também é finalizado.

Critério de fim de processo - Este critério determina a necessidade de processamento de um novo ciclo ou o encerramento do processo de segmentação. Para tal, basicamente duas medidas são adotadas como critério. A primeira e mais simples determina o número máximo de ciclos, evitando desta forma o prolongamento de uma segmentação que não esteja convergindo.

Já, a segunda medida mensura a resolução e precisão da segmentação obtida. Para isto, uma média entre a distância de cada ponto de controle e seu vizinho é calculada. Caso esta média seja menor que a distância média desejada como resolução, o processo é finalizado, não havendo processamento de novos ciclos de evolução.

3.2 Avaliação dos Métodos

Nesta seção são descritos os testes realizados para a avaliação da metodologia proposta sob diferentes aspectos. Basicamente, os testes objetivam avaliar a influência do tipo de malha utilizada com a atuação das forças internas propostas, a inicialização automática do MSA para os lobos pulmonares e a qualidade da segmentação dos lobos obtida pelo MSA proposto. Estes testes usam imagens sintéticas e imagens de TC do tórax.

3.2.1 Testes em Imagens sintéticas

A influência do tipo de malha utilizada com a atuação das forças internas não depende diretamente da energia externa, conseqüentemente não dependem de propriedades específicas da imagem. Entretanto, a forma do objeto a ser segmentado é de extrema importância, influenciando diretamente a atuação do MSA de acordo com a malha e energia interna utilizada.

Nesse sentido, a fim de se obter uma maior diversidade de formas para avaliar como o MSA se comporta e sob quais circunstâncias e características os tipos de malha e a energia

interna apresentam melhor desempenho, os testes realizados utilizam imagens sintéticas volumétricas em formatos de cilindro, cone, cubo, pirâmide e esfera. Desta forma, é possível observar as vantagens e limitações das técnicas utilizadas na segmentação dessas imagens.

3.2.2 Testes em exames de TC

Para avaliar a inicialização automática do MSA e a qualidade da segmentação dos lobos pulmonares, são necessários exames de TC volumétricos. Logo, para estas avaliações são utilizadas imagens proveniente de exames de TC obtidos do banco *Lung Image Database Consortium image collection* LIDC-IDRI (ARMATO et al., 2011).

O LIDC-IDRI consiste em um grande arquivo de imagens médicas de câncer disponível para acesso público. Este banco possui 1012 exames de TC de tórax com diagnóstico de câncer de pulmão e marcação nas lesões presentes. É um banco bastante utilizado para desenvolvimento, treinamento e avaliação de métodos de diagnóstico assistidos por computador para detecção e diagnóstico de câncer de pulmão.

3.2.2.1 Padrão Ouro

A validação de acurácia e precisão de um algoritmo computacional é uma etapa extremamente importante e nem sempre trivial, principalmente quando o algoritmo é aplicado na área médica. Neste contexto, o desafio para realização desta etapa revela-se na identificação de um padrão ouro, ou seja, de um parâmetro de referência (ZAIDI; NAQA, 2010; CAVALCANTE et al., 2013).

No caso de validação de algoritmos de imagens médicas, alguns autores chegam a um padrão ouro através da expertise de médicos especialistas. Para validar seu método Devaki, MuraliBhaskaran e Mohan (2013) medem a distância entre o contorno da segmentação obtida e o contorno marcado em 5 exames de TC por um médico. Enquanto Doel et al. (2012) realizam o mesmo procedimento em 10 exames de TC. Pu et al. (2009) também mensuram a distância entre o contorno segmentado e o contorno marcado por médicos, porém realizam uma amostragem nos exames, fazendo a comparação em 10 *slices* provenientes de 10 exames de TC. Wei et al. (2006) realizam procedimento semelhante para uma amostragem de 30 *slices* por exame, em um total de 6 exames de TC. Rebouças Filho (2013a) e Félix (2011), para validação de seus métodos, utilizam medidas de ajuste de forma com uma amostragem de 12 *slices* por exame em um universo de 3 exames de TC.

Nesta tese, para obtenção do padrão ouro, são selecionados aleatoriamente do banco LIDC-IDRI 10 exames com 1,25 mm de espessura de corte. A definição deste valor de espessura de corte justifica-se pelo fato de minimizar o efeito de volume parcial nas fissuras, uma vez que em exames de TC com cortes mais espessos a representação das fissuras sofre com este efeito, possuindo apenas pequenos trechos durante todo o exame, conforme abordado na seção 2.1.1.

O padrão ouro em questão é obtido pelo processo de segmentação tradicional que consiste no delineamento manual dos lobos nas imagens do exame de TC. Para otimizar este processo, possibilitando que o padrão ouro englobe exames distintos, é realizada uma amostragem em cada exame selecionando algumas imagens 2D para serem submetidas à junta médica e terem seu padrão ouro elaborado. A junta médica em questão foi composta por cinco profissionais da área de saúde sendo estes: radiologista, pneumologista, fisioterapeuta e técnico em radiologia. O delineamento manual era realizado por um profissional e confirmado ou corrigido pelos demais atingindo um censo comum.

Com o intuito de obter um resultado o mais próximo possível do real, minimizando desvios que possam acontecer em uma amostragem simples, a amostragem de *slices* realizada no padrão ouro considera *slices* nos 3 planos de cortes, sendo estes: axial, coronal e sagital, ilustrados na Figura 2.1. Desta forma, a segmentação dos lobos pode ser avaliada em praticamente todas as regiões do pulmão, pois estão presentes na amostragem dados distribuídos por toda sua altura, largura e profundidade.

Com base nisto, para compor o padrão ouro utilizado nesta tese são selecionados em cada exame: 3 *slices* no plano axial, contendo os pulmões direito e esquerdo, distribuídos pela altura dos pulmões; 3 *slices* no plano coronal, contendo os pulmões direito e esquerdo, distribuídos pela profundidade dos pulmões; 3 *slices* no plano sagital, contendo o pulmão esquerdo, distribuídos pela largura deste pulmão; e mais 3 *slices* no plano sagital, contendo o pulmão direito, distribuídos pela largura do mesmo, totalizando 12 *slices* por exame. Os *slices* são selecionados, pela junta médica especialista, com o intuito de representar todo o pulmão e a divisão entre os lobos. Logo, são selecionados *slices* espaçados ao longo do pulmão que obtenham fissuras, ou seja mais de um lobo por pulmão.

Por fim, para cada um dos *slices* selecionados, o contorno de cada lobo presente é demarcado manualmente por um médico especialista e submetido à equipe médica para aprovação.

É ilustrado o conjunto de imagens que compõem o padrão ouro de um dos exames utilizados, nos eixos axial, coronal e sagital, respectivamente, seguidas pelo padrão realizado para cada uma dessas imagens, nas Figuras 3.21, 3.22 e 3.23. Em vermelho é representado

o lobo superior direito, em azul o lobo médio direito, em verde o lobo inferior direito, em magenta é representado o lobo superior esquerdo e em ciano o lobo inferior esquerdo.

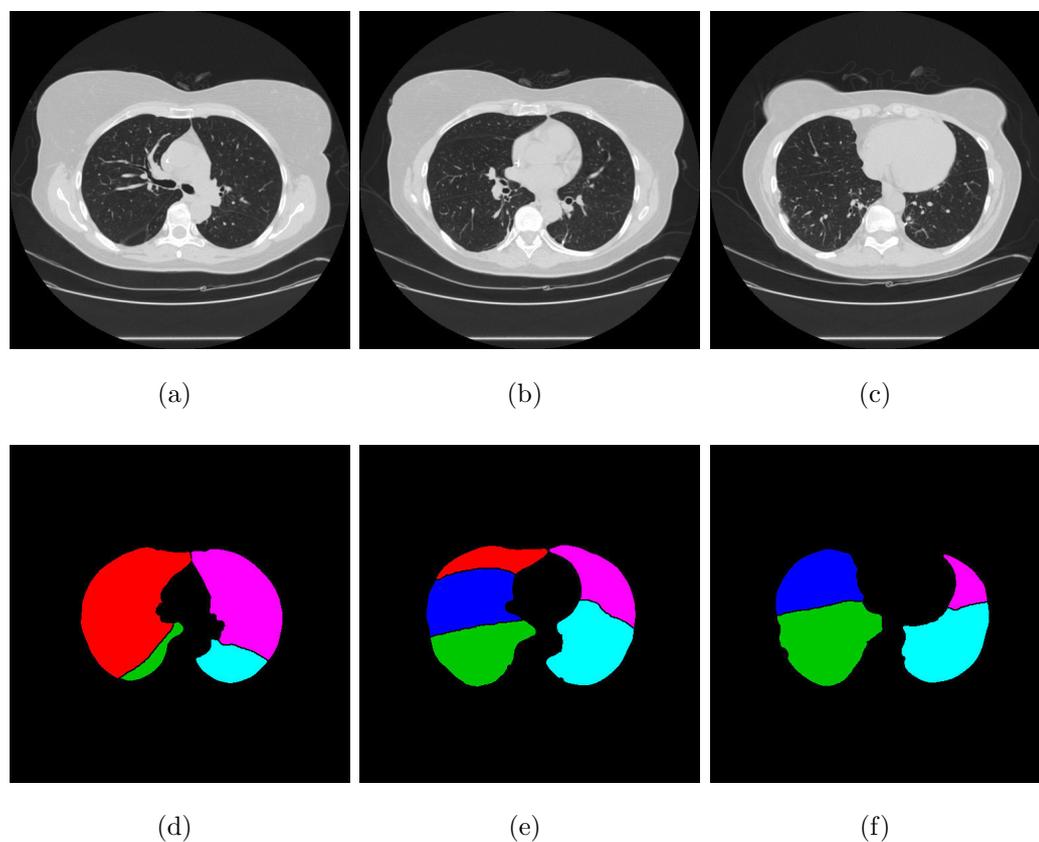


Figura 3.21: imagens no eixo axial que compõem o padrão ouro (a), (b) e (c) imagens originais e (d), (e) e (f) marcação do padrão ouro.

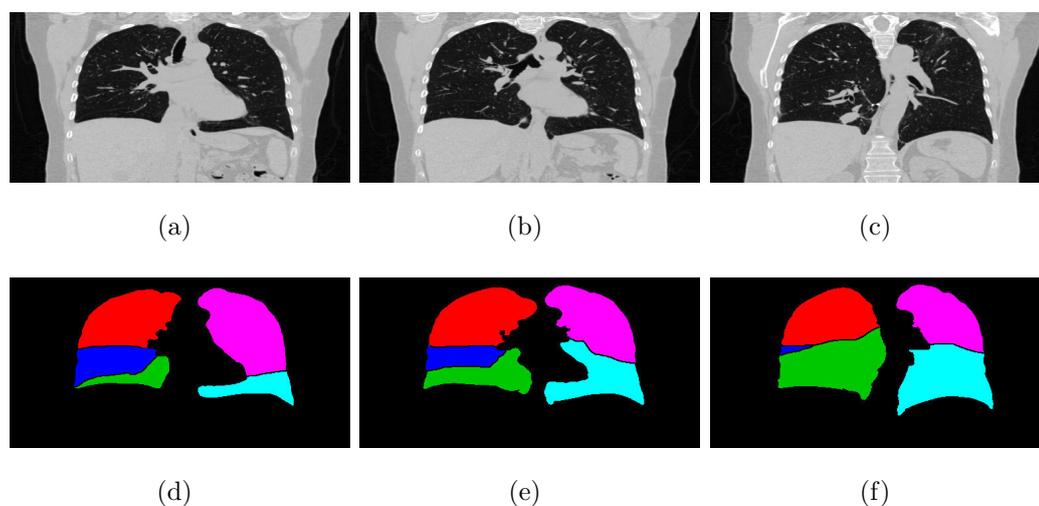


Figura 3.22: imagens no eixo coronal que compõem o padrão ouro (a), (b) e (c) imagens originais e (d), (e) e (f) marcação do padrão ouro.

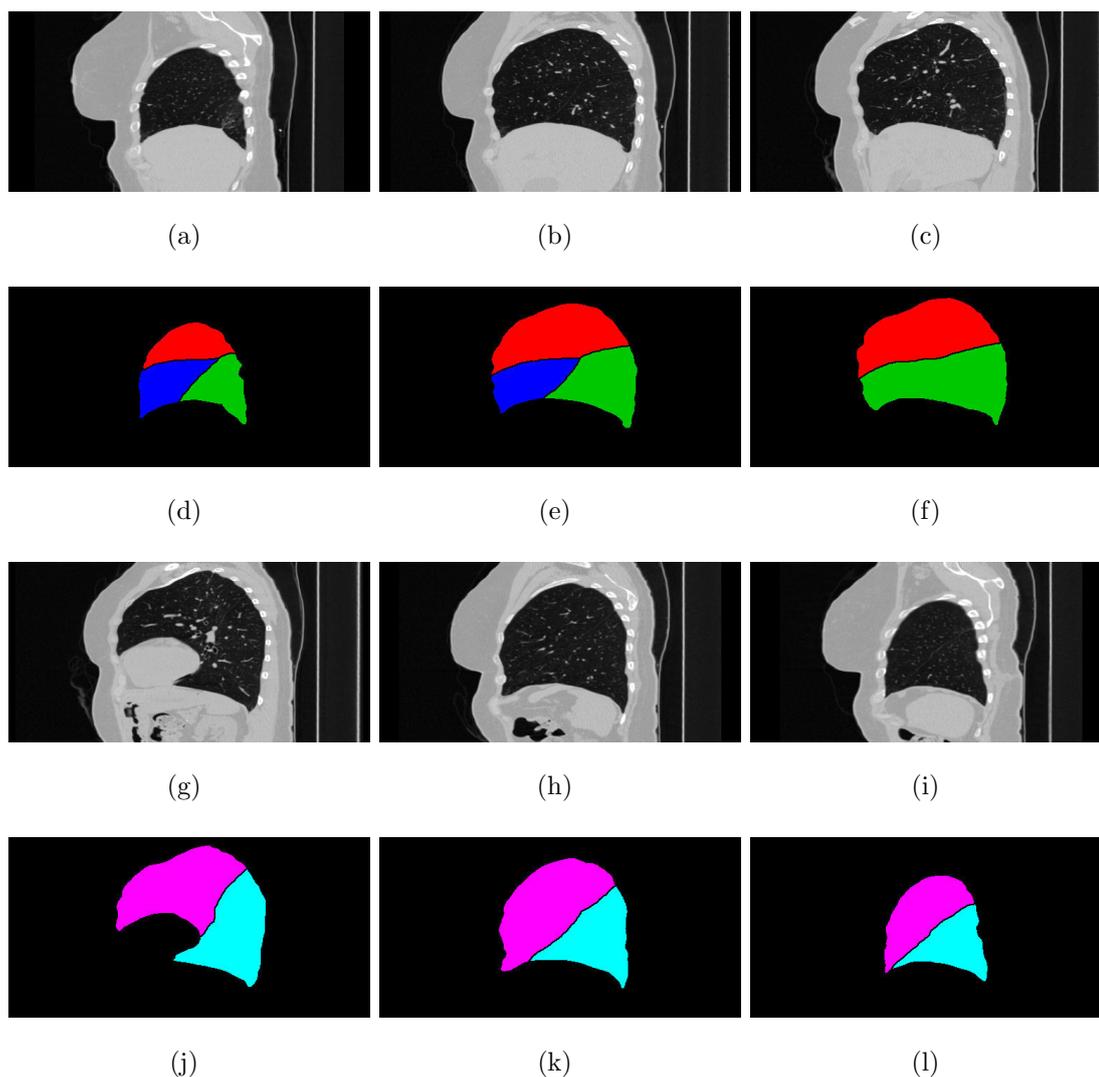


Figura 3.23: imagens no eixo sagital que compõem o padrão ouro (a), (b), (c), (g), (h) e (i) imagens originais e (d), (e), (f), (j), (k) e (l) marcação do padrão ouro.

3.2.2.2 Avaliação da Inicialização Automática

De posse dos exames de TC, a validação da inicialização dos MSAs é realizada. Para isto o algoritmo descrito na Seção 3.1.3 é executado para cada exame. Por fim, é determinado por inspeção visual se a superfície inicial dos MSAs determinada para cada lobo pulmonar se encontra no interior do referido lobo. Caso a superfície inicial esteja totalmente no interior do lobo, a inicialização é tida como certa, caso contrário a inicialização é classificada como errada.

Com base nisto, é possível quantificar as inicializações automáticas corretas calculando a taxa de acerto, sendo esta a razão entre a quantidade de inicializações corretas e o total de inicializações.

3.2.2.3 Avaliação da Segmentação dos lobos pulmonares

Para a avaliação da segmentação dos lobos pulmonares, cada exame de TC é submetido ao processo de segmentação descrito na Seção 3.1.

Por esta razão, para efeito de avaliação, a partir da segmentação volumétrica obtida são extraídas as segmentações dos *slices* correspondentes aos mesmos selecionados para compor o padrão ouro. Estas segmentações são comparadas de acordo com as métricas descritas na Seção 3.2.3, gerando medidas de avaliação por exame e por tipo de lobo.

3.2.3 Métricas de avaliação

Para medir a acurácia tanto das segmentações sintéticas quanto das segmentações em exames de TC realizadas neste trabalho, é utilizado um conjunto de métricas composto pela distância entre os contornos e por medidas de ajustes descritas a seguir.

A medida de distância considerada neste trabalho consiste na distância euclidiana. Logo, dado o conjunto de pontos do contorno segmentado (x_s, y_s) ou superfície segmentada (x_s, y_s, z_s) para $s = 1, 2, \dots, n_s$, em que n_s é quantidade de pontos do conjunto, e dado o conjunto de pontos do contorno de referência (x_r, y_r) ou superfície de referência (x_r, y_r, z_r) para $r = 1, 2, \dots, n_r$, em que n_r é quantidade de pontos do conjunto de referência, calcula-se a distância euclidiana para os casos 2D e 3D, entre os pontos das superfície segmentada e da superfície de referência.

Dessa forma, é considerada para cada ponto do contorno ou superfície, a menor distância entre o ponto em questão e o contorno da segmentação de referência, dada por

$$d(s) = \min [d(s, r)], \quad \text{para } r = 1, \dots, n_r. \quad (3.15)$$

Vale ressaltar que, para o cálculo da distância, são considerados todos os pontos do contorno ou superfície de referência, bem como também são considerados todos os pontos do contorno ou superfície do resultado da segmentação, e não apenas os pontos de controle do modelo ativo em questão.

Para as segmentações em imagens sintéticas, a segmentação de referência é o próprio objeto, já para os exames de TC as segmentações de referência são os contornos contidos no padrão ouro.

Baseado no conjunto de valores $d(s)$, são calculadas e utilizadas para a avaliação da segmentação a distância média (μ_d), além do desvio padrão (σ_d) e maior distância (\max_d).

Para auxiliar e complementar a análise dos resultados, além das medidas baseadas na

distância euclidiana, também são consideradas as medidas de ajustes descritas a seguir.

3.2.3.1 Medidas de ajuste

As medidas de ajuste *Fit* são baseadas na simetria entre regiões da imagem de referência $R = r_1; r_2; \dots; r_r$ e regiões da imagem segmentada $S = r_1; r_2; \dots; r_s$, ou seja, o quanto se assemelham entre si quando sobrepostas.

São adotadas quatro medidas de ajuste distintas, sendo estas (DELVES et al., 1992; FÉLIX, 2011)

Ajuste de posição - os ajustes de posição Fit_{xy} para imagens 2D e Fit_{xyz} para imagens 3D medem a precisão do ajuste entre R e S , baseando-se nas diferenças entre os centros geométricos de cada região e as médias dos eixos x e y , e z em caso de imagens 3D, definidos por

$$\begin{aligned} Fit_{xy} &= 1 - \frac{x_d + y_d}{2}, \\ Fit_{xyz} &= 1 - \frac{x_d + y_d + z_d}{3}, \end{aligned} \quad (3.16)$$

em que x_d , y_d e z_d são dados por

$$\begin{aligned} x_d &= \frac{|\bar{x}_R - \bar{x}_S|}{m}, \\ y_d &= \frac{|\bar{y}_R - \bar{y}_S|}{n}, \\ z_d &= \frac{|\bar{z}_R - \bar{z}_S|}{o}, \end{aligned} \quad (3.17)$$

em que \bar{x}_R , \bar{y}_R e \bar{z}_R indicam a coordenada média, nos eixos x , y e z , das regiões da imagem de referência R , bem como \bar{x}_S , \bar{y}_S e \bar{z}_S indicam o análogo para as regiões da imagem segmentada S ; m , n e o representam as dimensões da imagem nos eixos x , y e z respectivamente.

Ajuste de intensidade - o ajuste de intensidade Fit_I é definido como a razão da variação da média de intensidade dos níveis de cinza \bar{I}_R e \bar{I}_S das regiões R e S , respectivamente, dado por

$$Fit_I = 1 - \frac{|\bar{I}_R - \bar{I}_S|}{\bar{I}_R + \bar{I}_S}. \quad (3.18)$$

O valor obtido com Fit_I varia entre 0 e 1. Quando este valor tende a 1 indica que houve uma pequena variação de intensidade e a região segmentada se assemelha à região de referência. Caso as regiões sejam bastante diferentes o valor de Fit_I tende à zero, indicando uma grande variação de intensidade.

Ajuste de tamanho - o ajuste de tamanho Fit_T é definido como a razão da diferença entre as áreas, ou volumes, de R e S e a soma das mesmas, dado por

$$Fit_T = 1 - \frac{|R - S|}{R + S}. \quad (3.19)$$

Este valor também varia entre 0 e 1. Se este valor tende a 1, indica que as áreas ou volumes são semelhantes, quando tende à zero indica uma grande diferença entre as áreas ou volumes.

Ajuste de forma - o ajuste de forma Fit_F é definido como a razão da interseção e união das áreas ou volumes de R e S , dada por

$$Fit_F = \frac{(R \cap S)}{(R \cup S)}. \quad (3.20)$$

Da mesma forma que as demais medidas de ajuste, esta medida varia entre 0 e 1. Quando o valor de Fit_F tende para zero, indica a ausência ou discordância na sobreposição entre as regiões R e S . Caso contrário, quanto este valor tende para 1, a sobreposição entre as regiões de R e S é concordante.

Dado que todos os métodos e o fluxo da segmentação automática em imagens sintéticas e de TC do tórax estão definidos e descritos, devem-se aplicá-los na obtenção de resultados. Além disso, discussões relevantes acerca destes resultados devem ser realizadas, visando completar todos os objetivos desta tese.

Capítulo 4

Resultados e Discussões

Neste Capítulo são apresentados e discutidos os resultados obtidos com os testes em imagens sintéticas e de TC do tórax.

Os testes em imagens sintéticas são realizados com o intuito de verificar o comportamento das forças internas propostas e o comportamento de malhas diferentes para objetos com formatos distintos. Já os testes em imagens de TC do tórax são realizados para verificar o acerto da inicialização automática do MSA para cada lobo, além de mensurar a qualidade da segmentação do MSA quando aplicado aos lobos pulmonares.

4.1 Resultados em Imagens Sintéticas

Para realizar estes testes, 5 formas geométricas 3D são selecionadas, com o intuito de englobar características como cantos pontiagudos, cantos arredondados, regiões planas e regiões curvas. O processo de segmentação do MSA proposto é testado com os 3 tipos diferentes de malhas abordados na Seção 2.2.1.1, sendo estas uma malha estruturada retangular, uma malha KNN e uma malha Crust que se baseia em Delaunay.

Com o objetivo de medir a acurácia da segmentação para cada tipo de malha, os testes são realizados com quantidades distintas de pontos. A energia interna é testada com duas composições, sendo a primeira formada pela força de continuidade definida na Equação 3.2 e pela força de curvatura definida na equação 3.4, dessa forma a superfície deve se retrair até atingir as bordas do objeto. A segunda composição é formada pela mesma força de continuidade, mas tem a força de curvatura substituída pela força balão definida na Equação 3.5. Com esta segunda composição, a superfície inicial deve se expandir, conformando-se aos limites do objeto.

Os dados obtidos, juntamente com uma análise detalhada dos testes sintéticos, são apresentados no Apêndice C. Os resultados de distância média da segmentação dos volumes sintéticos utilizando 2500 pontos de controle, com as distintas configurações do MSA testadas, são apresentados na Tabela 4.1.

Tabela 4.1: resultados de distância média da segmentação dos volumes sintéticos utilizando 2500 pontos.

Nº de pontos	Malha estruturada		Malha kNN		Malha Crust	
	F_{cont}	F_{bal}	F_{cont}	F_{bal}	F_{cont}	F_{bal}
Cilindro	0,23	0,35	0,23	0,19	0,21	0,21
Cone	0,44	0,47	0,38	0,27	0,42	0,53
Cubo	1,05	0,01	0,03	0,01	0,04	0,01
Pirâmide	1,03	0,40	0,92	0,38	0,89	0,38
Esfera	0,30	1,13	0,31	0,69	0,38	0,36

Analisando os resultados obtidos nas segmentações das imagens sintéticas, conclui-se claramente a diferença de comportamento entre o MSAs dotado de energia interna com força de curvatura e o MSA com a força balão como uma das componentes da energia interna. É notória a superioridade da força balão na segmentação de objetos com cantos agudos e bordas retas ou com alta curvaturas, fato este plenamente explicável pela formulação da força balão que é o oposto da força de curvatura.

Os cantos com altas curvaturas geralmente são regiões críticas para a obtenção de uma boa representação do objeto 3D. Utilizando a energia interna com força de curvatura, dificilmente algum ponto de controle deve se posicionar nestas regiões, a não ser em casos extremamente específicos em que o posicionamento dos pontos de controles vizinhos resulte em valores da força de continuidade que compensem a diferença da força de curvatura.

Entretanto, também é possível observar que é extremamente satisfatória a segmentação por MSA com força de curvatura de objetos que não possuem cantos agudos, obtendo resultados melhores, em alguns casos, do que a segmentação com força balão. Este caso pode ser exemplificado com a segmentação da esfera.

Além da diferença no resultado da segmentação obtida, existe um fator que pode ser mandatório na escolha de qual força utilizar para compor a energia interna. Este fator consiste basicamente no tipo de movimento realizado pelo MSA durante o processo de evolução.

Enquanto a força de curvatura atua retraindo a superfície, a força balão atua expandido-a, o que explica a diferença do raio da esfera adotada como superfície inicial. Neste sentido, em casos em que o objeto deve ser segmentado pelo lado de fora, o uso da força de curvatura é recomendado. Já em casos que a segmentação deve ser feita por dentro do objeto, a força balão deve ser utilizada.

Em relação a segmentação dos lobos pulmonares, a utilização da força balão é mandatória devido à composição da energia interna. Caso a força de curvatura seja utilizada no MSA, com uma inicialização externa ao pulmão, o resultado obtido deve ser o próprio pulmão, pois os pontos devem convergir nas bordas do pulmão e não atingiriam a região das fissuras.

Além da diferença entre as duas energias internas utilizadas, também percebe-se uma superioridade, em termos de qualidade da segmentação, das malhas não estruturadas. Destaca-se que as forças internas propostas nesta tese podem ser utilizadas tanto em malhas estruturadas, quanto em malhas não estruturadas, proporcionando uma maior flexibilidade na configuração do MSA.

Por fim, as malhas não estruturadas permitem a realização de alterações pontuais, como a remoção ou adição de pontos de controles específicos, possibilitando o uso de funções de adição e remoção de pontos de controle durante a evolução do MSA, o que é fundamental para uma boa representação da segmentação dos lobos pulmonares.

4.2 Resultados em Exames de TC

Os resultados dos processamentos em exames de TC são divididos em duas seções. A primeira se refere ao desempenho do algoritmo de inicialização automática para o MSA descrito na Seção 3.1.3, enquanto a segunda seção aborda o desempenho obtido pelo MSA na segmentação dos lobos pulmonares.

Para ambas as seções os resultados demonstrados são obtidos pelo processamento dos 10 exames, do banco LIDC-IDRI, que compõem o padrão ouro elaborado para este trabalho.

4.2.1 Inicialização automática para MSA

Para os resultados obtidos na inicialização automática do MSA, são apresentadas, por exame, cinco superfícies iniciais sendo uma para cada lobo, totalizando 50 superfícies.

Conforme definido na Seção 3.1.3, a superfície inicial para cada um dos lobos consiste

em uma esfera de raio de 10 voxels com centro nas coordenadas definidas com base nas funções de projeção descritas na mesma seção.

Nestes resultados, é considerada correta a inicialização que obtém toda a esfera inicial no interior do lobo correspondente. A verificação desta condição é efetuada baseada na marcação dos contornos dos lobos contida no padrão ouro. Desta forma, é calculado um percentual de acerto para cada lobo, que consiste na razão entre a quantidade de inicializações corretas e o total de lobos, neste caso 10 lobos de cada tipo. Além deste, é calculado um percentual de acerto geral definido pela razão de todas as inicializações corretas pelo total de lobos processados, neste caso 50, sendo 5 por exame.

Dentre as superfícies esféricas geradas, baseando-se nas coordenadas apresentadas, todas as que são referentes aos lobos superior direito e esquerdo, bem como aos lobos inferior direito e esquerdo são localizadas no interior dos respectivos lobos.

Já para lobo médio direito, nos exames 2, 3 e 6 a inicialização é considerada errada. Nos exames 3 e 6, as imagens que os compunham não apresentaram, em nenhum nível, alguma estrutura semelhante à fissura horizontal, que separa o lobo superior do lobo médio, por motivos detalhados na Seção 2.1.1. Neste caso, com a ausência da fissura horizontal não é possível determinar se a inicialização está correta. Para ilustrar a falta da fissura horizontal, dois *slices* dos exames de TC 6 e 8 são apresentados na Figura 4.1.

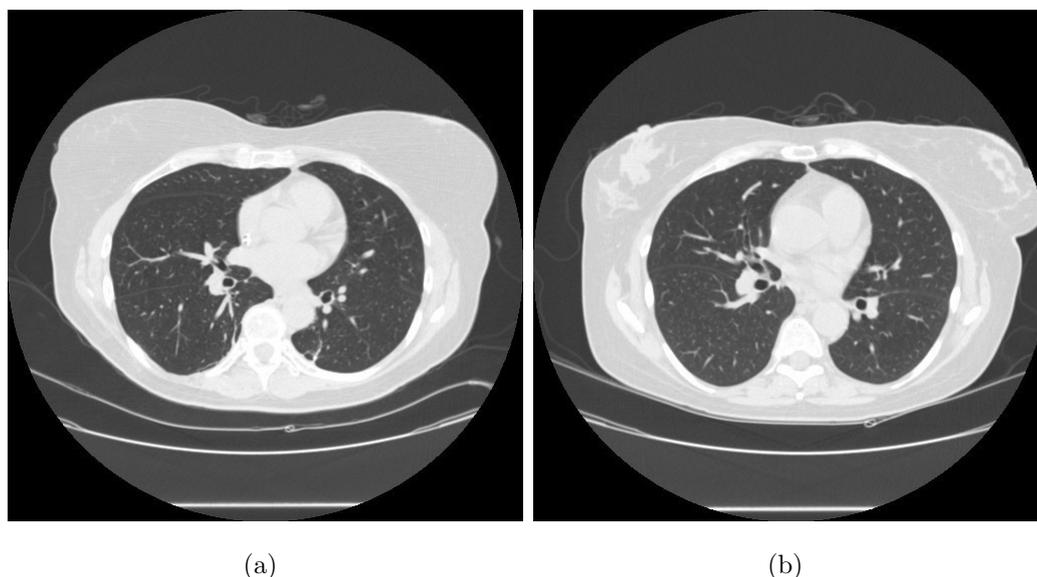


Figura 4.1: Imagem de exames de TC (a) exame 8 com fissura horizontal, e (b) exame 6 sem fissura horizontal.

Em relação ao exame 2, parte da esfera é interna ao lobo médio direito e parte se localiza externa ao referido lobo, sendo considerada como uma inicialização errada. Tal

erro, pode ser explicado observando a estrutura anatômica do pulmão, que apresenta uma base côncava, fazendo com que seus limites, em regiões no centro da base, estejam em níveis de altura menores do que os demais. A inicialização referente ao lobo médio direito do exame 2 é ilustrada na Figura 4.2.

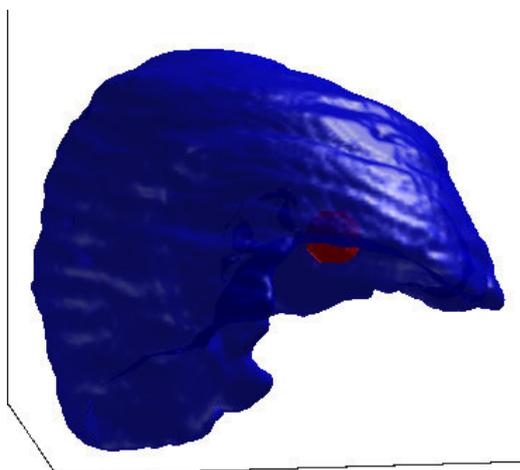


Figura 4.2: Inicialização do MSA referente ao lobo médio direito do exame 2.

As taxas de acerto obtidas são apresentadas na Tabela 4.2. São ilustrados alguns exemplos das inicializações obtidas em vermelho na Figura 4.3.

Tabela 4.2: Taxas de acerto, por lobo e geral, obtidas pelo método de inicialização automática.

Lobo	Taxa de Acerto (%)
Superior Direito	100%
Médio Direito	70%
Inferior Direito	100%
Superior Esquerdo	100%
Inferior Esquerdo	100%
Geral	94%

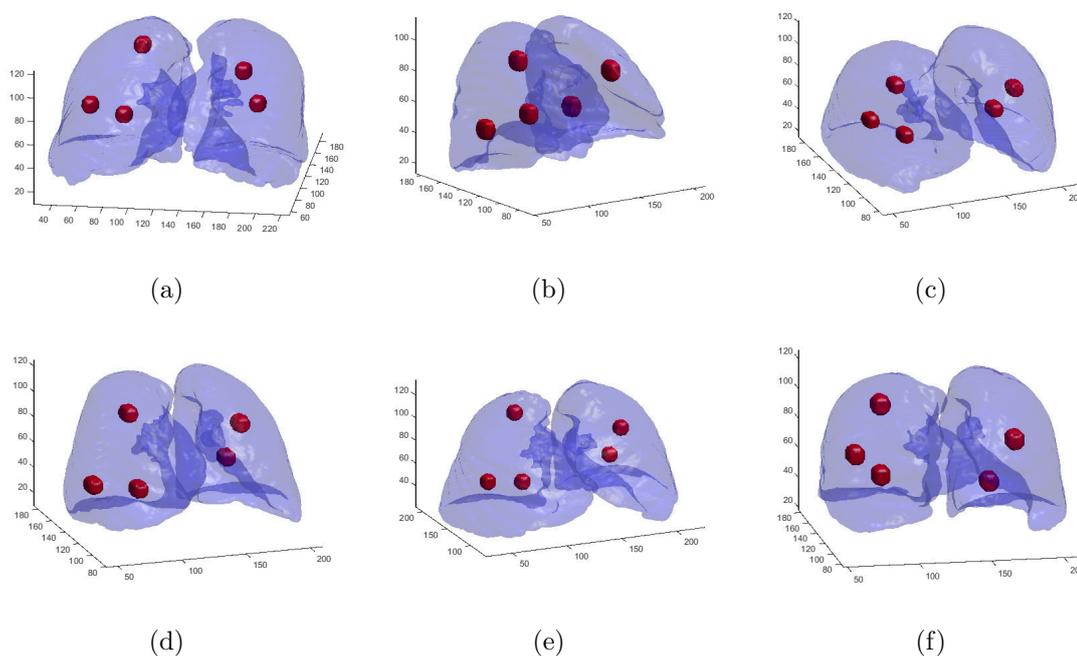


Figura 4.3: exemplos de inicializações automáticas geradas para os cinco lobos.

Baseado nos dados apresentados, observa-se o desempenho com 94% de acerto do método de inicialização proposto nesta tese. Vale ressaltar, que para todos os lobos com exceção do lobo médio, as taxas obtidas foram de 100%. Além disso, a taxa de 70% obtida, acontece devido a uma alta variabilidade nos exames contidos em um conjunto com poucas amostras.

4.2.2 Segmentação dos lobos pulmonares

Por fim, são apresentados os resultados obtidos na segmentação dos lobos pulmonares em imagens de TC do Tórax. Os resultados são produzidos para quatro métodos distintos resultantes da combinação de dois tipos de malhas e dos dois tipos de energia externa. Em relação às malhas são utilizadas apenas malhas não estruturadas sendo estas a malha kNN e a malha Crust, apresentadas anteriormente na Seção 2.2.1.1.

Nesses resultados a malha estruturada não é utilizada devido a sua limitação e incompatibilidade em relação aos métodos de adição e remoção de pontos de controle, conforme descrito na Seção 3.1.4. Além disso, dentre as três malhas abordadas nos testes sintéticos, descritos no Apêndice C, a malha estruturada é a que apresenta, em geral, o pior desempenho.

Em relação à energia interna, apenas a composição que considera a força de continuidade, definida na Equação 3.2, e a força balão, definida na Equação 3.5, são utilizadas. A motivação para utilizar apenas esta composição para a energia interna é inerente à aplicação, além da mesma obter os melhores resultados nos testes sintéticos apresentados no Apêndice C.

A utilização da energia interna composta por força de curvatura, neste caso, é inviável, uma vez que esta determina que o MSA deve ser inicializado no exterior do objeto de interesse e a energia externa utilizada é composta basicamente pelos limites dos pulmões e fissuras, que por sua vez se encontram no interior dos pulmões. Desta forma, a superfície inicializada no exterior do objeto deve convergir até as bordas dos pulmões, que possuem energia externa mínima e não conseguem atingir as fissuras, conseqüentemente não convergem para a superfície dos lobos pulmonares.

O valor adotado para os parâmetros α , que pondera a força de continuidade, e β , que pondera a força balão, é de 0,1. As inicializações adotadas consistem na distribuição uniforme de 200 pontos sobre a superfície da esfera calculada pelo método de inicialização descrito na seção 3.1.3.

Cada um dos lobos de cada um dos exames são processados independentemente, seguindo o processo ilustrado na Figura 3.1, sendo utilizados os critérios de parada, função de adição e funções de remoção de pontos descritos na Seção 3.1.4.

Todos os testes realizados contemplaram as duas funções de remoção de pontos, descritas na Seção 3.1.4.1, sendo considerado o limiar de remoção para força de curvatura em 0,2. Este valor foi adotado com base em testes empíricos, de tal forma que não seja removido nenhum ponto pertencente à superfície dos lobos, restando apenas, quando houver, pontos estacionados em mínimos locais.

Para a função de adição de pontos, descrita na Seção 3.1.4.2, foi estabelecido o valor de 0,05. Tal valor foi adotado por se tratar da distância máxima desejada entre dois pontos vizinhos, como as imagens de exames de TC possuem resolução padrão de 512×512 voxels, o valor adotado define em 25 voxels a distância máxima entre dois pontos conectados.

Os três critérios de parada descritos na Seção 3.1.4.3 também são utilizados em todos os testes realizados em exames de TC. Os valores e limiares necessários para estes critérios são estabelecidos com base em testes empíricos realizados exaustivamente.

Para determinar a quantidade de iterações para o critério de parada de ponto, é observada a quantidade máxima de iterações em que cada ponto permanece no mesmo local, antes de ter sua coordenada novamente alterada. Nos testes realizados, esta quantidade

de iterações não passou de 3, por isto para o critério de parada de ponto é adotado empiricamente o valor de 5 iterações.

Já para o critério de fim de ciclo é adotado o número máximo de 500 iterações e o percentual de 95% de pontos estacionados. Considerando que, em cada iteração, um ponto de controle pode se mover um pixel em qualquer direção e que a resolução da imagem de exame de TC é 512×512 voxels, 500 iterações é quase suficiente para que um ponto percorra de um extremo a outro em um plano qualquer. Por fim, para o critério de fim de processo, é definida a quantidade máxima de 10 ciclos e a distância média de 0,075 voxels, equivalente a 1,5 vezes a distância adotada para a adição de pontos.

Para a análise e discussão dos resultados são consideradas as medidas em milímetros da distância média μ_d juntamente com desvio padrão σ_d descritas na Seção 3.2.3. As medidas de ajustes de forma e tamanho descritas na Seção 3.2.3.1 também são calculadas. As medidas de ajuste de posição e de intensidade, em todos os casos de testes, obtêm resultados próximo ao valor máximo. Apesar de retratar o sucesso dos testes realizados, não agrega informação útil que possa ser utilizada em uma análise comparativa entre os métodos distintos.

Para cálculo das métricas supracitadas, inicialmente é realizada a segmentação 3D dos lobos pulmonares de cada exame pelos 4 métodos testados, sendo estes:

- Hessiana/Crust - MSA com energia externa Hessiana e malha Crust;
- Hessiana/NN - MSA com energia externa Hessiana e malha NN;
- LBP/Crust - MSA com energia externa LBP e malha Crust; e
- LBP/NN - MSA com energia externa LBP e malha NN.

Em seguida, os *slices* da segmentação correspondentes aos *slices* do padrão ouro são selecionados para comparação e cálculo de métricas. As métricas são calculadas por exame para cada lobo pulmonar. Para isto são selecionadas dentre as imagens do padrão ouro de cada exame, todas as regiões que compõem o lobo em questão.

Para melhor interpretação e análise dos resultados obtidos, inicialmente as métricas calculadas são apresentadas por lobo e em seguida é realizada uma discussão sobre os resultados abordando os sucessos e falhas. Por fim, uma média geral dos resultados é apresentada juntamente com uma conclusão para os testes realizados.

Com as medidas obtidas na segmentação do lobo superior esquerdo para cada um dos métodos testados, é ilustrado um gráfico comparativo entre as distâncias médias obtidas

na Figura 4.4, bem como são ilustrados os gráficos com as medidas Fit_T e Fit_F nas Figura 4.5 e 4.6, respectivamente.

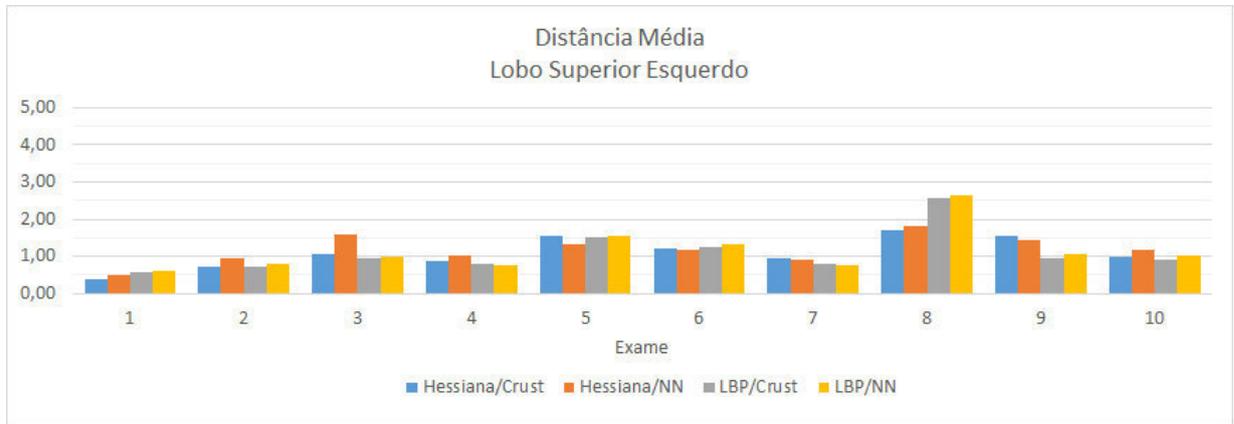


Figura 4.4: gráfico das distância médias obtidas na segmentação do lobo superior esquerdo para cada método testado.

Inicialmente, verifica-se que os métodos obtêm segmentações com todas as distâncias médias μ_d calculadas menores que 3 mm, além de diversas medidas de μ_d menores que 1 mm. Além disso, é possível observar que, geralmente, os métodos que utilizam a mesma energia externa apresentam resultados próximos, mesmo utilizando malhas diferentes. Este comportamento é recorrente e pode ser observado nos demais resultados.

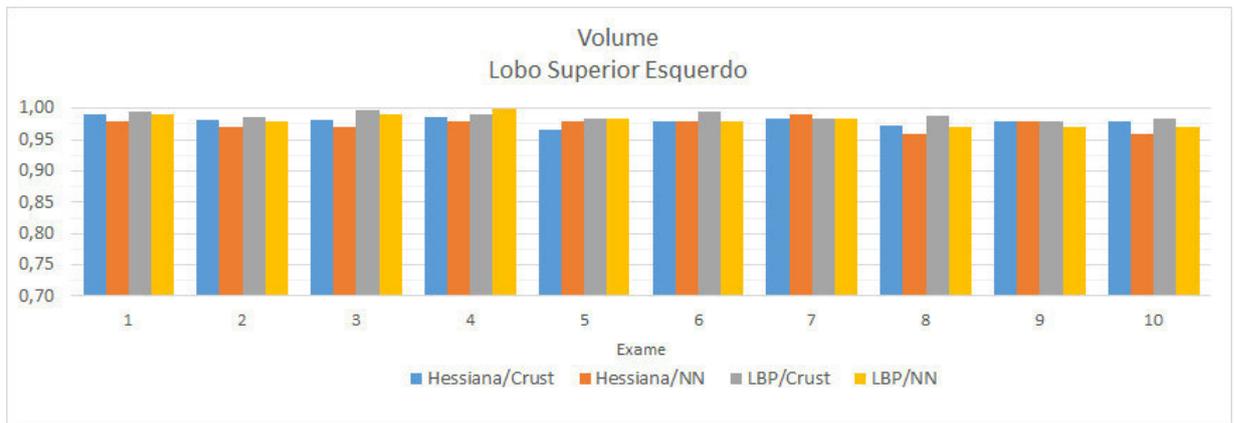


Figura 4.5: gráfico das medidas de ajuste de volume (Fit_T) obtidas na segmentação do lobo superior esquerdo para cada método testado.

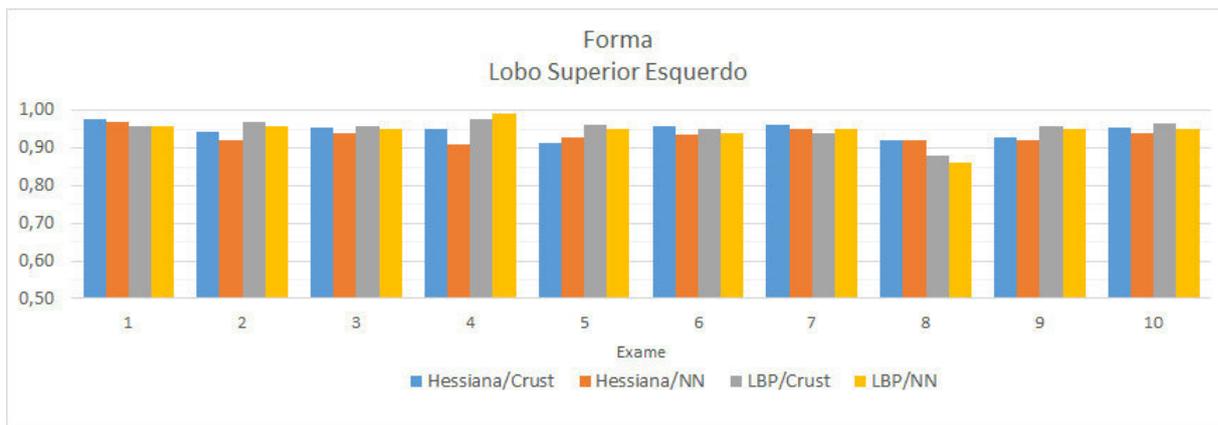


Figura 4.6: gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo superior esquerdo para cada método testado.

Ao analisar as Figuras 4.5 e 4.6, a qualidade da segmentação obtida é novamente confirmada com os valores de Fit_T maiores que 0,95 e Fit_F maiores que 0,9 para todos os casos, com exceção da segmentação obtida com a energia LBP para o exame 8.

As medidas de ajuste das segmentações do lobo superior esquerdo mostram que as diferentes energias externas chegam a ser equivalentes em diversos casos, entretanto a diferença entre as métricas μ_d e Fit_F obtidas no exame 8, apontam uma superioridade na energia Hessiana neste exame.

Em relação a segmentação obtida para o lobo inferior esquerdo, são ilustrados gráficos comparativos entre as distâncias médias, entre as medidas Fit_T e entre as medidas Fit_F nas Figuras 4.7, 4.8 e 4.9, respectivamente.

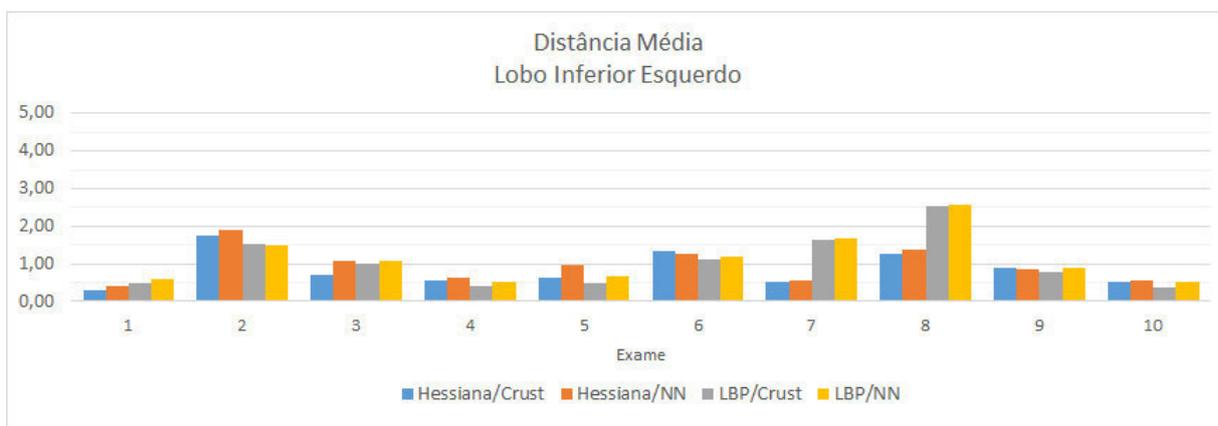


Figura 4.7: gráfico das distâncias médias obtidas na segmentação do lobo inferior esquerdo para cada método testado.

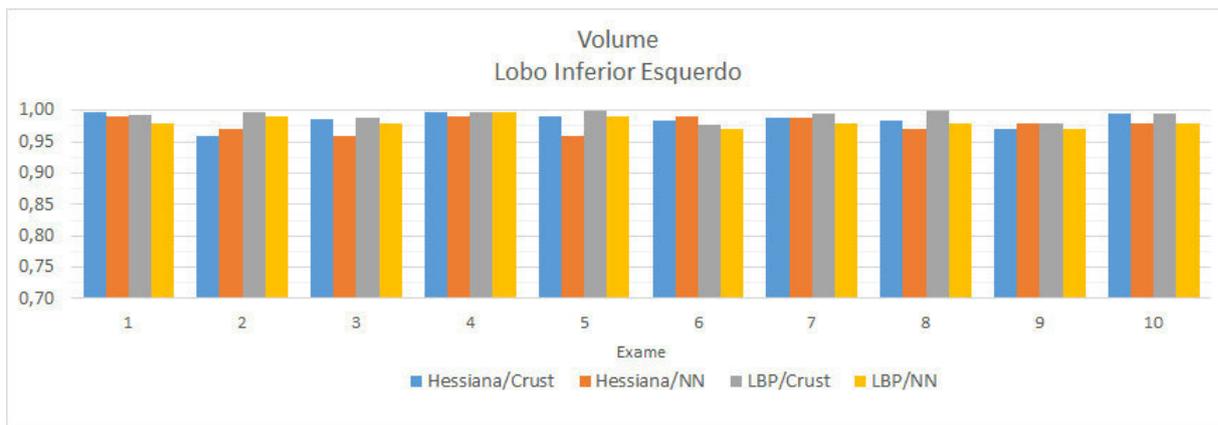


Figura 4.8: gráfico das medidas de ajuste de volume (Fit_V) obtidas na segmentação do lobo inferior esquerdo para cada método testado.

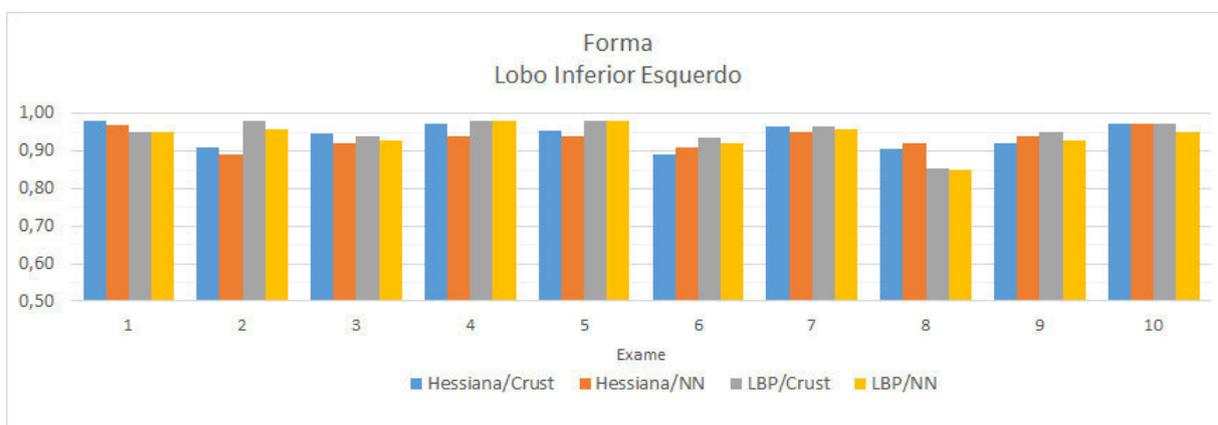


Figura 4.9: gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo inferior esquerdo para cada método testado.

Mais uma vez, excelentes resultados são obtidos, retratando um desempenho superior dos métodos em realizar a segmentação do lobo inferior esquerdo, com $0,30 \leq \mu_d \leq 2,58$.

Vale ressaltar que o pulmão esquerdo possui apenas uma fissura, e esta por sua vez geralmente é representada nas imagens de TC de uma forma mais evidente do que as fissuras do pulmão direito. Fato este que torna menos complexo a segmentação dos lobos do pulmão esquerdo, entretanto não diminui o mérito dos resultados apresentados.

Analisando a segmentação dos lobos no pulmão esquerdo observa-se que dentre os resultados apresentados para o exame 8 por exemplo, quando é utilizada a energia LBP, é obtida uma segmentação com menor qualidade tanto para o lobo superior quanto para o lobo inferior.

Nesse contexto, o MSA converge de acordo com a energia externa calculada, que por sua vez apresenta as regiões de energia mínima em locais próximos, mas não exatamente

no mesmo local da fissura. Isto gera um desvio tanto para o MSA que processa o lobo superior, quanto para o MSA que processa o lobo inferior.

Outro comportamento que pode ser observado em situações com erro, pode ser exemplificado com base nas segmentações obtidas com o exame 2. Ao analisar o lobo superior esquerdo deste exame, há uma convergência com valor de μ_d em $0,72 \text{ mm}$ para o MSA com energia Hessiana e malha Crust, além das medidas de Fit_F em torno de $0,98$. Já ao observar a segmentação do lobo inferior esquerdo do mesmo exame, com o mesmo método percebe-se que, apesar de pequena a variação, a segmentação obtida apresenta menor precisão com μ_d igual à $1,77 \text{ mm}$ e Fit_F em torno de $0,97$.

Este comportamento é explicado pelo fato do processamento do MSA em cada lobo ser totalmente independente. Desta forma, além de, por ventura, alguma região do lobo inferior não ser corretamente segmentada, existe a possibilidade de alguma região do lobo superior, mesmo fazendo parte da segmentação de outro MSA, ser incluída na segmentação do lobo inferior. Isto faz com que o erro apresentado neste lobo seja maior do que no seu lobo adjacente. Conforme citado anteriormente, o processamento dos cinco lobos são independentes e este comportamento pode se fazer presente em qualquer um dos lobos.

Por fim, para exemplificação e visualização das segmentações obtidas, dentre as inúmeras imagens do padrão ouro, são selecionadas algumas juntamente com exemplos de segmentação do MSA com energia Hessiana e energia LBP, variando o tipo de malha. Destaca-se que todas as imagens de exemplo de segmentação desta seção são selecionadas para ilustrar adequadamente a diferença na segmentação dos métodos e comparar visualmente com o padrão ouro.

Na Figura 4.10, as imagens da primeira linha são provenientes do exame 1 e as segmentações apresentadas são obtidas com malha Crust, as imagens da segunda linha são referentes ao exame 4 e as segmentações apresentadas são obtidas com malha Crust, já as imagens da terceira linha são referentes ao exame 8 e as segmentações apresentadas são obtidas com malha NN.

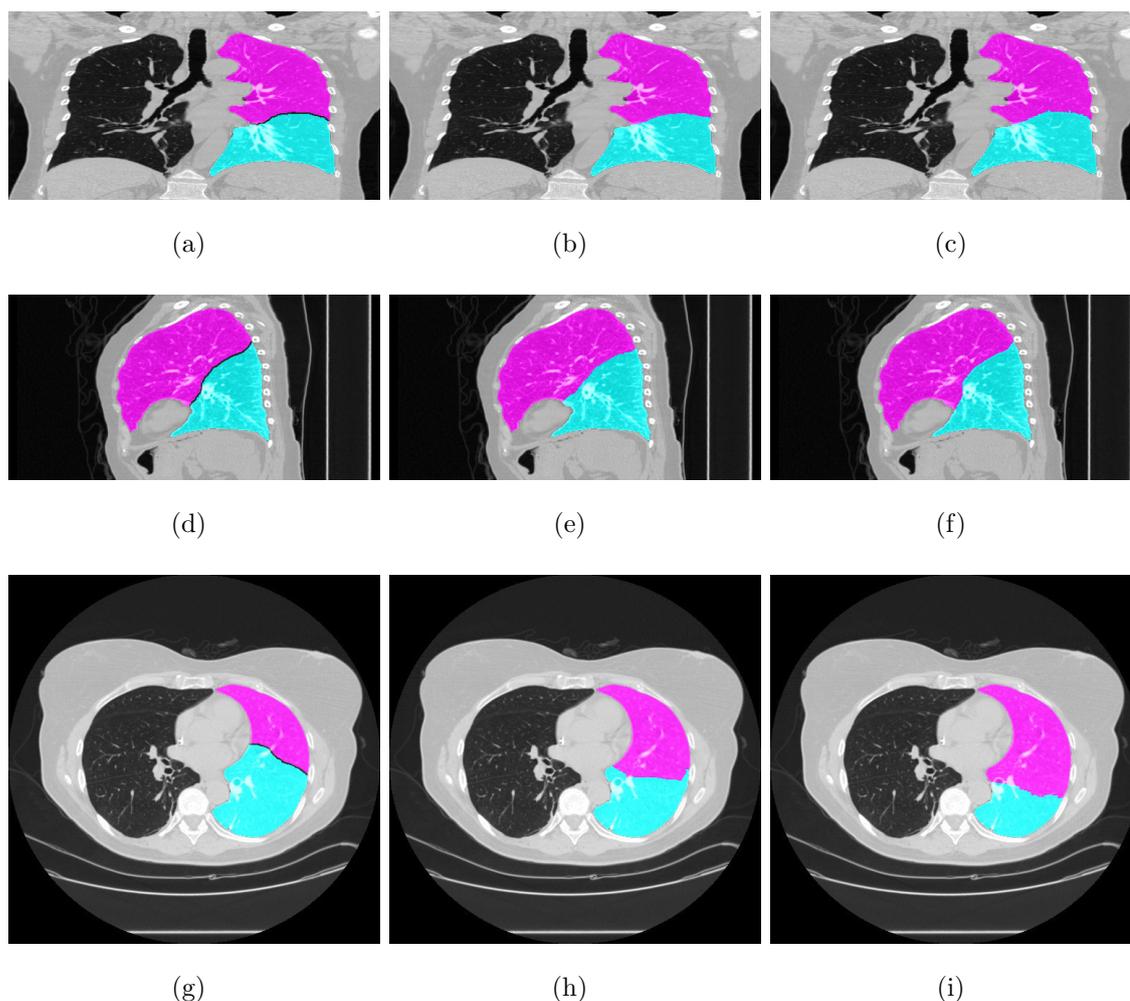


Figura 4.10: segmentação dos lobos do pulmão esquerdo, (a), (d) e (g) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) Hessiana/NN; (c) e (f) LBP/Crust; e (i) LBP/NN.

A seguir, os resultados obtidos para as segmentações dos lobos do pulmão direito são apresentados. Vale lembrar, que o pulmão direito possui três lobos separados por duas fissuras, a fissura oblíqua e a fissura horizontal. Estas fissuras, principalmente a horizontal, geralmente apresentam diversos trechos que não são adequadamente representados nos exames de TC, seja por espessura ou posicionamento da fissura, ou até mesmo efeito de volume parcial. Nesse sentido, destaca-se que há maior complexidade para o processo de segmentação destes lobos.

Baseado na segmentação obtida do lobo superior direito, é ilustrado um gráfico comparativo entre as distâncias médias na Figura 4.11, bem como são ilustrados gráficos comparativos das medidas Fit_T e Fit_F , nas Figuras 4.12 e 4.13 respectivamente.

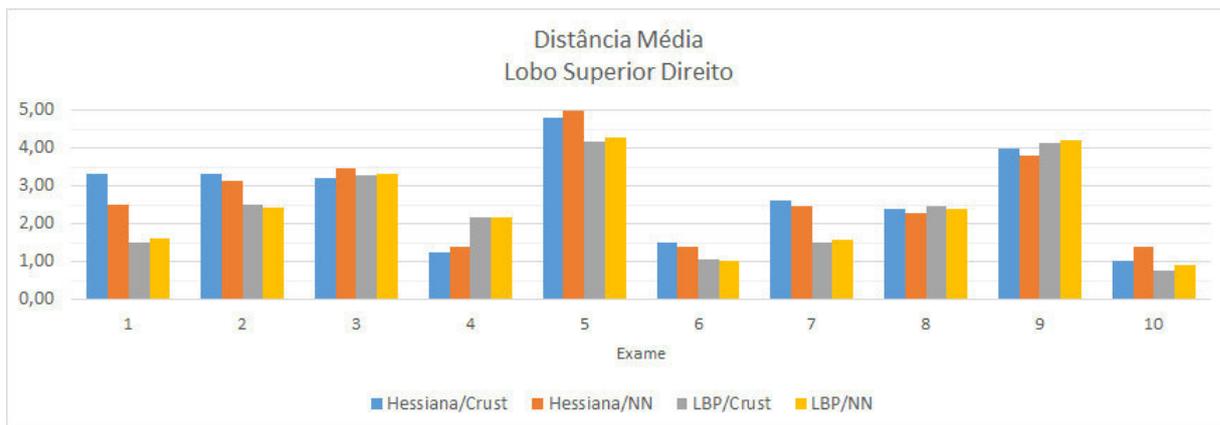


Figura 4.11: gráfico das distâncias médias obtidas na segmentação do lobo superior direito para cada método testado.

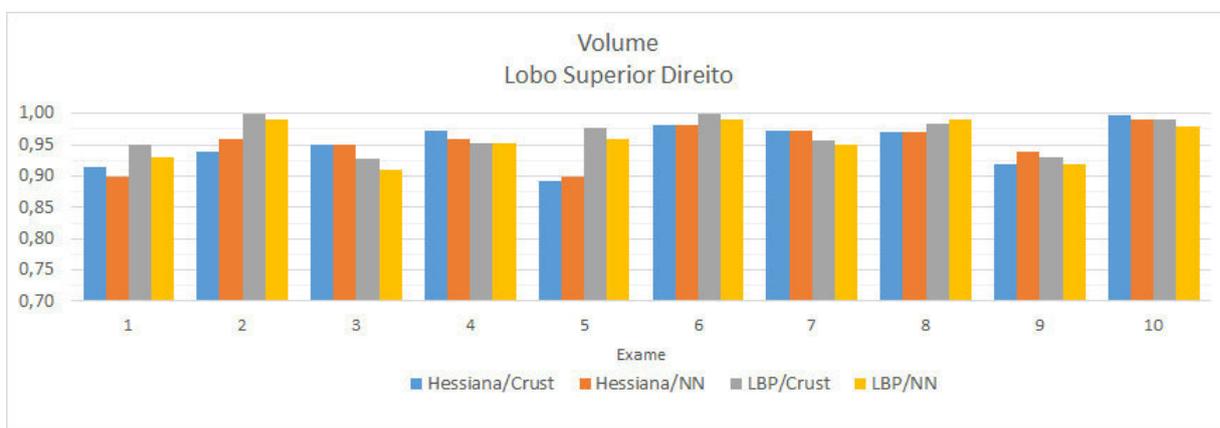


Figura 4.12: gráfico das medidas de ajuste de volume (Fit_V) obtidas na segmentação do lobo superior direito para cada método testado.

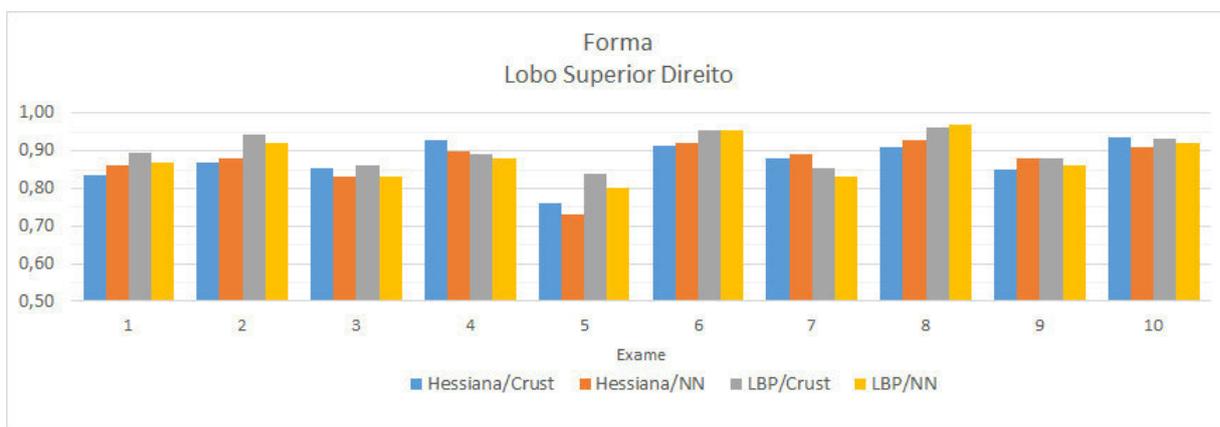


Figura 4.13: gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo superior direito para cada método testado.

Como já era esperado, os resultados do lobo superior direito que possui como limites,

além das bordas do pulmão, as fissuras oblíqua e horizontal, estão um pouco aquém dos resultados obtidos nos lobos do pulmão esquerdo. Todavia, ainda são resultados relevantes. O exame 5, por exemplo, apresenta o pior resultado dentre os testados, obtendo valores de μ_d entre 4 e 5 *mm*, distância essa considerada satisfatória, tendo em vista que o pulmão em questão mede em torno de 280 *mm* de comprimento.

Além de μ_d , a segmentação do lobo superior direito do exame 5 obtém as menores métricas de Fit_T e Fit_F , para o método Hessiana/Crust com 0,89 e 0,76, respectivamente, e para o método LBP/Crust 0,98 e 0,84, respectivamente.

Todavia, excelentes resultados são obtidos, mesmo se tratando do pulmão direito, como por exemplo o exame 10, que apresentou μ_d igual a 0,77 *mm*, Fit_T igual a 0,98 e Fit_F igual a 0,93, para a segmentação realizada por MSA com energia LBP e malha Crust.

A segmentação obtida para o lobo superior direito apresenta resultados satisfatórios ou até mesmo excelentes. Exemplos desta segmentação são ilustrados na Figura 4.14. Nesta Figura o padrão ouro é representado na primeira coluna, as segmentações obtidas pelo MSA com energia Hessiana e com energia LBP são ilustrados na segunda e terceira coluna respectivamente. As regiões consideradas como lobo superior direito são representadas em tons de vermelho.

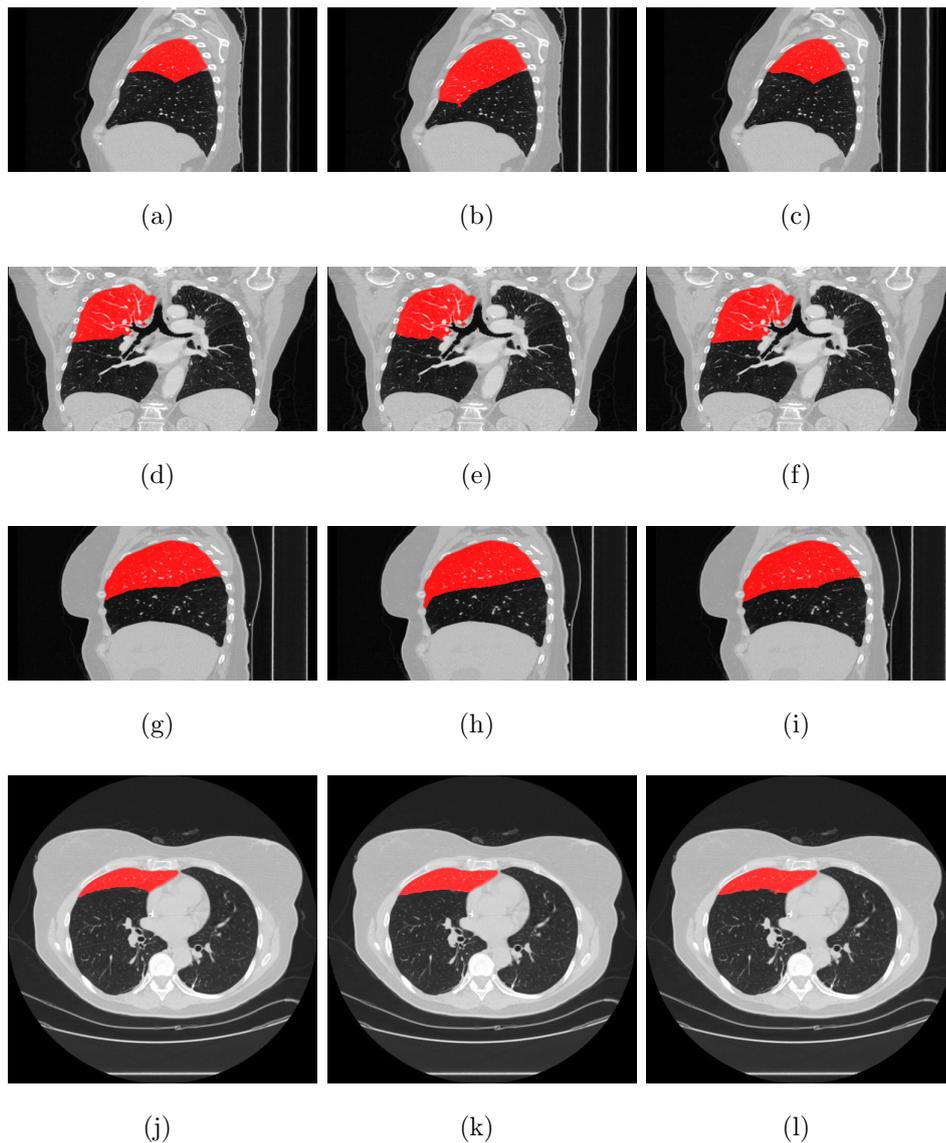


Figura 4.14: segmentação do lobo superior direito, (a), (d), (g) e (j) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) e (k) Hessiana/NN; (c) e (f) LBP/Crust; e (i) e (l) LBP/NN.

Com os dados obtidos na segmentação do lobo médio direito, são ilustrados os gráficos comparativos com μ_d , Fit_T e Fit_F nas Figuras 4.15, 4.16 e 4.17, respectivamente. Observa-se que o lobo médio direito não é definido nos exames 3 e 6, por terem sido removidos em procedimentos cirúrgicos ou pela variabilidade anatômica, conforme detalhado na Seção 2.1.1, logo não há resultados de segmentação, nem padrão ouro, para os lobos médios destes exames.

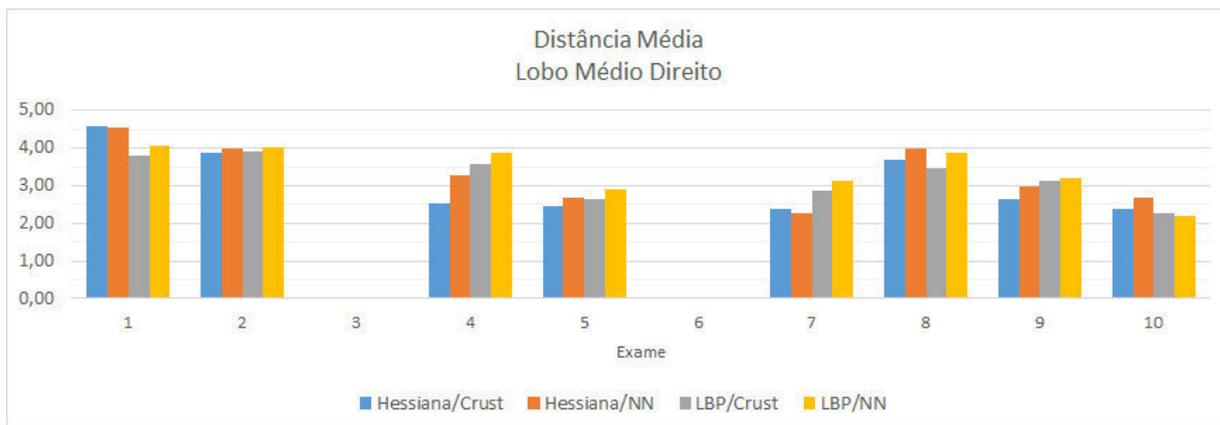


Figura 4.15: gráfico das distâncias médias obtidas na segmentação do lobo médio direito para cada método testado.

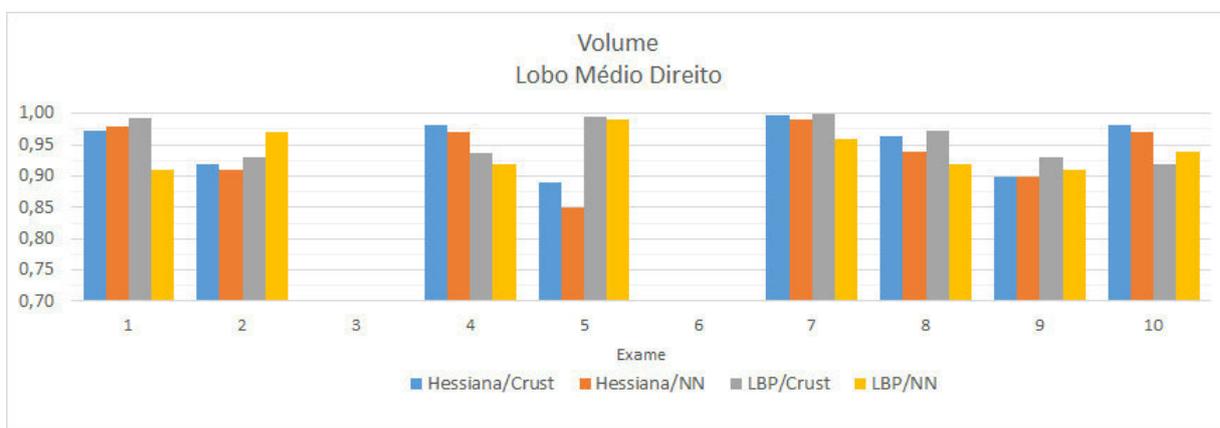


Figura 4.16: gráfico das medidas de ajuste de volume (Fit_V) obtidas na segmentação do lobo médio direito para cada método testado.

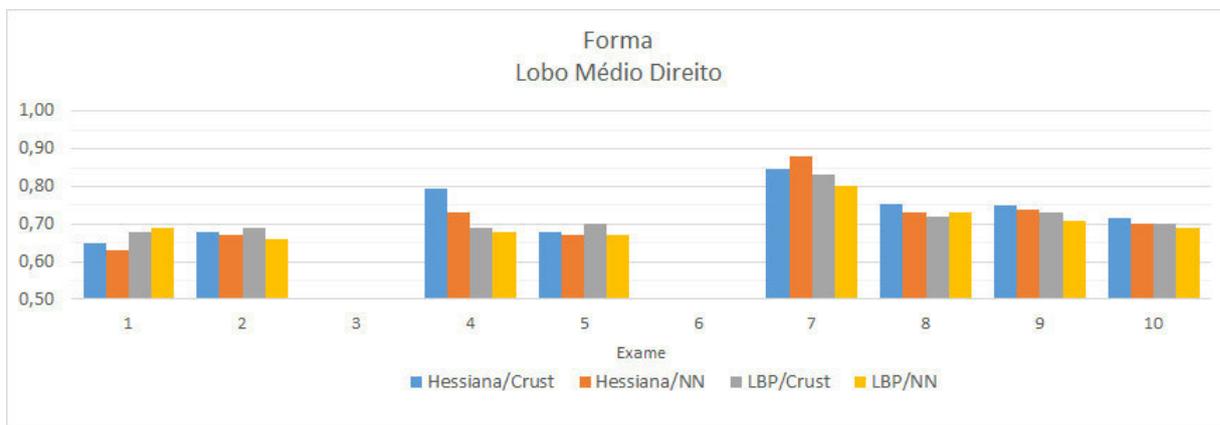


Figura 4.17: gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo médio direito para cada método testado.

Dentre os cinco lobos pulmonares, o lobo médio direito é o que apresenta o maior

desafio para o processo de segmentação, pois é o que possui maior parte de sua superfície definida pela fissura horizontal. Assim, é plenamente explicável que as segmentações obtidas para este lobo sejam as de pior qualidade em relação aos demais.

Todas as medidas de μ_d variaram entre 2 e 4,6 *mm*, o que pode ser considerado uma grande distância quando comparado com as medidas obtidas para os lobos do pulmão esquerdo, como também pode ser considerado um resultado relevante, considerando que a maior distância não chega aos 5 *mm* obtidos na segmentação de um exame do lobo superior direito.

Percebe-se uma grande diferença em relação à medida Fit_T dos métodos com energia Hessiana e LBP no exame 5, porém a medida Fit_F destes métodos para o mesmo exame são semelhantes. Neste caso, os métodos com energia LBP adicionam à segmentação regiões que não pertencem ao lobo médio.

Analisando as medidas de ajuste de forma, percebe-se a dificuldade da segmentação do lobo médio, pois as taxas variam em torno de 0,7, tendo apenas o exame 7 com taxas superiores a 0,80. Na Figura 4.18 são ilustradas, para os mesmos slices, a segmentação do padrão ouro, na primeira coluna, juntamente com as segmentações do lobo médio direito obtidas pelo MSA como energia Hessiana e com energia LBP, na segunda e terceira coluna respectivamente. As regiões consideradas como lobo médio direito são representadas em tons de azul. As duas primeiras linhas são relativas aos slices do exame 5, enquanto as duas últimas linhas são relativas à slices do exame 7.

Ao observar as Figuras 4.18 (e), (h) e (k), percebe-se a dificuldade da correta detecção da fissura horizontal, que separa os lobos superior e médio direito. Baseado no fato de que as segmentações do lobo superior e médio direito partilham do mesmo limite, ao analisar as Figuras 4.14 (b) e 4.18 (e), que ilustram o mesmo slice do mesmo exame, é possível concluir, que neste caso, a fissura horizontal não foi corretamente detectada.

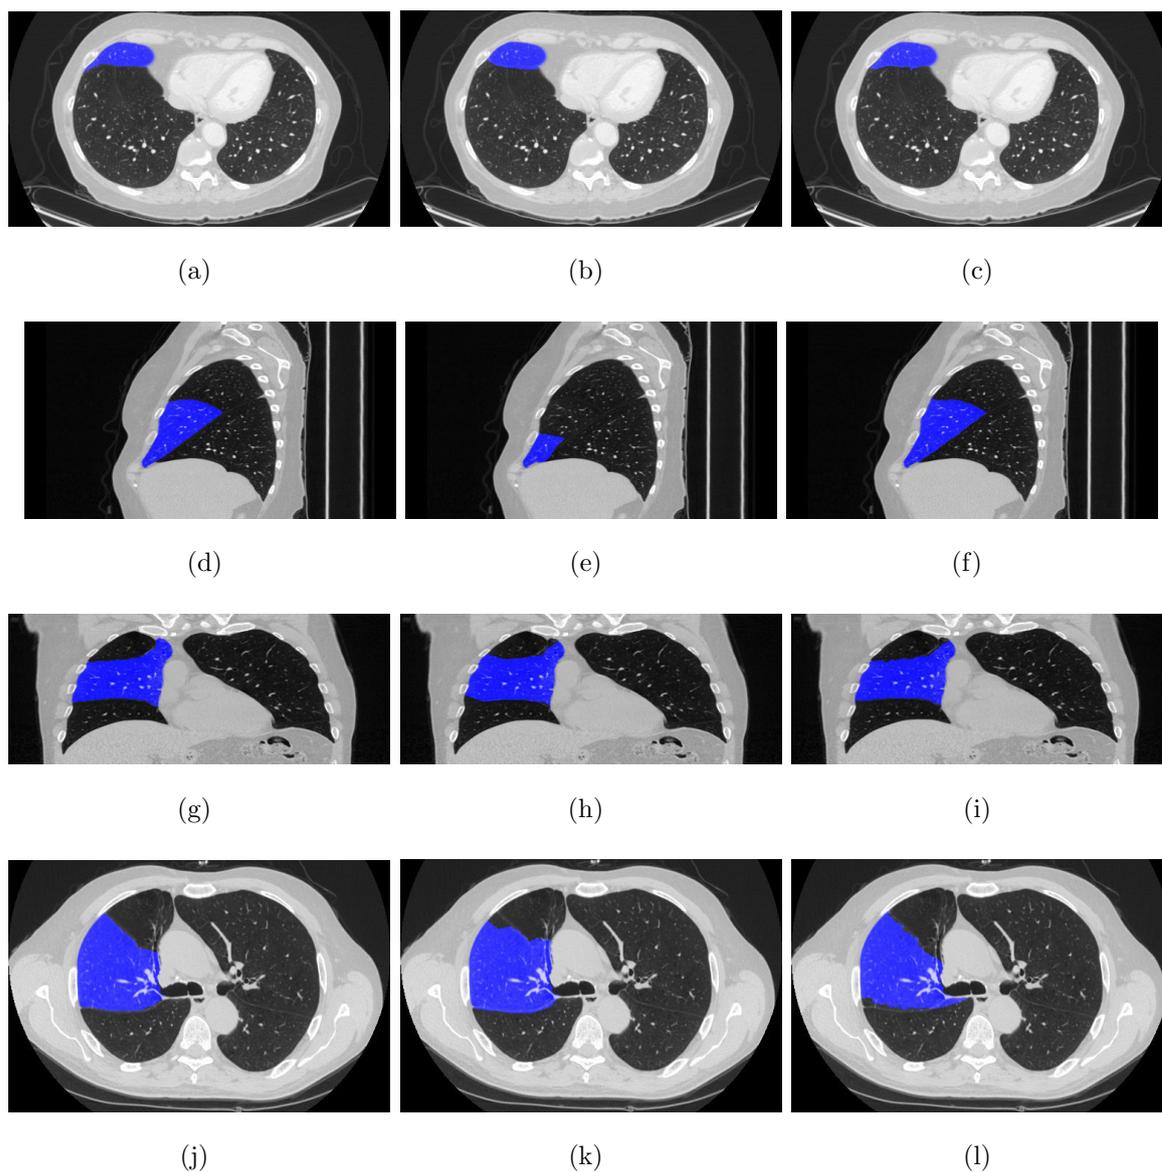


Figura 4.18: segmentação do lobo médio direito, (a), (d), (g) e (j) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) e (k) Hessiana/NN; (c) e (f) LBP/Crust; e (i) e (l) LBP/NN.

Por fim, são apresentados os resultados obtidos com as segmentações do lobo inferior direito. É ilustrado um gráfico comparativo entre as distâncias médias na Figura 4.19, e são ilustrados os gráficos com as medidas Fit_T e Fit_F nas Figuras 4.20 e 4.21, respectivamente.

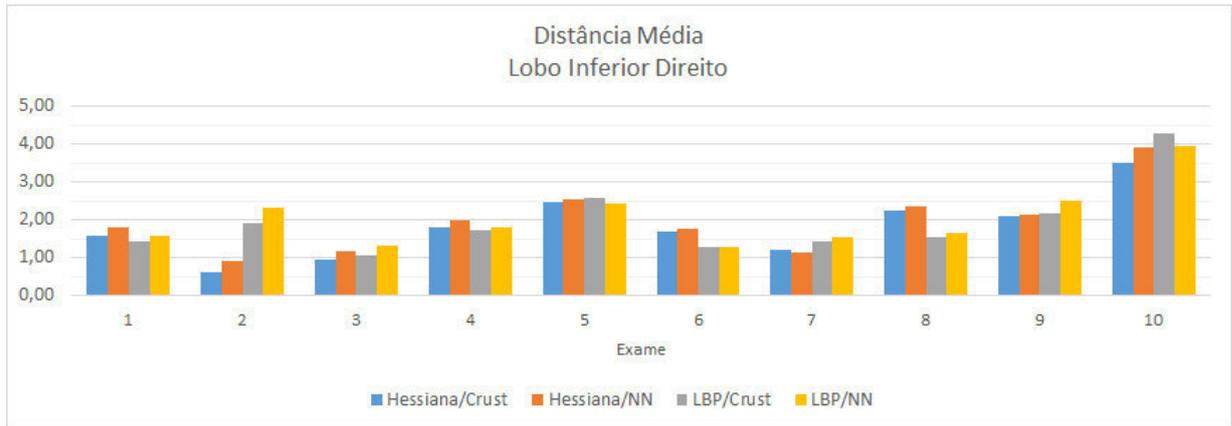


Figura 4.19: gráfico das distâncias médias obtidas na segmentação do lobo inferior direito para cada método testado.

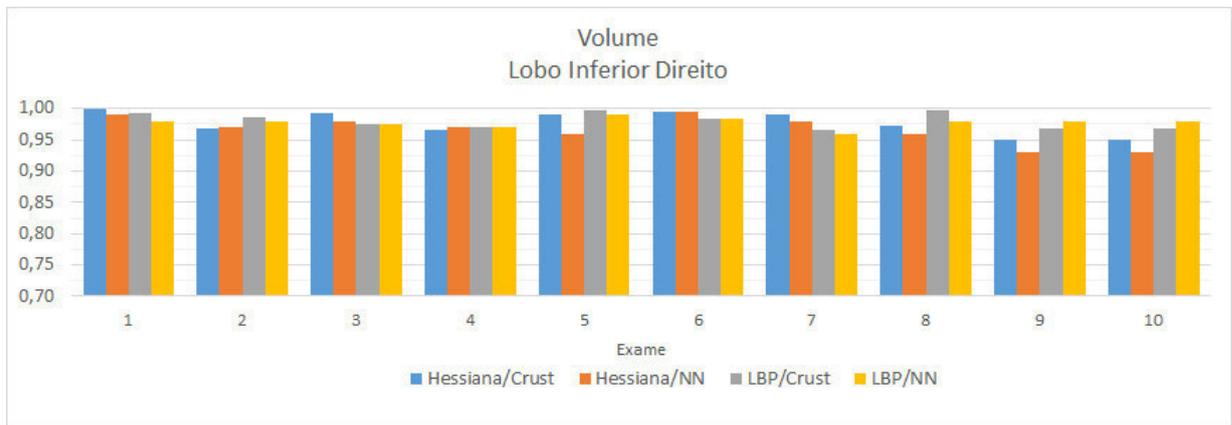


Figura 4.20: gráfico das medidas de ajuste de volume (Fit_V) obtidas na segmentação do lobo inferior direito para cada método testado.

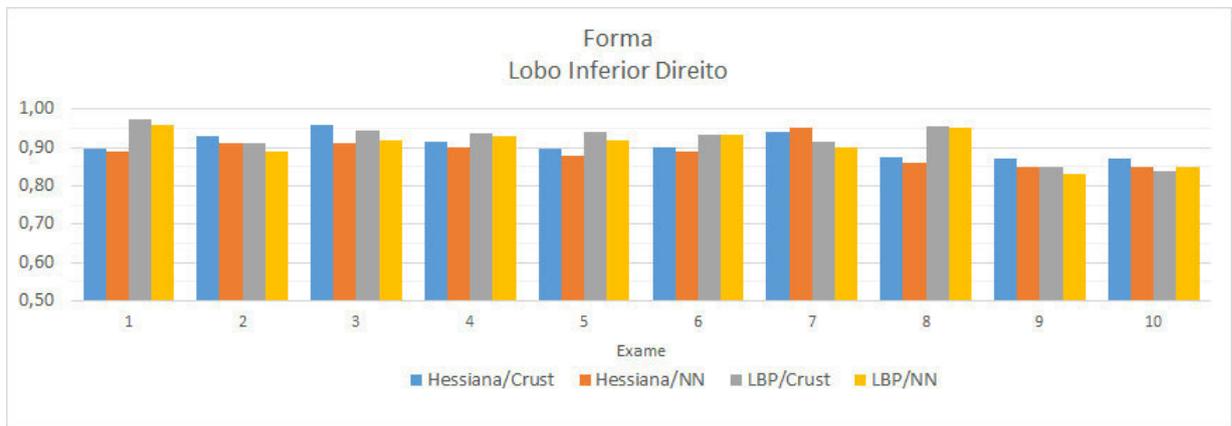


Figura 4.21: gráfico das medidas de ajuste de forma (Fit_F) obtidas na segmentação do lobo inferior direito para cada método testado.

Dentre os lobos do pulmão direito, o lobo inferior é o que geralmente possui limites com

melhor definição, pois estes são compostos pelos limites do pulmão e pela fissura oblíqua. Esta por sua vez, costuma ser melhor representada em exames de TC do que a fissura horizontal, apesar de geralmente possuir diversas regiões com falhas em sua representação.

Com exceção do exame 10 que obteve distâncias médias em torno de 4 *mm*, todos os valores obtidos para μ_d não ultrapassaram 2,5 *mm*. Adicionando-se às medidas de ajuste de forma, que estão em torno de 0,9 para os exames de 1 a 8, e 0,85 para os exames 9 e 10, demonstram uma melhor qualidade nas segmentações do lobo inferior direito dos exames utilizados.

São ilustradas em verde as regiões correspondentes lobo inferior direito na Figura 4.22, sendo a primeira coluna relativa ao padrão ouro, a segunda coluna relativa à segmentação com energia Hessiana e a terceira coluna à segmentação com energia LBP. As duas primeiras linhas ilustram slices do exame 3, enquanto a última ilustra slices do exame 10.

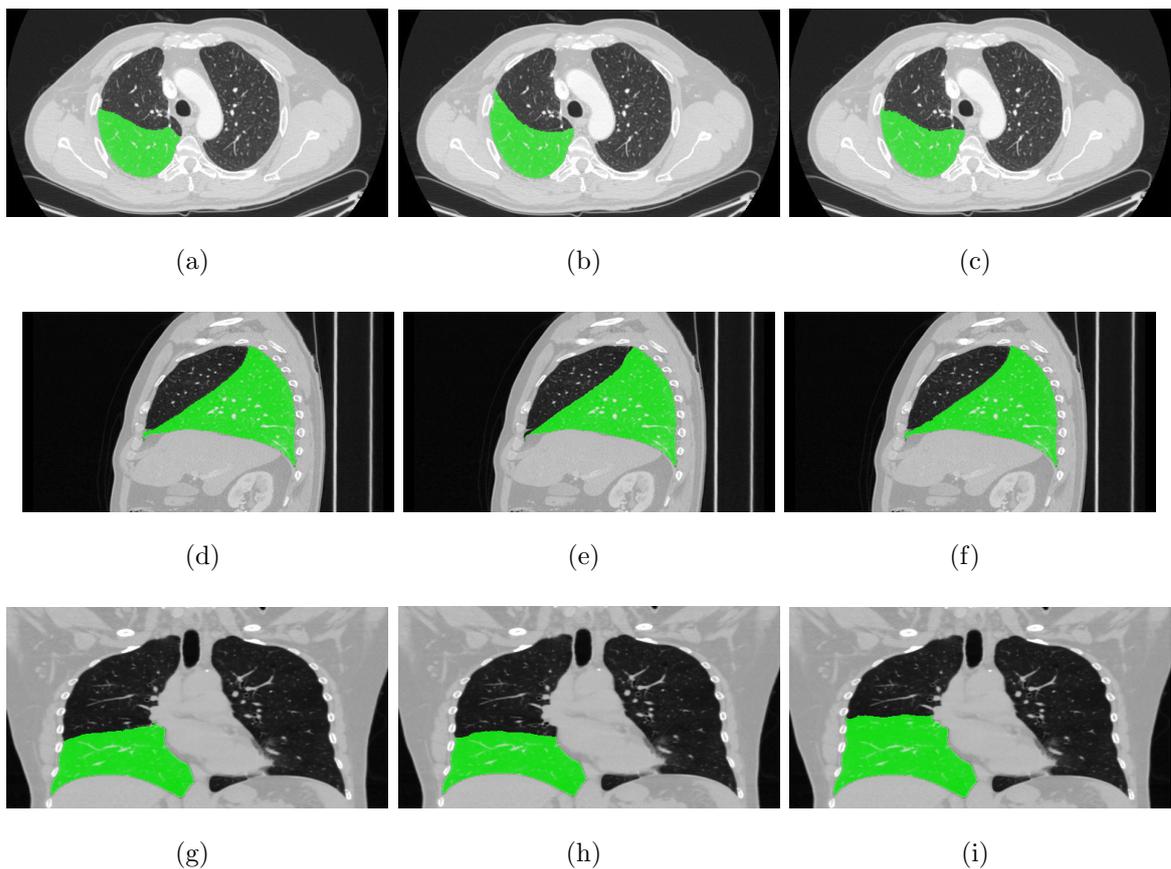


Figura 4.22: segmentação do lobo inferior direito, (a), (d) e (g) padrão ouro; segmentação dos slices correspondentes ao padrão ouro com os métodos: (b) e (e) Hessiana/Crust; (h) Hessiana/NN; (c) e (f) LBP/Crust; e (i) LBP/NN.

Os dados obtidos na segmentação do lobo inferior direito, quando comparados aos dados dos demais lobos do mesmo pulmão, comprovam a dificuldade de detecção da

fissura horizontal. Fato explicado por o lobo inferior direito, que não possui a fissura horizontal em seus limites, apresentar resultados superiores aos demais lobos do pulmão direito (superior e médio) que são separados pela fissura horizontal.

Em relação à análise comparativa entre as energias externas e malhas utilizadas, durante a demonstração das métricas, observa-se uma alternância entre melhores e piores resultados. Com o intuito de proporcionar uma análise mais conclusiva entre os métodos comparados, é apresentada a seguir a média das métricas calculadas por lobo e por fim uma média geral com os valores de μ_d , Fit_T e Fit_F para cada um dos métodos testados.

Os valores médios de μ_d , Fit_T e Fit_F , de cada um dos quatro métodos por lobo são detalhados na Tabela 4.3 e representados em gráfico nas Figuras 4.23, 4.24 e 4.25, respectivamente.

Tabela 4.3: médias de μ_d , Fit_T e Fit_F , de cada método utilizado, produzidas para cada lobo

Lobo	Hessiana/Crust			Hessiana/NN			LBP/Crust			LBP/NN		
	μ_d	Fit_T	Fit_F	μ_d	Fit_T	Fit_F	μ_d	Fit_T	Fit_F	μ_d	Fit_T	Fit_F
Sup. Esq.	1,09	0,98	0,95	1,19	0,97	0,93	1,10	0,99	0,95	1,15	0,98	0,95
Inf. Esq.	0,85	0,99	0,94	0,96	0,98	0,94	1,04	0,99	0,95	1,12	0,98	0,94
Sup. Dir.	2,75	0,95	0,87	2,68	0,95	0,87	2,36	0,97	0,90	2,40	0,96	0,88
Méd. Dir.	3,07	0,95	0,73	3,30	0,94	0,72	3,21	0,96	0,72	3,41	0,94	0,70
Inf. Dir.	1,82	0,98	0,91	1,97	0,97	0,89	1,95	0,98	0,92	2,04	0,98	0,91

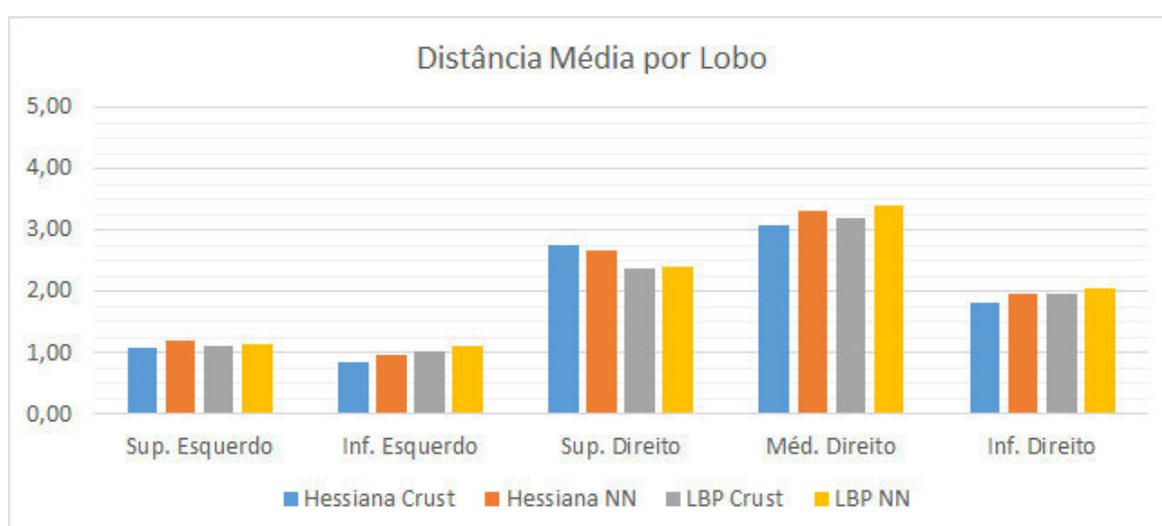


Figura 4.23: gráfico das médias de μ_d de cada método utilizado produzido para cada lobo.

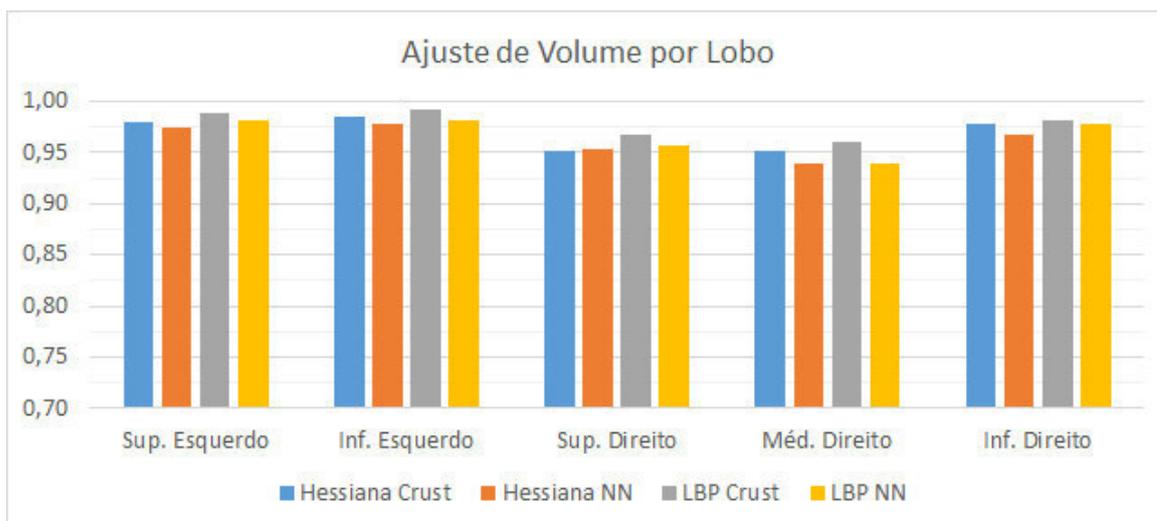


Figura 4.24: gráfico das médias de Fit_T de cada método utilizado produzido para cada lobo.

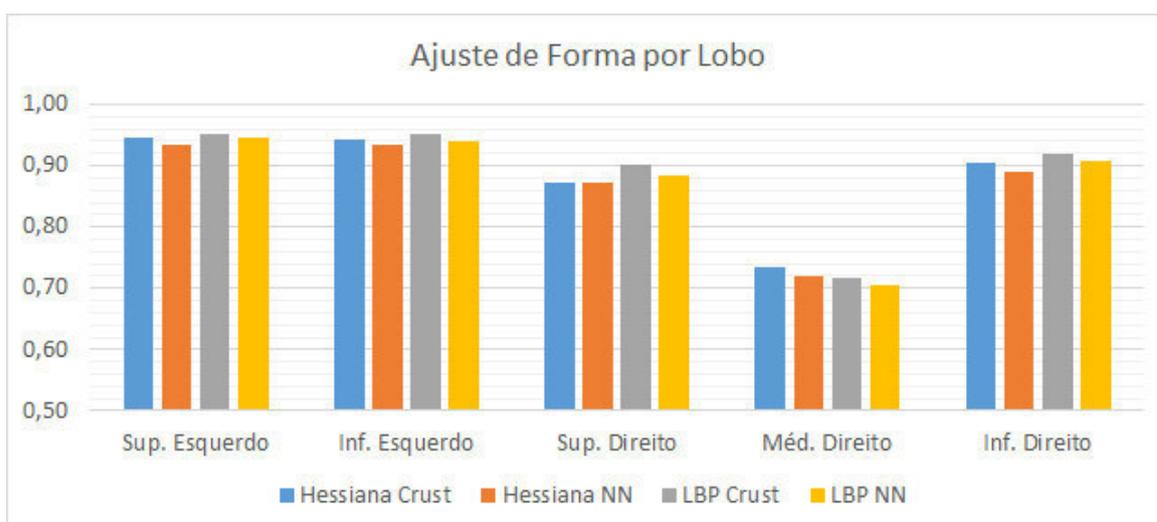


Figura 4.25: gráfico das médias de Fit_F de cada método utilizado produzido para cada lobo.

Apesar do desempenho semelhante, realizando uma análise comparativa entre os diferentes tipos de malha, dada a mesma energia externa, verifica-se que a malha Crust, em geral, apresenta métricas mais precisas. Com exceção da média de μ_d para o lobo superior direito, dos métodos com energia Hessiana, todas as demais métricas dos métodos com malha Crust têm valor ligeiramente melhor ou igual às métricas obtidas pelos métodos com malha NN, dada a mesma energia externa.

Diante disso, é possível concluir que o desempenho da malha Crust, no geral, é melhor do que desempenho da malha NN, embora a diferença, entre esta malha e as demais, seja pequena.

O desempenho da segmentação dos MSAs no pulmão esquerdo merece destaque por

apresentar valores de μ_d em torno de 1 mm, Fit_T em torno de 0,98 e Fit_F em torno de 0,94.

Dentre os lobos do pulmão direito, o lobo inferior apresenta as melhores métricas, o que já era esperado pelo fato deste lobo não possuir a fissura horizontal compondo seus limites. A fissura horizontal, por sua vez, apresenta certa complexidade para o processo de detecção, fazendo com que os lobos superior e médio do pulmão direito apresentem métricas menores em relação aos demais. O lobo médio direito é o mais afetado por possuir maior parte de sua superfície limitada pela fissura horizontal.

A seguir na Tabela 4.4 são apresentados os valores da média geral de cada métrica para os métodos testados, bem como são ilustrados das Figuras 4.26 e 4.27 gráficos comparativos com estes valores.

Tabela 4.4: média geral de μ_d , Fit_T e Fit_F para cada método testado.

	Hessiana/Crust	Hessiana/NN	LBP/Crust	LBP/NN
μ_d	1,92	2,02	1,93	2,02
Fit_T	0,97	0,96	0,98	0,97
Fit_F	0,88	0,87	0,89	0,88

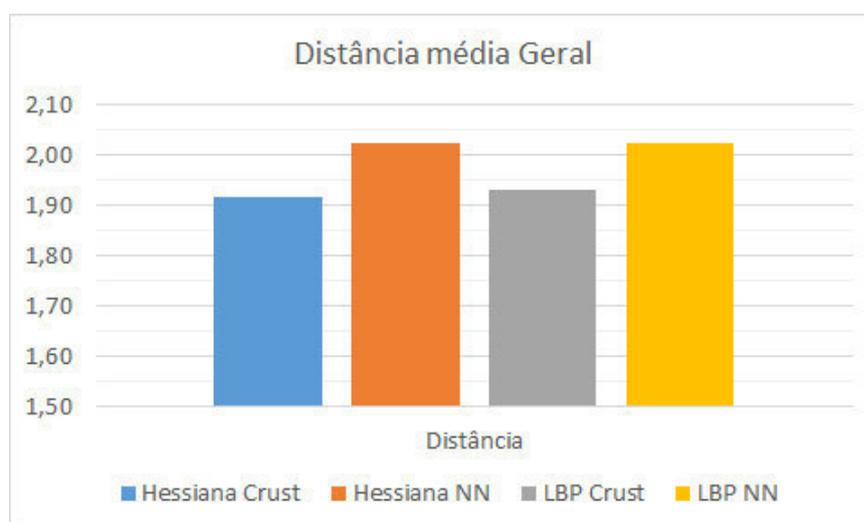


Figura 4.26: gráfico da média geral de μ_d para cada método utilizado.

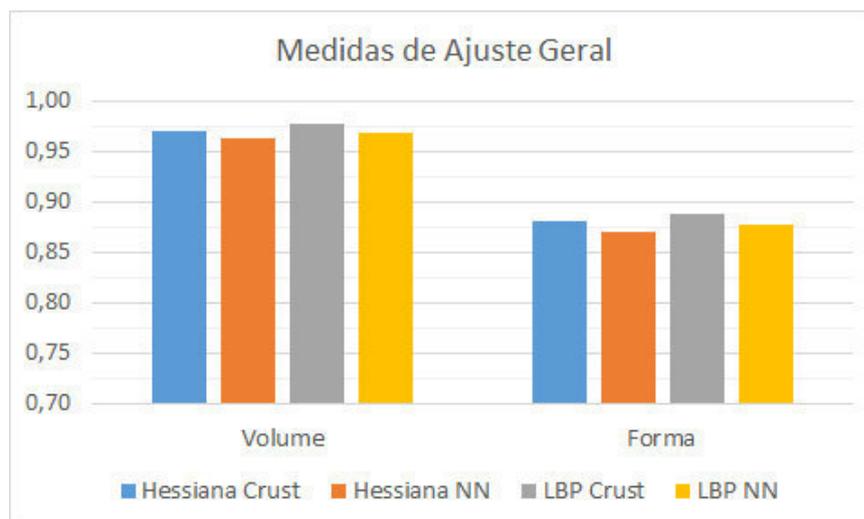


Figura 4.27: gráfico da média geral de Fit_T e Fit_F para cada método utilizado.

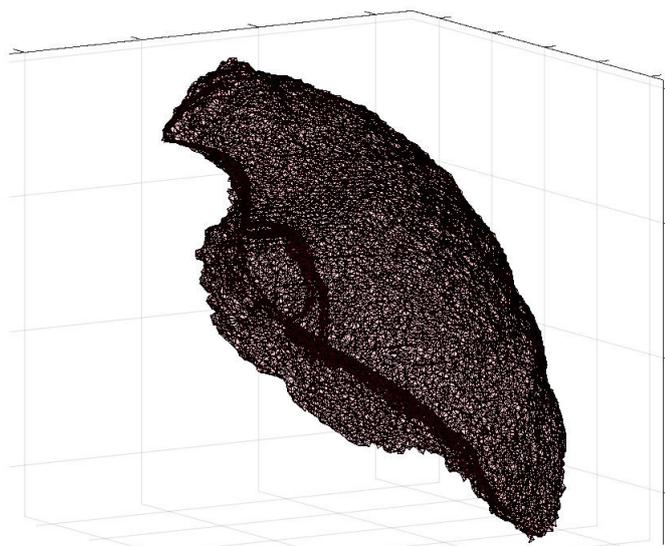
Analisando os valores gerais apresentados, conclui-se o sucesso dos métodos em relação à segmentação dos lobos pulmonares em exames de TC. A distância média em torno de 2 mm, juntamente com valores em torno de 0,97 e 0,88 para as medidas de ajuste de tamanho e de forma, respectivamente, validam os métodos de segmentação propostos nesta tese.

Os trabalhos sobre segmentação lobar em imagens de TC recorrentes na literatura utilizam bancos de imagens distintos, impossibilitando uma comparação direta das métricas obtidas entre esses. Todavia, observando os resultados apresentados na literatura é possível avaliar que a segmentação lobar realizada nesta tese está dentro do faixa de valores apresentada. Kuhnigk et al. (2005) apresenta distância média de 2,78 mm, Doel et al. (2012) obtêm distância média das fissuras de 2,85 mm, Lassen et al. (2013), Qi et al. (2014) e Wei e Hu (2014) apresentam distâncias de 2,68 mm, 2,37 mm e 1,56 mm, respectivamente. Vale lembrar que os exames utilizados nesta tese e nos trabalhos citados são todos diferentes entre si, mas as métricas apresentadas nestes trabalhos são suficientes para concluir o sucesso da segmentação lobar obtida.

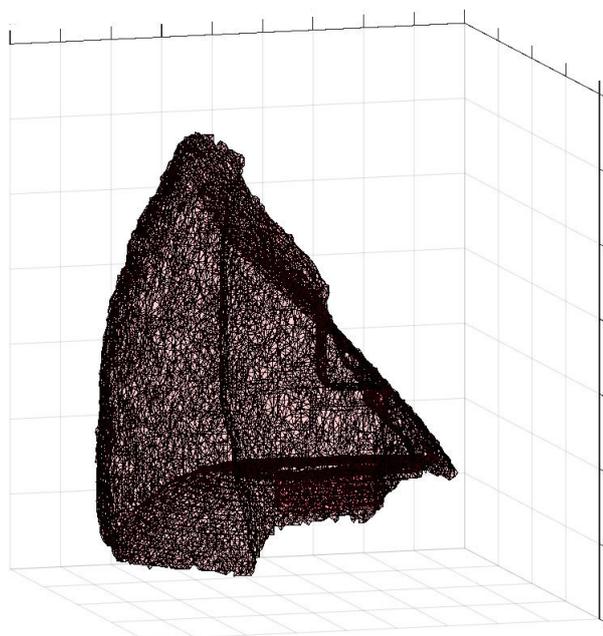
Em relação a comparação dos quatro métodos testados conclui-se que os métodos com malha Crust obtêm melhor desempenho. Além disso, é possível reafirmar uma importante contribuição desta tese, devido ao fato da energia externa LBP apresentar resultados equivalentes aos obtidos com energia externa Hessiana, obtendo inclusive medidas de ajustes levemente melhores.

Tal fato, comprova que a textura LBP utilizada é capaz de detectar as fissuras pulmonares tão bem quanto o método baseado nos autovalores da matriz Hessiana, que é recorrente na maioria dos trabalhos na literatura.

Por fim, dois exemplos da malha Crust após a evolução do MSA são ilustrados na Figura 4.28. Além deste exemplo, algumas segmentações 3D obtidas com o MSA proposto nesta tese utilizando as energias externas Hessiana e LBP com malha Crust são ilustradas nas Figuras 4.29, 4.30 e 4.31. Para o pulmão direito, em vermelho são representados os lobos superiores, em azul os lobos médios e em verde os lobos inferiores. Para o pulmão esquerdo, em magenta são representados os lobos superiores e em ciano os lobos inferiores.



(a)



(b)

Figura 4.28: visualização da malha Crust após a segmentação dos lobos por MSA (a) lobo superior esquerdo e (b) lobo inferior esquerdo.

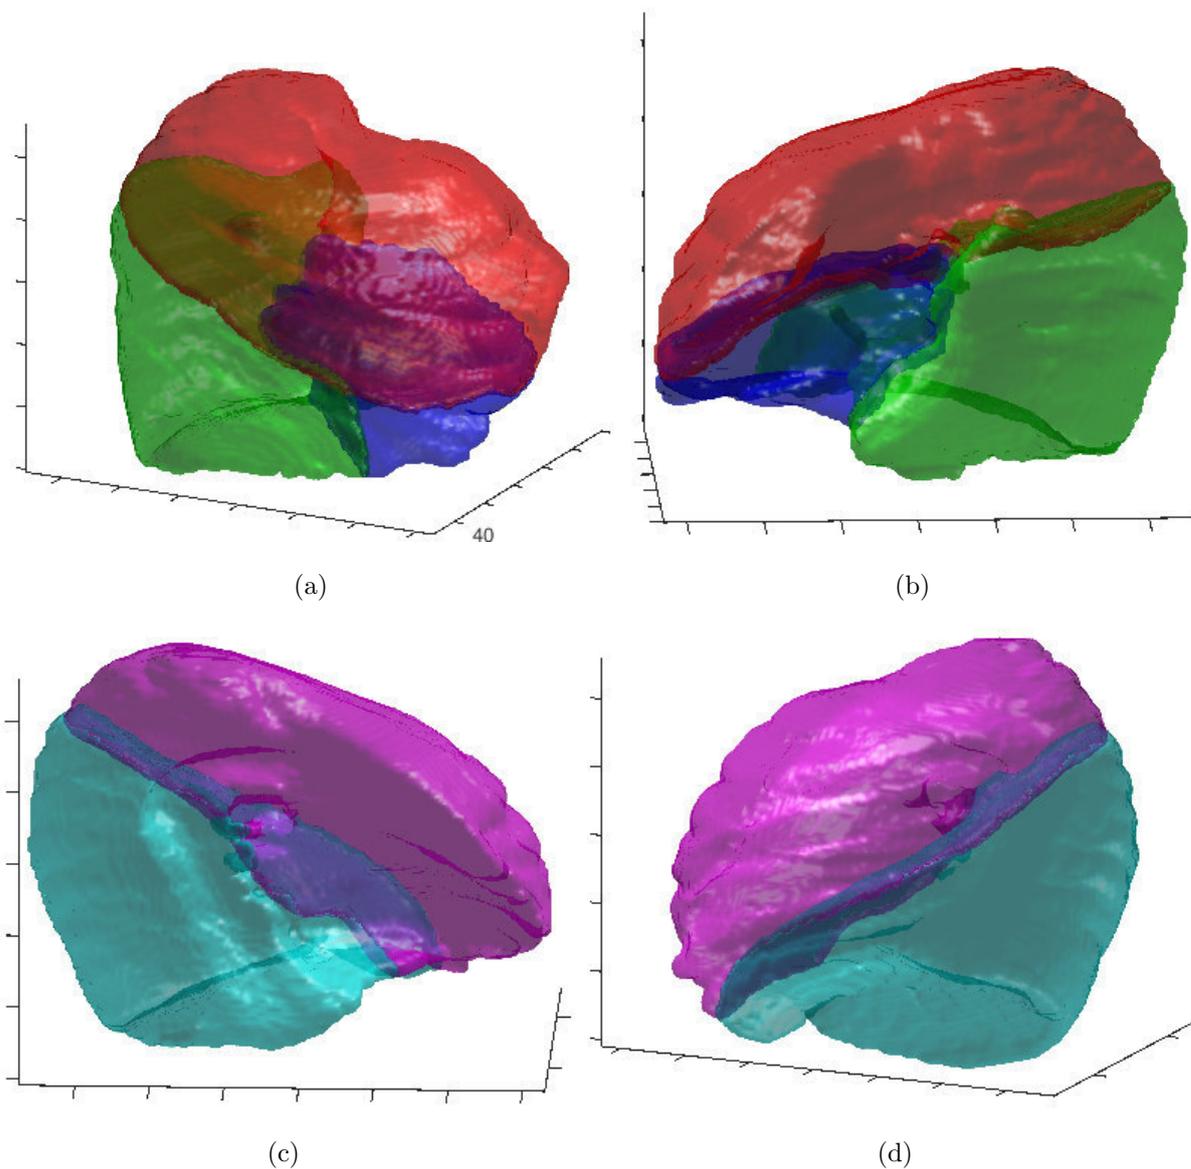


Figura 4.29: exemplo de segmentação lobar 3D por MSA com energia Hessiana e malha Crust
(a) e (b) pulmão direito, em vermelho é representado o lobo superior, em azul o lobo médio e em verde o lobo inferior; e (c) e (d) pulmão esquerdo, em magenta é representado o lobo superior e em ciano o lobo inferior.

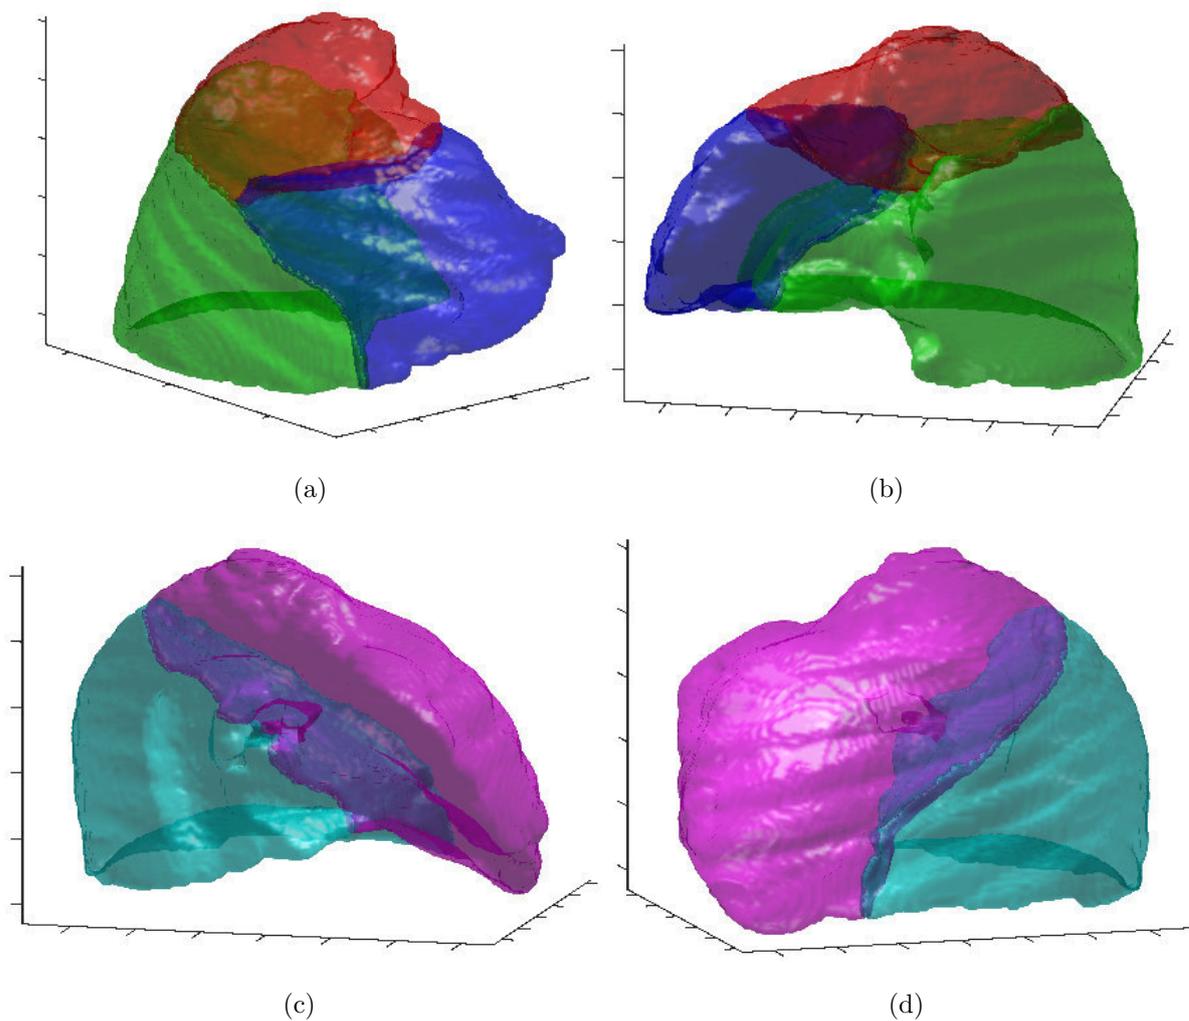


Figura 4.30: exemplo de segmentação lobar 3D por MSA com energia Hessiana e malha Crust
(a) e (b) pulmão direito, em vermelho é representado o lobo superior, em azul o lobo médio e em verde o lobo inferior; e (c) e (d) pulmão esquerdo, em magenta é representado o lobo superior e em ciano o lobo inferior.

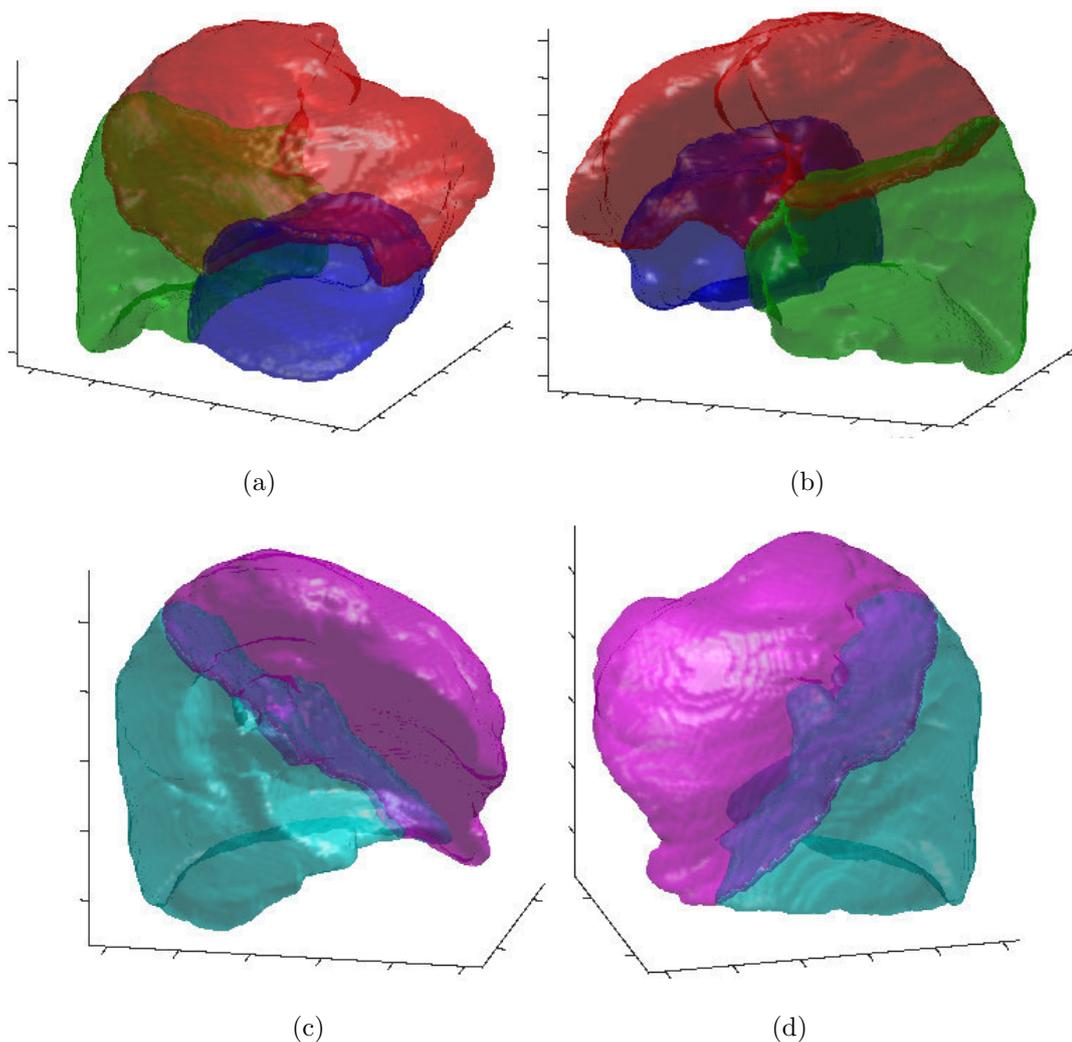


Figura 4.31: exemplo de segmentação lobar 3D por MSA com energia LBP e malha Crust (a) e (b) pulmão direito, em vermelho é representado o lobo superior, em azul o lobo médio e em verde o lobo inferior; e (c) e (d) pulmão esquerdo, em magenta é representado o lobo superior e em ciano o lobo inferior.

Além dos dados apresentados, ainda é possível, de forma subjetiva, perceber a qualidade da segmentação dos lobos pulmonares obtida nesta tese ao observar as Figuras 4.29, 4.30 e 4.31.

Com base nos resultados postos e na discussão feita, diversas conclusões e contribuições devem ser realizadas, bem como trabalhos futuros devem ser sugeridos.

Capítulo 5

Conclusões, Contribuições e Trabalhos Futuros

Nesta tese é proposto um novo MSA, para malhas estruturadas e não estruturadas, capaz de realizar a segmentação 3D automática dos lobos pulmonares em imagens de TC do tórax.

Para compor tal MSA, são propostos e descritos neste trabalho:

- método de inicialização de MSA automático para lobos pulmonares, baseado em funções de projeção;
- versões 3D para as forças de continuidade, curvatura e balão, que se adequam às malhas estruturadas e não estruturadas;
- energia externa Hessiana, baseada nos autovalores da matriz Hessiana;
- energia externa LBP, baseada na medida de textura LBP; e
- funções de adição e remoção de pontos, juntamente com critérios de parada de iteração e de ciclo.

Para verificar o desempenho do MSA proposto em malhas estruturadas e não estruturadas são realizados testes de segmentação em imagens sintéticas. Assim, são utilizadas três malhas 3D, sendo uma estruturada regular e duas não estruturadas: a malha NN e a malha Crust, derivada da malha Delaunay. Ainda no teste de segmentação de imagens sintéticas é realizada uma comparação em relação ao desempenho do MSA com força de curvatura versus o MSA com força balão. As segmentações são avaliadas de acordo com

medidas de ajuste e com as distâncias obtidas entre a superfície do objeto sintético e a superfície resultante do processo de segmentação.

Os resultados obtidos nesses testes comprovaram que o MSA proposto funciona adequadamente tanto para malhas estruturadas como para malhas não estruturadas, apresentando para todos os objetos sintéticos testados, diversos casos com medidas de ajuste FIT_T e FIT_F maiores que 0,95 e distâncias médias μ_d menores que 1 voxel. No geral, as malhas não estruturadas obtêm resultados melhores do que a malha estruturada, o que já era esperado devido a flexibilidade intrínseca das malhas não estruturadas.

Em relação à comparação entre a força de curvatura e força balão, é possível concluir que objetos com cantos ou arestas que apresentam ângulos internos reduzidos não são adequadamente segmentados pelo MSA com força de curvatura, uma vez que estes cantos e arestas são preteridos por tal força, não permitindo uma configuração de energia mínima para a superfície nestas regiões.

Todavia, vale ressaltar a diferença de comportamento do MSA com cada força. Enquanto o MSA com força de curvatura atua retraindo a superfície, o MSA com força balão atua expandido esta superfície. Assim, em casos que o objeto deve ser segmentado pelo lado externo, o uso da força de curvatura é recomendado. Já em casos que a segmentação deve ser feita a partir do interior do objeto, a força balão deve ser utilizada.

Uma vez verificada tais propriedades, a segmentação automática dos lobos pulmonares é realizada. Para tal, é proposto um método de inicialização automática de MSA. Tal método utiliza funções de projeção que reduzem um espaço 3D para 2D, bem como reduzem espaços 2D para 1D. Dessa forma, é calculada com precisão uma coordenada interna a cada um dos cinco lobos pulmonares e em seguida superfícies iniciais para o MSA são geradas em torno destas coordenadas.

Para validar a acurácia do método de inicialização proposto, é verificado se a superfície gerada possui toda sua extensão no interior do lobo correspondente, ou seja, se qualquer trecho da superfície estiver fora do pulmão ou em alguma região que pertença a outro lobo a inicialização é considerada errada. Para as 50 inicializações realizadas, apenas três referentes ao lobo médio direito são consideradas erradas, perfazendo um acerto geral de 94%. Vale ressaltar que os exames de dois dos três casos considerados errados não apresentam a fissura horizontal, não permitindo a identificação do lobo médio direito.

Para que o MSA realize uma segmentação correta dos lobos pulmonares, é necessário lhe atribuir uma energia externa que represente de forma adequada estes lobos. Nesse sentido, são utilizados dois tipos de energia externa para realizar tal representação. Um

dos tipos, denominado energia Hessiana, baseia-se nos autovalores da matriz Hessiana, técnica recorrente na literatura. A segunda energia externa, denominada energia LBP, utiliza a classificação por MLP de medidas texturas LBP para realizar a representação dos limites dos lobos pulmonares.

Por fim, são realizados testes para validar a segmentação dos lobos pulmonares obtida pelo MSA proposto. Para realizar tal validação, um padrão ouro é desenvolvido por uma junta médica. Este padrão é composto de 12 slices por exames em um total de 10 exames de TC, contidos no banco LIDC-IDRI. Desta forma, métricas de avaliação são calculadas comparando os slices do padrão ouro com os slices correspondentes da segmentação.

Nos testes de segmentação lobar, são comparados quatro versões do MSA que se diferenciam entre si pelo tipo energia externa e malha utilizada, sendo estes: MSA com energia Hessiana e malha NN, MSA com energia Hessiana e malha Crust, MSA com energia LBP e malha NN e MSA com energia LBP e malha Crust.

Os valores obtidos, em geral menores do que os valores observados na literatura pesquisada, retratam uma segmentação lobar relevante com distância média em torno de 2 mm ; e ajuste de tamanho e de forma em torno de 0,97 e 0,88, respectivamente. Apesar das medidas de ajuste serem bastante próximas, os valores obtidos na distância média geral revelam uma superioridade dos MSAs com malha Crust que obtêm 1,92 e 1,93 mm para as energias Hessiana e LBP, respectivamente. Já os MSAs com malha NN obtêm 2,02 mm em ambas as energias.

Em relação à comparação de desempenho entre as energias externas propostas, percebe-se certa semelhança. O MSA com energia Hessiana e malha Crust apresenta 1,92 mm para a distância média geral e 0,97 e 0,88 para as medidas de ajuste FIT_T e FIT_F respectivamente. O MSA com energia LBP e malha Crust apresenta 1,93 mm para a distância média geral e 0,98 e 0,89 para as medidas de ajuste FIT_T e FIT_F respectivamente.

Diante do exposto, conclui-se que a energia externa LBP proposta nesta tese representa os limites dos lobos pulmonares tão bem quanto à energia Hessiana, que é baseada em técnica recorrente na literatura. Além disto, uma breve comparação é realizada entre as medidas obtidas nesta tese e medidas de outros trabalhos presente na literatura. Vale ressaltar que os exames utilizados nesta tese e nos trabalhos citados são todos diferentes entre si, o que impossibilita uma comparação direta das métricas obtidas entre os mesmos. Todavia, as métricas apresentadas nestes trabalhos são suficientes par validar e concluir o sucesso da segmentação lobar obtida nesta tese.

O sucesso da segmentação por MSA, bem como da representação da superfície lobar

com textura LBP, estimulam o desenvolvimento de pesquisas que podem ser sugeridas como trabalhos futuros, como por exemplo:

- estudo do impacto de outros tipos de malhas estruturadas e não estruturadas no processo de segmentação por MSA;
- estudo de variações da textura LBP para detecção de fissuras;
- investigação de algoritmos de inteligência artificial para classificação dos padrões LBP na detecção de fissuras pulmonares;
- investigação de Transformada de Hilbert e matriz Hilbertiana na detecção de fissuras pulmonares;
- levantamento e análise de tempo de processamento e eficiência de métodos de segmentação lobar;
- implementação de métodos de segmentação lobar em unidade de processamento gráfico;
- investigação de aplicações e desempenho de MSAs com força de curvatura e MSAs com força balão em conjunto;
- adicionar funcionalidades de detecção de erro ao método de inicialização proposto;
e
- integração do método proposto ao Sistema de Análise de Imagens Pulmonares (LISA), registrado para fins de pesquisa na área médica.

Referências Bibliográficas

ALEXANDRIA, A. R.; CORTEZ, P. C.; BESSA, J. B.; FÉLIX, J. H. S.; ABREU, J. S.; ALBUQUERQUE, V. H. C. psnakes: A new radial active contour model and its application in the segmentation of the left ventricle from echocardiographic images. *Computer Methods and Programs in Biomedicine*, v. 116, n. 3, p. 260–273, 2014.

ALEXANDRIA, A. R.; CORTEZ, P. C.; FELIX, J. H. S.; ABREU, J. S. Método de contornos ativos psnakes aplicado em imagens de ecocardiograma de eixo curto para cálculo de fração de ejeção. *Revista Brasileira de Engenharia Biomédica*, v. 27, n. 3, p. 147–162, 2011.

ALMEIDA, M. A. *Repercussões agudas da ventilação não invasiva sobre o fluxo sanguíneo cerebral e a função cognitiva de pacientes com doença pulmonar obstrutiva crônica e indivíduos saudáveis*. Tese (Doutorado) — Universidade Federal do Ceará, 2011.

AMENTA, N.; BERN, M.; KAMVYSSELIS, M. A new voronoi-based surface reconstruction algorithm. In: *Proceedings of the ACM SIGGRAPH Conference on Computer Graphics*. 1998. p. 19–24.

AMINI, A.; WEYMOUTH, T.; JAIN, R. Using dynamic programming for solving variational problems in vision. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 12, n. 9, p. 855–867, 1990.

ANTON, H.; BIVENS, I.; DAVIS, S. *Calculus: Late Transcendentals Single And Multivariable*. 8. ed. : John Wiley Professio, 2005.

ARMATO, S.; MCLENNAN, G.; BIDAUT, L.; MCNITT-GRAY, M.; MEYER, C.; REEVES, A.; ZHAO, B.; ABERLE, D.; HENSCHKE, C.; HOFFMAN, E.; KAZEROONI, E.; MACMAHON, H.; BEEKE, E. V.; YANKELEVITZ, D.; BIANCARDI, A.; BLAND, P.; BROWN, M.; ENGELMANN, R.; LADERACH, G.; MAX, D.; PAIS, R.; QING, D.; ROBERTS, R.; SMITH, A.; STARKEY, A.; BATRAH, P.; CALIGIURI, P.; FAROOQI, A.; GLADISH, G.; JUDE, C.; MUNDEN,

R.; PETKOVSKA, I.; QUINT, L.; SCHWARTZ, L.; SUNDARAM, B.; DODD, L.; FENIMORE, C.; GUR, D.; PETRICK, N.; FREYMAN, J.; KIRBY, J.; HUGHES, B.; CASTEELE, A.; GUPTE, S.; SALLAM, M.; HEATH, M.; KUHN, M.; DHARAIYA, E.; BURNS, R.; FRYD, D.; SALGANICOFF, M.; ANAND, V.; SHRETER, U.; VASTAGH, S.; CROFT, B. The lung image database consortium (lidc) and image database resource initiative (idri): a completed reference database of lung nodules on ct scans. *Medical Physics*, v. 38, n. 2, p. 915–931, Feb 2011.

ARROYO, M.; DESIMONE, A. Shape control of active surfaces inspired by the movement of euglenids. *Journal of the Mechanics and Physics of Solids*, v. 62, p. 99–112, 2014.

BARBOSA, D.; DIETENBECK, T.; HEYDE, B.; HOULE, H.; FRIBOULET, D.; DHOOGHE, J.; BERNARD, O. Fast and fully automatic 3-d echocardiographic segmentation using b-spline explicit active surfaces: Feasibility study and validation in a clinical setting. *Ultrasound in Medicine and Biology*, v. 39, n. 1, p. 89–101, 2013.

BARBOSA, D.; DIETENBECK, T.; SCHAERER, J.; DHOOGHE, J.; FRIBOULET, D.; BERNARD, O. B-spline explicit active surfaces: An efficient framework for real-time 3-d region-based segmentation. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, v. 21, n. 1, 2012.

BARBOSA, D.; HEYDE, B.; CIKES, M.; DIETENBECK, T.; CLAUS, P.; FRIBOULET, D.; BERNARD, O.; D'HOOGHE, J. Real-time 3d interactive segmentation of echocardiographic data through user-based deformation of b-spline explicit active surfaces. *Computerized Medical Imaging and Graphics*, v. 38, n. 1, p. 57 – 67, 2014. ISSN 0895-6111. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0895611113001493>>.

BAYAT, S. *Direct Structured Finite Element Mesh Generation from Three-dimensional Medical Images of the Aorta*. Tese (Doutorado) — University of Ottawa (CA), 2014.

BERCOVIER, M.; PIRONNEAU, O.; SASTRI, V. Finite elements and characteristics for some parabolic-hyperbolic problems. *Applied Mathematical Modelling*, v. 7, n. 2, p. 89–96, 1983.

BERG, G.; JULIAN, W.; MINES, R.; RICHMAN, F. The constructive jordan curve theorem. *Rocky Mountain Journal of Mathematics*, n. 2, p. 225–236, 1975.

- BESSA, J. A.; CORTEZ, P. C.; FELIX, J. H. S.; NETO, A. R. R.; ALEXANDRIA, A. R. Radial snakes: Comparison of segmentation methods in synthetic noisy images. *Expert Systems with Applications*, v. 42, n. 6, p. 3079–3088, 2015.
- BI, L.; KIM, J.; WEN, L.; FENG, D. Automatic descending aorta segmentation in whole-body pet-ct studies for percist-based thresholding. In: *Digital Image Computing Techniques and Applications (DICTA), 2012 International Conference on*. 2012. p. 1–6.
- BIRKFELLNER, W. *Applied Medical Image Processing*. 2nd. ed. : CRC Press, 2015.
- BONO, G.; AWRUCH, A. M. Numerical study between structured and unstructured meshes for euler and navier-stokes equations. In: ELASKAR, S. A.; PILOTTA, E. A.; TORES, G. A. (Ed.). *Mecanica Computacional Vol XXVI*. 2007. v. 26, p. 3134–3146.
- BONTRAGER, K. L. *Tratado de Técnica Radiológica e Base Anatômica*. : Guanabara Koogan, 2000.
- BOTSCH, M.; KOBELT, L.; PAULY, M.; ALLIEZ, P.; LEVY, B. *Polygon Mesh Processing*. : AK Peters, 2010. ISBN 978-1-56881-426-1.
- BRADSHAW, A.; TAUBMAN, D.; TODD, M.; MAGNUSSEN, J.; HALMAGYI, G. Augmented active surface model for the recovery of small structures in ct. *Image Processing, IEEE Transactions on*, v. 22, n. 11, p. 4394–4406, Nov 2013. ISSN 1057-7149.
- CANNY, J. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8, n. 6, p. 679–698, 1986.
- CAVALCANTE, T. S.; CORTEZ, P. C.; ALMEIDA, T. M.; FELIX, J. H. S.; HOLANDA, M. A. Segmentação automática 2d de vias aéreas em imagens de tomografia computadorizada do tórax. *Revista Brasileira de Engenharia Biomédica*, v. 29, n. 4, p. 389–403, 2013. Disponível em: <<http://rbeb.org.br/articles/view/id/52caafc75ce02ae779000000>>.
- CAVALCANTI NETO, E. *SFPT Neural: nova técnica de segmentação de fissuras pulmonares em imagens de Tomografia Computadorizada baseada em Texturas*. Dissertação (Dissertação (Mestrado)) — Universidade Federal do Ceará, 2014.
- CHEN, B. Y. An explicit formula of hessian determinants of composite functions and its applications. *Kragujevac Journal of Mathematics*, v. 36, n. 1, p. 27–39, 2012.
- CHEN, M.; TU, B.; LU, B. Surface triangular mesh and volume tetrahedral mesh generations for biomolecular modeling. In: ZHANG, Y. (Ed.). *Image-Based Geometric*

Modeling and Mesh Generation. : Springer Netherlands, 2013, (Lecture Notes in Computational Vision and Biomechanics, v. 3). p. 85–106.

CHENG, J.; FOO, S. W. Dynamic directional gradient vector flow for snakes. *IEEE Transactions on Image Processing*, v. 15, n. 6, p. 1563–1571, 2006.

CHERNIKOV, A. N.; FOTEINOS, P. A.; LIU, Y.; AUDETTE, M.; ENQUOBAHRIE, A.; CHRISOCHOIDES, N. P. Tetrahedral image-to-mesh conversion approaches for surgery simulation and navigation. In: ZHANG, Y. (Ed.). *Image-Based Geometric Modeling and Mesh Generation.* : Springer Netherlands, 2013, (Lecture Notes in Computational Vision and Biomechanics, v. 3).

CHIN, S. W.; SENG, K. P.; ANG, L. M. Lips contour detection and tracking using watershed region-based active contour model and modified h. *Circuits and Systems for Video Technology, IEEE Transactions on*, v. 22, n. 6, p. 869–874, 2012.

COHEN, L.; COHEN, I. Finite-element methods for active contour models and balloons for 2-d and 3-d images. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 15, n. 11, p. 1131–1147, 1993.

COHEN, L. D. On active contour models and balloons. *CVGIP: Image Understanding*, v. 53, n. 2, p. 211–218, 1991. Disponível em: <<http://www.sciencedirect.com/science/article/pii/104996609190028N>>.

COOK, D.; MUELLER, M.; FEDELE, F.; YEZZI, A. Adjoint active surfaces for localization and imaging. *Image Processing, IEEE Transactions on*, v. 24, n. 1, p. 316–331, 2015.

CRONIN, P.; GROSS, B. H.; KELLY, A. M.; PATEL, S.; KAZEROONI, E. A.; CARLOS, R. C. Normal and accessory fissures of the lung: Evaluation with contiguous volumetric thin-section multidetector ct. *European Journal of Radiology*, v. 75, n. 2, p. e1–e8, 2010.

CULA, O. G.; DANA, K. J. Compact representation of bidirectional texture functions. In: *Computer Vision and Pattern Recognition, 2001. CVPR 2001. Proceedings of the 2001 IEEE Computer Society Conference on*. 2001. v. 1, p. 1041–1047.

DAROLTI, C.; MERTINS, A.; BODENSTEINER, C.; HOFMANN, U. Local region descriptors for active contours evolution. *Image Processing, IEEE Transactions on*, v. 17, n. 12, p. 2275–2288, 2008.

- DELAUNAY, B. Sur la sphere vide, izvestia akademii nauk sssr. *Otdelenie Matematicheskikh i Estestvennykh Nauk*, v. 7, p. 793–800, 1934.
- DELGADO-GONZALO, R.; CHENOUDARD, N.; UNSER, M. Spline-based deforming ellipsoids for interactive 3d bioimage segmentation. *Image Processing, IEEE Transactions on*, v. 22, n. 10, p. 3926–3940, Oct 2013. ISSN 1057-7149.
- DELIBASIS, K. K.; ASVESTAS, P. A.; KECHRINIOTIS, A. I.; MATSOPOULOS, G. K. An implicit evolution scheme for active contours and surfaces based on {IIR} filtering. *Computers in Biology and Medicine*, v. 48, n. 0, p. 42 – 54, 2014. ISSN 0010-4825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010482514000389>>.
- DELIBASIS, K. K.; KECHRINIOTIS, A.; MAGLOGIANNIS, I. A novel tool for segmenting 3d medical images based on generalized cylinders and active surfaces. *Computer Methods and Programs in Biomedicine*, v. 111, n. 1, p. 148–165, 2013a.
- DELIBASIS, K. K.; TASSANI, S.; ASVESTAS, P.; KECHRINIOTIS, A. I.; MATSOPOULOS, G. K. A fourier-based implicit evolution scheme for active surfaces, for object segmentation in volumetric images. *Measurement Science and Technology*, v. 24, n. 7, 2013b.
- DELMAS, P.; COULON, P. Y.; FRISTOT, V. Automatic snakes for robust lip boundaries extraction. In: *EEE International Conference on Acoustics, Speech, and Signal Processing-ICASSP*. 1999.
- DELVES, L. M.; WILKINSON, R.; OLIVER, C. J.; WHITE, R. G. Comparing the performance of sar image segmentation algorithms. *International Journal of Remote Sensing*, v. 13, n. 11, p. 2121–2149, 1992.
- DEVAKI, K.; MURALIBHASKARAN, V.; MOHAN, M. Segment segmentation in lung ct images. *Special Issue of International Journal on Advanced Computer Theory and Engineering*, v. 2, n. 1, 2013.
- DOEL, T.; MATIN, T.; GLEESON, F.; GAVAGHAN, D.; GRAU, V. Pulmonary lobe segmentation from ct images using fissureness, airways, vessels and multilevel b-splines. In: *Biomedical Imaging (ISBI), 2012 9th IEEE International Symposium on*. 2012. p. 1491–1494. ISSN 1945-7928.
- DUFOUR, A.; THIBEAUX, R.; LABRUYERE, E.; GUILLEN, N.; OLIVO-MARIN, J.-C. 3-d active meshes: Fast discrete deformable models for cell tracking in 3-d

time-lapse microscopy. *Image Processing, IEEE Transactions on*, v. 20, n. 7, p. 1925–1937, 2011.

ELLIS, S. M.; FLOWER, C. *The WHO manual of diagnostic imaging - Radiographic Anatomy and Interpretation of the Chest and the Pulmonary System.* : World Health Organization, 2006.

EPSTEIN, C. L. *Introduction to the Mathematics of Medical Imaging.* 2nd. ed. : SIAM, 2007.

FAN, Y.; JIANG, T.; EVANS, D. Volumetric segmentation of brain images using parallel genetic algorithms. *Medical Imaging, IEEE Transactions on*, v. 21, n. 8, p. 904–909, Aug 2002. ISSN 0278-0062.

FELIX, J.; CORTEZ, P.; CAVALCANTE, T.; ALEXANDRIA, A.; HOLANDA, M. Autoin: Method of automatic initialization of active contours applied to lungs in ct images. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, v. 10, n. 4, p. 1954–1960, June 2012. ISSN 1548-0992.

FÉLIX, J. H. S. *Métodos de Contornos Ativos Hilbert 2D Aplicados na Segmentação de Imagem dos Pulmões em Tomografia Computadorizada do Tórax.* Tese (Tese (Doutorado)) — Universidade Federal do Ceará, Março 2011.

FENG, G.; YUEN, P. Variance projection function and its application to eye detection for human face recognition. *Pattern Recognition Letters*, v. 19, 1998.

FETITA, C.; ORTNER, M.; BRILLET, P.; PRETEUX, F.; GRENIER, P. A. Volumetric quantification of airway wall in ct via collision-free active surface model: Application to asthma assessment. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, v. 33, n. 7, 2014.

FRANGI, A.; NIESSEN, W.; VINCKEN, K.; VIERGEVER, M. Multiscale vessel enhancement filtering. In: WELLS, W.; COLCHESTER, A.; DELP, S. (Ed.). *Medical Image Computing and Computer-Assisted Intervention.* Springer Berlin Heidelberg, 1998, (Lecture Notes in Computer Science, v. 1496). p. 130–137. ISBN 978-3-540-65136-9. Disponível em: <<http://dx.doi.org/10.1007/BFb0056195>>.

FUSHMAN, D. D.; ANTANI, S.; CRAMER, J. K.; MULLER, H. A decade of community-wide efforts in advancing medical image understanding and retrieval. *Computerized Medical Imaging and Graphics*, v. 39, 2015.

- GEFEN, A. *Patient-Specific Modeling in Tomorrow's Medicine*. : Springer, 2012.
- GEVENOIS, P. A.; YERNAULT, J. C. Can computed tomography quantify pulmonary emphysema. *European Respiratory Journal*, n. 5, p. 843–848, janeiro 1995.
- GODWIN, J. D.; TARVER, R. D. Accessory fissures of the lung. *American Journal of Roentgenology*, v. 144, n. 1, p. 39–47, 1985.
- GONÇALVES, N. D. F. *Metodo dos Volumes Finitos em Malhas Nao-Estruturadas*. Dissertação (Mestrado) — Faculdade de Ciencias da Universidade do Porto, 2007.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing*. 3rd. ed. : Prentice Hall, 2008.
- GOURDON, A. Simplification of irregular surfaces meshes in 3d medical images. In: AYACHE, N. (Ed.). *Computer Vision, Virtual Reality and Robotics in Medicine*. : Springer Berlin Heidelberg, 1995, (Lecture Notes in Computer Science, v. 905).
- GU, S.; FUHRMAN, C.; MENG X. SIEGFRIED, J. M.; GUR, D.; LEADER, J. K.; SCIURBA, F. C.; PU, J. Computerized identification of airway wall in ct examinations using a 3d active surface evolution approach. *Medical Image Analysis*, v. 17, n. 3, p. 283–296, 2013.
- HARANGI, B.; HAJDU, A. Automatic exudate detection by fusing multiple active contours and regionwise classification. *Computers in Biology and Medicine*, v. 54, p. 156–171, Nov 2014.
- HAYKIN, S. O. *Neural Networks and Learning Machines*. : Pearson Prentice Hall, 2008.
- HE, L.; PENG, Z.; EVERDING, B.; WANG, X.; HAN, C. Y.; WEISS, K. L.; WEE, W. G. A comparative study of deformable contour methods on medical image segmentation. *Image and Vision Computing*, v. 26, n. 2, p. 141 – 163, 2008. ISSN 0262-8856. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0262885607001230>>.
- HEIMANN, T.; MEINZER, H.-P. Statistical shape models for 3d medical image segmentation: A review. *Medical Image Analysis*, v. 13, n. 4, p. 543 – 563, 2009. ISSN 1361-8415. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841509000425>>.
- HONG, Q.; LI, Q.; WANG, B.; LI, Y.; YAO, J.; LIU, K.; WU, Q. 3d vasculature segmentation using localized hybrid level-set method. *BioMedical Engineering*

OnLine, v. 13, 2014. Disponível em: <<http://www.biomedical-engineering-online.com/content/13/1/169>>.

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

INCA. Instituto nacional de câncer ministério da saúde. Brasília: Ministério da Saúde, august 2014.

INCA. Estimativa 2016. incidência de câncer no brasil. *Instituto Nacional de Câncer Ministério da Saúde*, 2016.

JAOUEN, V.; GONZALEZ, P.; STUTE, S.; GUILLOTEAU, D.; BUVAT, I.; TAUBER, C. Vector-based active surfaces for segmentation of dynamic pet images. In: *Biomedical Imaging (ISBI), 2013 IEEE 10th International Symposium on*. 2013.

KALENDER, W. A. Review: X-ray computed tomography. *Physics in Medicine and Biology*, v. 51, n. 13, p. 29–43, junho 2006.

KALLEMEYN, N. A.; SHIVANNA, K. H.; DEVRIES, N. A.; KODE, S.; GANDHI, A. A.; FREDERICKS, D. C.; SMUCKER, J. D.; GROSLAND, N. M. Advancements in spine fe mesh development: Toward patient-specific models. In: GEFEN, A. (Ed.). *Patient-Specific Modeling in Tomorrow's Medicine*. : Springer Berlin Heidelberg, 2012, (Studies in Mechanobiology, Tissue Engineering and Biomaterials, v. 09). p. 75–101.

KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes:active contours models. *International Journal of Computer Vision*, v. 1, 1987.

KHOSHNIAT, M.; STUHNE, G.; STEINMAN, D. Relative performance of geometric search algorithms for interpolating unstructured mesh data. In: ELLIS, R.; PETERS, T. (Ed.). *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2003*. : Springer Berlin Heidelberg, 2003, (Lecture Notes in Computer Science, v. 2879).

KRINIDIS, S.; CHATZIS, V. Fuzzy energy-based active contours. *Image Processing, IEEE Transactions on*, v. 18, n. 12, p. 2747–2755, 2009.

KUHNIGK, J. M. *Quantitative analysis of lung morphology and function in computed tomographic images*. Tese (Doutorado) — Univ. Bremen, Alemanha, 2008.

KUHNIGK, J.-M.; DICKEN, V.; ZIDOWITZ, S.; BORNEMANN, L.; KUEMMERLEN, B.; KRASS, S.; PEITGEN, H.-O.; YUVAL, S.; JEND, H.-H.; RAU, W. S.;

- ACHENBACH, T. New tools for computer assistance in thoracic ct. part 1. functional analysis of lungs, lung lobes, and bronchopulmonary segments. *RadioGraphics*, v. 25, n. 2, p. 525–536, 2005. PMID: 15798068.
- KUMAR., S. N.; KAVITHA, V. Automatic segmentation of lung lobes and fissures for surgical planning. In: *International Conference on Emerging Trends in Electrical and Computer Technology*. 2011.
- LANG, S. *Calculo Vol. 2.* : Livros Tecnicos e Cientificos Editora S.A., 1975.
- LASSEN, B.; RIKXOORT, E. M. van; SCHIMIDT, M.; KERKSTRA, S.; GINNEKEN, B. van; KUHNIGK, J.-M. Automatic segmentation of the pulmonary lobes from chest ct scans based on fissures, vessels, and bronchi. *IEEE Transactions on Medical Imaging*, v. 32, p. 210–222, 2013.
- LEUNG, T.; MALIK, J. Representing and recognizing the visual appearance of materials using three-dimensional textures. *International Journal of Computer Vision*, v. 43, n. 1, p. 29–44, 2001.
- LI, B.; ACTON, S. Vector field convolution for image segmentation using snakes. In: *IEEE International Conference on Image Processing*. 2006. p. 1637–1640.
- 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, 2007.
- LI, B.; CHRISTENSEN, G. E.; HOFFMAN, E. A.; MCLENNAN, G.; REINHARDT, J. M. Establishing a normative atlas of the human lung. *Academic Radiology*, v. 10, n. 3, p. 255–265, 2003.
- 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*. 2008. v. 2, n. 1.
- LIMA, E. L. *Curso de Analise Vol. 2.* : IMPA, 1985.
- LO, S. H. *Finite Element Mesh Generation.* : CRC Press, 2014.
- 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.

- MACKIEWICH, B. *Intracranial boundary detection and radio frequency correction in magnetic resonance images*. Dissertação (Mestrado) — School of Computing Science, Citeseer, 1995.
- MAENPAA, T.; PIETIKAINEN, M. Texture analysis with local binary patterns. *Handbook of Pattern Recognition and Computer Vision*, 2005.
- MAHESH, M. The aapm/rsna physics tutorial for residents. *RadioGraphics*, v. 22, n. 4, p. 949–962, 2002.
- MATHERS, C. D.; LONCAR, D. Projections of global mortality and burden of disease from 2002 to 2030. *PLOS Medicine*, 2006.
- MCINERNEY, T.; TERZOPOULOS, D. Deformable models in medical image analysis. In: *Mathematical Methods in Biomedical Image Analysis, 1996., Proceedings of the Workshop on*. 1996. p. 171–180.
- MCINERNEY, T.; TERZOPOULOS, D. T-snakes: Topology adaptive snakes. *Medical Image Analysis*, v. 4, n. 2, p. 73–91, 2000.
- MEDEIROS, C. M. de S. *Uma Contribuição ao Problema de Seleção de Modelos Neurais Usando e Princípio de Máxima Correlação dos Erros*. Tese (Doutorado) — Universidade Federal do Ceará, 2008.
- MISHRA, A.; FIEGUTH, P.; CLAUSI, D. Decoupled active surface for volumetric image segmentation. In: *Computer and Robot Vision (CRV), 2010 Canadian Conference on*. 2010. p. 293–300.
- MOORE, P.; MOLLOY, D. A survey of computer-based deformable models. In: *Machine Vision and Image Processing Conference, 2007. IMVIP 2007. International*. 2007. p. 55–66.
- MURATA, N.; YOSHIZAWA, S.; AMARI, S.-I. Network information criterion-determining the number of hidden units for an artificial neural network model. *Neural Networks, IEEE Transactions on*, v. 5, n. 6, p. 865–872, Nov 1994. ISSN 1045-9227.
- NANJAPPA, A. *Delaunay Triangulation in R^3 on the GPU*. Tese (Doutorado) — Department of Computer Science - National University of Singapore, 2012.
- NIXON, M. S.; AGUADO, A. S. *Feature Extraction and Image Processing*. 1. ed. : Newnes, 2002.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, p. 971–987, 2002.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, v. 29, n. 1, p. 51–59, 1996.

PARK, J.; SHONTZ, S.; DRAPACA, C. A combined level set/mesh warping algorithm for tracking brain and cerebrospinal fluid evolution in hydrocephalic patients. In: ZHANG, Y. (Ed.). *Image-Based Geometric Modeling and Mesh Generation*. : Springer Netherlands, 2013, (Lecture Notes in Computational Vision and Biomechanics, v. 3). p. 107–141.

PIETIKAINEN, M.; HADID, A.; ZHAO, G.; AHONEN, T. *Computer Vision Using Local Binary Patterns*. : Springer, 2011.

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*. 2005.

PONS, J.-P.; BOISSONNAT, J.-D. Delaunay deformable models: Topology-adaptive meshes based on the restricted delaunay triangulation. In: *Computer Vision and Pattern Recognition, 2007. CVPR '07. IEEE Conference on*. 2007. p. 1–8.

PU, J.; LEADER, J.; ZHENG, B.; KNOLLMANN, F.; FUHRMAN, C.; SCIURBA, F.; GUR, D. A computational geometry approach to automated pulmonary fissure segmentation in ct examinations. *Medical Imaging, IEEE Transactions on*, v. 28, n. 5, p. 710–719, May 2009. ISSN 0278-0062.

QI, S.; TRIEST, H. J. W.; YUE, Y.; XU, M.; KANG, Y. Automatic pulmonary fissure detection and lobe segmentation in ct chest images. *Biomedical Engineering*, v. 13, 2014.

REBOUÇAS FILHO, P. P. *Métodos de contornos ativos crisp adaptativo 2D e 3D aplicados na segmentação dos pulmões em imagens de tomografia computadorizada do tórax*. Tese (Doutorado) — Univeridade Feredal do Ceará, 2013a.

REBOUÇAS FILHO, P. P.; CORTEZ, P. C.; FÉLIX, J. H. S.; CAVALCANTE, T. S.; HOLANDA, M. A. Modelo de contorno ativo crisp adaptativo 2d aplicado na segmentação dos pulmões em imagens de tc do tórax de voluntários sadios e pacientes

com enfisema pulmonar. *Revista Brasileira de Engenharia Biomédica*, v. 29, n. 4, p. 363–376, 2013b.

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*, v. 27, n. 4, p. 259–272, 2011.

REBOUÇAS FILHO, P. P.; SARMENTO, R. M.; CORTEZ, P. C.; BARROS, A. C. D. S.; ALBUQUERQUE, V. H. C. D. Adaptive crisp active contour method for segmentation and reconstruction of 3d lung structures. *International Journal of Computer Applications*, v. 111, n. 4, p. 1–8, 2015.

RIKXOORT, E. van; GINNEKEN, B. V.; KLIK, M.; PROKOP, M. Supervised enhancement filters: Application to fissure detection in chest ct scans. *Medical Imaging, IEEE Transactions on*, v. 27, n. 1, p. 1–10, Jan 2008. ISSN 0278-0062.

RIKXOORT, E. van; PROKOP, M.; HOOP, B. de; VIERGEVER, M.; PLUIM, J.; GINNEKEN, B. van. Automatic segmentation of pulmonary lobes robust against incomplete fissures. *Medical Imaging, IEEE Transactions on*, v. 29, n. 6, p. 1286–1296, June 2010. ISSN 0278-0062.

ROSS, J. C.; KINDLMANN, G. L.; OKAJIMA, Y.; HATABU, H.; DÍAZ, A. A.; SILVERMAN, E. K.; WASHKO, G.; DY, J.; ESTÉPAR, R. S. J. Pulmonary lobe segmentation based on ridge surface sampling and shape model fitting. *Medical Physics*, v. 40, n. 12, 2013.

SAISAN, P.; DORETTO, G.; WU, Y. N.; SOATTO, S. Dynamix teexture recognition. *IEE Proceedings Computer VIsion and Pattern Recognition*, v. 2, p. 58–63, 2001.

SAKAMOTO, M. M. *Algoritmo de refinamento de Delaunay a malhas sequenciais, adaptativas e com processamento paralelo*. Tese (Doutorado) — Escola Politecnica da Universidade de Sao Paulo, 2007.

SANKARANARAYANAN, J.; SAMET, H.; VARSHNEY, A. A fast all nearest neighbor algorithm for applications involving large point-clouds. *Computers & Graphics*, v. 31, n. 2, p. 157–174, 2007.

SATO, Y.; WESTIN, C. F.; BHALERAO, A.; NAKAJIMA, S.; SHIRAGA, N.; TAMURA, S.; KIKINIS, R. Tissue classification based on 3d local intensity structures for volume rendering. *Visualization and Computer Graphics, IEEE Transactions on*, v. 6, n. 2, p. 160–180, Apr 2000. ISSN 1077-2626.

- SCHAEFFER, H.; VESE, L. Active contours with free endpoints. *Journal of Mathematical Imaging and Vision*, v. 49, p. 20–36, 2014.
- SHANG, Y.; DEKLERCK, R.; NYSSSEN, E.; MARKOVA, A.; MEY, J. de; YANG, X.; SUN, K. Vascular active contour for vessel tree segmentation. *Biomedical Engineering, IEEE Transactions on*, v. 58, n. 4, p. 1023–1032, 2011.
- SHANI, U.; BALLARD, D. Splines as embeddings for generalized cylinders. *Computer Vision, Graphics, and Image Processing*, v. 27, n. 2, p. 129–156, 1984.
- SHAPIRO, L. G.; STOCKMAN, G. C. *Computer Vision*. : Prentice Hall, 2001.
- SHEN, W.; KASSIM, A. A new scheme for automatic initialization of deformable models. In: *IEEE International Conference on Image Processing - ICIP*. 2007. v. 4.
- SIEMENS. *Computed Tomography: Its History and Technology*. setembro 2004. Disponível em: <www.SiemensMedical.com>. Acesso em: maio de 2009.
- SKALSKI, A.; LAGWA, J.; KEDZIERAWSKI, P.; ZIELINSKI, T.; KUSZEWSKI, T. Automatic prostate segmentation in mr images based on 3d active contours with shape constraints. In: *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA), 2013*. 2013. p. 246–249. ISSN 2326-0262.
- SLABAUGH, G.; UNAL, G. Active polyhedron: surface evolution theory applied to deformable meshes. In: *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. 2005. v. 2, p. 84–91 vol. 2. ISSN 1063-6919.
- 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.
- SMITH-BINDMAN, R.; MIGLIORETTI, D. L.; B., L. E. Rising use of diagnostic medical imaging in a large integrated health system. *Health Aff Millwood*, v. 27, n. 6, p. 1491–1502, Dec 2008.
- SOLTANINEJAD, S.; KESHANI, M.; TAJERIPOUR, F. Lung nodule detection by knn classifier and active contour modelling and 3d visualization. In: *Artificial Intelligence and Signal Processing (AISP), 2012 16th CSI International Symposium on*. 2012. p. 440–445.
- STRZELECKI, M.; SZCZYPINSKI, P.; MATERKA, A.; KLEPACZKO, A. A software tool for automatic classification and segmentation of 2d/3d medical images. *Nuclear*

Instruments & Methods in Physics Research, Section A: Accelerators, Spectrometers, Detectors, and Associated Equipment, v. 702, p. 137–140, 2013.

SUN, K.; CHEN, Z.; JIANG, S. Local morphology fitting active contour for automatic vascular segmentation. *Biomedical Engineering, IEEE Transactions on*, v. 59, n. 2, p. 464–473, 2012.

SURI, J. S. *Deformable Models - Theory and Biomaterial Applications*. Springer-Verlag New York, 2007. Disponível em: <<http://www.springer.com/978-0-387-31204-0>>.

TANG, J.; MILLINGTON, S.; ACTON, S.; CRANDALL, J.; HURWITZ, S. Ankle cartilage surface segmentation using directional gradient vector flow snakes. In: *Image Processing, 2004. ICIP '04. 2004 International Conference on*. 2004. v. 4.

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*. 2005. v. 2, n. 1.

TERZOPOULOS, D.; WITKIN, A.; KASS, M. Symmetry-seeking models and 3d object reconstruction. *International Journal of Computer Vision*, v. 1, p. 211–221, 1987.

TERZOPOULOS, D.; WITKIN, A.; KASS, M. Constraints on deformable models: recovering 3d shape and nonrigid motion. *Artificial Intelligence*, v. 36, n. 1, p. 91–123, 1988.

UGALDE, P.; CAMARGO, J. de J.; DESLAURIERS, J. Lobes, fissures, and bronchopulmonary segments. *Thoracic Surgery Clinics*, v. 17, n. 4, p. 587 – 599, 2007. ISSN 1547-4127. Thoracic Anatomy, Part I Chest Wall, Airway, Lungs. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1547412706001125>>.

UKIL, S.; REINHARDT, J. Anatomy-guided lung lobe segmentation in x-ray ct images. *Medical Imaging, IEEE Transactions on*, v. 28, n. 2, p. 202–214, Feb 2009. ISSN 0278-0062.

VARMA, M.; ZISSERMAN, A. Classifying images of materials: Achieving viewpoint and illumination independence. In: *Computer Vision - ECCV 2002*. : Springer Berlin Heidelberg, 2002, (Lecture Notes in Computer Science, v. 2352). p. 255–271.

VERGEL, J. L. G. *Estudo da influencia da malha computacional, modelos de turbulencia e aspectos numericos da modelagem CFD em impelidores PBT usando malhas*

nao-estruturadas. Dissertação (Mestrado) — Universidade Estadual de Campinas - Faculdade de Engenharia Química, 2013.

WANG, J.; BETKE, M.; KO, J. P. Pulmonary fissure segmentation on {CT}. *Medical Image Analysis*, v. 10, n. 4, p. 530 – 547, 2006. ISSN 1361-8415. Special Issue on Functional Imaging and Modelling of the Heart (FIMH 2005). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841506000338>>.

WEBB, W. R.; MÜLLER, N. L.; NAIDICH, D. P. *High-Resolution {CT} of the Lung*. 4th. ed. New York: Lippincott, 2008.

WEI, Q.; HU, Y. A hybrid approach to segmentation of diseased lung lobes. *Biomedical and Health Informatics, IEEE Journal of*, v. 18, n. 5, p. 1696–1706, Sept 2014. ISSN 2168-2194.

WEI, Q.; HU, Y.; GELFAND, G.; MACGREGOR, J. Segmentation of lung lobes in high-resolution isotropic ct images. *Biomedical Engineering, IEEE Transactions on*, v. 56, n. 5, p. 1383–1393, May 2009. ISSN 0018-9294.

WEI, Q.; HU, Y.; MACGREGOR, J.; GELFAND, G. Segmentation of lung lobes in volumetric ct images for surgical planning of treating lung cancer. In: *Engineering in Medicine and Biology Society, 2006. EMBS '06. 28th Annual International Conference of the IEEE*. 2006. p. 4869–4872. ISSN 1557-170X.

WEI Q., M.; ZHOU, Y.; WAN, M. A fast snake model based on non-linear diffusion for medical image segmentation. *Computerized Medical Imaging and Graphics*, v. 28, n. 3, p. 109–117, 2004.

WIEMKER, R.; BÜLOW, T.; BLAFFERT, T. Unsupervised extraction of the pulmonary interlobar fissures from high resolution thoracic {CT} data. *International Congress Series*, v. 1281, n. 0, p. 1121 – 1126, 2005. ISSN 0531-5131. {CARS} 2005: Computer Assisted Radiology and Surgery Proceedings of the 19th International Congress and Exhibition. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0531513105003535>>.

WU, Q.; AN, J.; LIN, B. A texture segmentation algorithm based on pca and global minimization active contour model for aerial insulator images. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, v. 5, n. 5, p. 1509–1518, 2012.

WU, Q.; GAN, Y.; LIN, B.; ZHANG, Q.; CHANG, H. An active contour model based on fused texture features for image segmentation. *Neurocomputing*, v. 151, p. 1133–1141, 2015.

XU, C.; PRINCE, J. L. Snakes, shapes, and gradient vector flow. *IEEE Transactions on Medical Processing*, v. 7, n. 3, p. 359–369, march 1998.

XU, C.; PRINCE, J. L. Generalized gradient vector flow external forces for active contours. *Signal Processing*, v. 71, p. 131–139, 1998b.

ZAIDI, H.; NAQA, I. E. Pet-guided delineation of radiation therapy treatment volumes: a survey of image segmentation techniques. *European Journal of Nuclear Medicine and Molecular Imaging*, Springer-Verlag, v. 37, n. 11, p. 2165–2187, 2010. ISSN 1619-7070. Disponível em: <<http://dx.doi.org/10.1007/s00259-010-1423-3>>.

ZENG, Z.; WANG, J.; TIDDEMAN, B.; ZWIGGELAAR, R. Unsupervised tumour segmentation in pet using local and global intensity-fitting active surface and alpha matting. *Computers in Biology and Medicine*, v. 43, p. 1530–1544, 2013.

ZHANG, L.; HOFFMAN, E. A.; REINHARDT, J. M. Atlas-driven lung lobe segmentation in volumetric x-ray ct images. *IEEE Transactions on Medical Imaging*, v. 25, p. 1–15, 2006.

ZHANG, Y. Challenges and advances in image-based geometric modeling and mesh generation. In: ZHANG, Y. (Ed.). *Image-Based Geometric Modeling and Mesh Generation*. : Springer Netherlands, 2013, (Lecture Notes in Computational Vision and Biomechanics, v. 3). p. 1–10.

ZHOU, Z.; GENG, X. Projection functions for eye detection. *Pattern Recognition*, v. 37, p. 1049–1056, 2003.

ZUBAIR, M.; ABDULLAH, M. Z.; ARIFIN, A. K. Hybrid mesh for nasal airflow studies. *Computational and Mathematical Methods in Medicine*, 2013.

Apêndices

Apêndice A

Método de Contornos Ativos - MCA

O MCA é baseado em métodos variacionais, cujo objetivo é minimizar uma função que representa a energia. O método proposto por Kass, Witkin e Terzopoulos (1987) consiste inicialmente em estabelecer uma curva em torno do objeto de interesse. Esta curva é conduzida, através de forças, e evolui então até às bordas do objeto de tal modo que a sua energia diminui a cada nova iteração. Basicamente, o MCA consiste na parametrização 2D de uma curva geométrica c da forma (KASS; WITKIN; TERZOPOULOS, 1987)

$$\begin{cases} [0, 1] \rightarrow R^2 \\ c(s) = [x(s), y(s)], \end{cases} \quad (\text{A.1})$$

na qual a posição de cada ponto $c(s)$ é determinada pelas coordenadas $x(s)$ e $y(s)$.

Este modelo é denominado deformável porque é descrito por uma função de energia E definida por (KASS; WITKIN; TERZOPOULOS, 1987)

$$E = \int_0^1 E_s [c(s)] ds = \int_0^1 \{E_{int} [c(s)] + E_{ext} [c(s)]\} ds, \quad (\text{A.2})$$

em que o termo E_s representa a energia total de um ponto da curva, E_{int} representa a energia interna e E_{ext} a energia externa.

Como o objetivo do MCA é minimizar a função de energia E , costuma-se realizar uma busca nas proximidades da curva, para cada um dos pontos $c(s)$, pela energia mínima E_s , dessa forma, ao minimizar a energia de cada ponto da curva, a função de energia E assume valores menores (REBOUÇAS FILHO, 2013a).

Afim de maximizar a eficiência do método, são definidos pontos de controle. Dessa forma a curva passa a ser representada pela ligação entre esses pontos, ou seja, apenas esses pontos de controle são considerados para o cálculo da energia da curva. Nesse sentido,

quanto maior a quantidade de pontos mais precisa é a curva e maior é o custo computacional para a minimização da energia (ALEXANDRIA et al., 2011; REBOUÇAS FILHO, 2013a).

Vale ressaltar que a quantidade de pontos de controle definida inicialmente pode ser alterada durante o processo de minimização de energia, por meio de regras para adição e remoção de pontos de controle (ALEXANDRIA et al., 2011).

A região em que é realizada a busca pela menor energia é definida pela vizinhança de busca de cada ponto, conforme ilustrado na Figura A.1. Para cada coordenada contida na vizinhança é calculada a energia E_s definida na Equação A.2. Aquela coordenada que possuir a menor energia E_s dentre as calculadas é o destino do ponto em questão. O processo de atualização das coordenadas de todos os pontos de controle da curva é definido como iteração. Dessa forma, a minimização da energia é atingida através de sucessivas iterações.

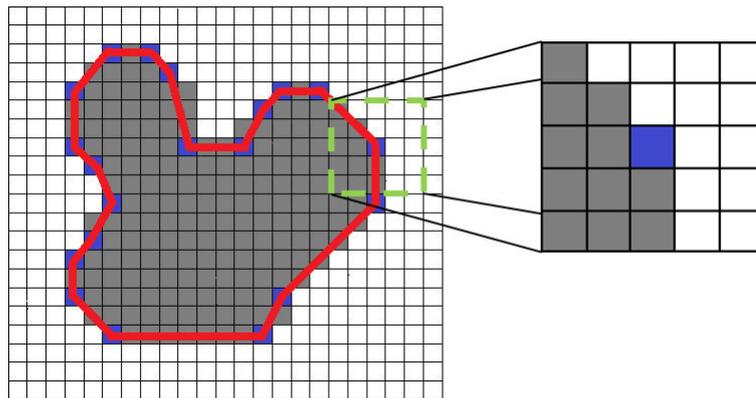


Figura A.1: destaque de vizinhança 5x5 de um ponto de controle do MCA.

As vizinhanças de busca podem assumir formatos e dimensões arbitrárias, todavia, vale ressaltar que quanto maior a vizinhança de busca, maior a quantidade de soluções possíveis naquela iteração, porém maior o volume de operações a serem realizadas e consequentemente maior tempo de processamento por iteração.

A.1 Energias

A Energia do MCA é sua principal característica descritiva e depende somente de sua forma, da localização de seus pontos e da imagem que se pretende segmentar. Esta energia se decompõe nas energias interna e externa, que por sua vez podem assumir um ou mais termos (KASS; WITKIN; TERZOPOULOS, 1987).

A maioria das pesquisas realizadas, contribuições descritas e novas formulações de MCA propostas na literatura dizem respeito a formulação dessas energias. Nesse contexto, define-se o tipo de MCA pela configuração das energias adotadas.

No MCA tradicional proposto por Kass, Witkin e Terzopoulos (1987), por exemplo, a energia interna é definida por

$$E_{\text{int}} [c(s)] = \alpha(s) \left| \frac{d}{ds} c(s) \right|^2 + \beta(s) \left| \frac{d^2}{ds^2} c(s) \right|^2, \quad (\text{A.3})$$

em que $\alpha(s)$ e $\beta(s)$ determinam a relevância de cada termo da energia interna no ponto $c(s)$. Geralmente, a energia interna é composta por mais de um termo, e cada um desses termos é denominado de força interna.

Nesta seção são detalhadas as principais forças e energias mais recorrentes na literatura. Posteriormente são apresentados os MCAs que foram gerados com a combinação destas.

A.1.1 Força de Continuidade

A força de continuidade (F_{cont}), também conhecida por força de elasticidade, proposta por Kass, Witkin e Terzopoulos (1987), representa o primeiro termo da energia interna definida na Equação A.3.

Esta força define a capacidade de um ponto da curva se distanciar ou aproximar dos pontos vizinhos, atuando no contorno para torná-lo uniformemente espaçado. Realizando uma aproximação da derivada por diferenças finitas, obtém-se (KASS; WITKIN; TERZOPOULOS, 1987)

$$\left| \frac{d}{ds} c(s) \right|^2 \approx |c(s) - c(s-1)|^2 = [x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2, \quad (\text{A.4})$$

em que $x(s)$ e $y(s)$ são as coordenadas do ponto $c(s)$ (NIXON; AGUADO, 2002). Logo, é possível descrever a força de continuidade como a diferença espacial entre dois pontos consecutivos da curva c , associando-a à distância euclidiana entre estes dois pontos.

Neste contexto, como a força de continuidade surge para manter uniforme o espaçamento entre os pontos da curva, a distância média entre os pontos de controle da curva deve ser considerada, visto que esta pode ser utilizada para espaçar igualmente os pontos (REBOUÇAS FILHO, 2013a). Deste modo, a distância média pode ser calculado por

$$\mu_D = \frac{\sum_{s=0}^{N-1} \sqrt{[x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2}}{N}, \quad (\text{A.5})$$

em que N é a quantidade de pontos de controle. Assim, pode-se formular a força de continuidade F_{cont} como

$$F_{cont}[c(s)] = \left| \mu_D - \sqrt{[x(s) - x(s-1)]^2 + [y(s) - y(s-1)]^2} \right|. \quad (\text{A.6})$$

Desta forma, quanto mais próxima for a distância entre o ponto de controle e seu anterior, da distância média, menor a força de continuidade e mais estável estará o ponto. Caso contrário a força atuará aproximando os pontos afastados e distanciando os pontos próximos, tendendo a deixá-los o mais equidistantes possível.

A.1.2 Força de Curvatura

A força de curvatura (F_{curv}) também foi proposta por Kass, Witkin e Terzopoulos (1987) e consiste na segunda derivada da Equação A.3.

A força de curvatura é responsável pela suavização da curva. Esta força baseia-se nos ângulos internos do contorno e tende a deixá-lo contínuo para mantê-lo suave, em detrimento de trechos irregulares e pontiagudos (CAVALCANTE et al., 2013; FÉLIX, 2011). Realizando uma aproximação da derivada por diferenças finitas, obtém-se (KASS; WITKIN; TERZOPOULOS, 1987)

$$\left| \frac{d^2}{ds^2} c(s) \right|^2 \approx |c(s-1) - 2c(s) + c(s+1)|^2, \quad (\text{A.7})$$

resultando em

$$F_{curv}[c(s)] = \sqrt{[x(s-1) - 2x(s) + x(s+1)]^2 + [y(s-1) - 2y(s) + y(s+1)]^2}. \quad (\text{A.8})$$

Percebe-se que, para o cálculo da força de curvatura de um ponto de controle, são utilizadas as coordenadas dos seus dois vizinhos imediatos, $c(s-1)$ e $c(s+1)$. Logo, é possível estimar a curvatura da curva no ponto de controle em questão e nas coordenadas presente na vizinhança, possibilitando com que a força de curvatura beneficie a coordenada com menor curvatura (NIXON; AGUADO, 2002).

A.1.3 Força Balão

Cohen (1991) define uma força para compor a energia interna do MCA. Denominada de força balão (F_{bal}), esta força tem como intuito inflar o contorno, uma vez que as forças internas existentes tendiam a aproximar os pontos fazendo com que a área do contorno sempre diminuísse.

Essa força é a responsável por permitir que o MCA possa ser inicializado no interior do objeto, pois age expandindo o contorno. Também consiste em uma força de fundamental importância para o contorno quando este se encontra em regiões homogêneas da imagem em que a energia externa é nula e as únicas forças que devem interferir no contorno 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 livremente o contorno até que alguma energia externa seja detectada e a curva realize a segmentação do objeto (CAVALCANTE et al., 2013).

Cohen (1991) define a força balão como uma pressão interna ao contorno que o empurra para fora, e faz analogia a um balão quando possui ar sendo introduzido. Originalmente a força balão foi definida como,

$$F_{bal}[c(s)] = n(s), \quad (\text{A.9})$$

em que $n(s)$ é o vetor unitário normal a curva no ponto $c(s)$. Assim, em cada ponto de controle deve ser calculado o vetor normal a curva.

Esta é uma das forças mais populares em MCAs, conseqüentemente alguns estudos e novas formulações desta força foram propostas. Mackiewicz (1995) sugere uma técnica baseada no centróide do contorno de coordenadas (x_m, y_m) . Esta coordenada é o ponto central da curva, calculado através das médias das coordenadas $x(s)$ e $y(s)$ dos pontos do contorno. Neste método, a força balão é baseada na distância euclidiana, e também definida para cada ponto do contorno $c(s)$, por (MACKIEWICH, 1995)

$$F_{bal}[c(s)] = -\sqrt{E_x^2 + E_y^2}, \quad (\text{A.10})$$

em que E_x e E_y são determinadas por

$$E_x = |x_m - x(s)| \quad (\text{A.11})$$

e

$$E_y = |y_m - y(s)|. \quad (\text{A.12})$$

Apesar do custo computacional reduzido em relação à proposta original, esta abordagem possui uma limitação que se refere a segmentação de objetos côncavos. Uma vez que o centroide é único para todo o contorno, as concavidades geram regiões em que esta abordagem da força balão não atua da direção correta, conforme ilustrado na Figura A.2. Observando a Figura A.2(c), percebe-se que o contorno não segmenta corretamente o canto inferior direito porque a força balão que deveria expandi-lo até as bordas está com a direção em relação ao centroide.

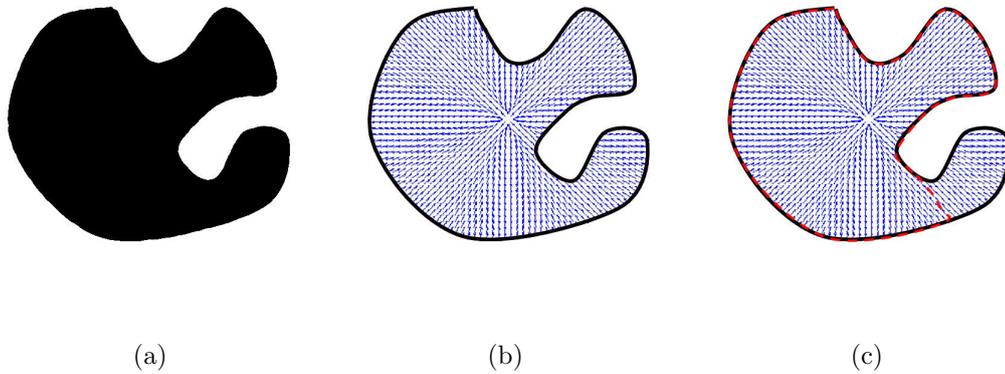


Figura A.2: aplicação da força balão definida na Equação A.10, (a) imagem original; (b) mapa da força balão para um centroide; e (c) resultado da segmentação do MCA para o mapa de forças em (b).

Baseado em Mackiewicz (1995), Rebouças Filho (2013a) propõe uma outra abordagem para o cálculo da força balão, que em vez de considerar o centroide do contorno, baseia-se na distância entre o ponto $c(s)$ e a coordenada média dos vizinhos imediatos deste ponto $c_v(s) = [x_v(s), y_v(s)]$. Logo, a força é definida por

$$F_{bal}[c(s)] = \alpha(s) \sqrt{[x_v(s) - x(s)]^2 + [y_v(s) - y(s)]^2}, \quad (\text{A.13})$$

em que

$$x_v(s) = \frac{x(s-1) + x(s+1)}{2}, \quad (\text{A.14})$$

$$y_v(s) = \frac{y(s-1) + y(s+1)}{2} \quad (\text{A.15})$$

e α assume valores de acordo com a coordenada $c_v(s)$. É necessário determinar se a coordenada $c_v(s)$ está dentro ou fora do contorno utilizando, por exemplo, o método de Berg et al. (1975) para tal. Nesse caso obtém-se

$$\alpha(s) = \begin{cases} -1, & \text{se } c_v(s) \text{ for interna à curva} \\ +1, & \text{caso contrario} \end{cases} \quad (\text{A.16})$$

Esta abordagem elimina a limitação ilustrada na Figura A.2, porém eleva o custo computacional, uma vez que é necessário determinar para cada ponto $c(s)$ se a coordenada $c_v(s)$ respectiva se encontra interna ou externa ao contorno.

A.1.4 Energia externa tradicional

A energia externa E_{ext} , referenciada na Equação A.2, permite ao MCA uma adaptação sobre os objetos, pois se baseia em informações da própria imagem. É a energia externa que compensa a energia interna, evitando assim, que o MCA se contraia sobre si mesmo ou se expanda sem limites, sem sofrer influência das informações contidas na imagem. Em geral, no cálculo desta energia é utilizado o gradiente ∇ da imagem I no ponto $c(s)$ e em sua vizinhança, sendo (KASS; WITKIN; TERZOPOULOS, 1987; ALEXANDRIA et al., 2011)

$$E_{ext}^{(1)}(s) = -|\nabla \{I[c(s)]\}|^2 \quad (\text{A.17})$$

e

$$E_{ext}^{(2)}(s) = -|\nabla \{G_\sigma * I[c(s)]\}|^2 \quad (\text{A.18})$$

em que ∇ é o operador gradiente e G_σ é uma função gaussiana centrada no ponto $c(s)$ de variância σ^2 (XU; PRINCE, 1998). No caso especial em que a imagem é um contorno simples, constituído por linhas, como círculos em imagens sintéticas, por exemplo, as energias externas podem ser reduzidas a (COHEN, 1991)

$$E_{ext}^{(3)}(s) = I[c(s)] \quad (\text{A.19})$$

e

$$E_{ext}^{(4)}(s) = G_\sigma * I[c(s)] \quad (\text{A.20})$$

respectivamente. Esta simplificação ocorre por a imagem já possuir um contorno simples, sendo dispensado o uso do gradiente na detecção do contorno do objeto a ser segmentado.

Sabe-se que, quanto maior o valor de σ^2 utilizado, maior o borramento da imagem, especialmente nas bordas. Todavia, pode ser útil para permitir ao MCA detectar as bordas mais facilmente, devido à redução de ruído na imagem a ser segmentada e por tornar as bordas mais espessas (ALEXANDRIA et al., 2011; FÉLIX, 2011).

A.1.5 Energia externa *Gradient Vector Flow* - GVF

A energia externa GVF, E_{gvf} , é definida por um campo de vetores, V_{gvf} , que é calculado por meio da difusão de gradientes derivados do resultado do operador gradiente, definido por Xu e Prince (1998) como mapa de bordas de uma imagem:

$$V_{gvf}(x, y) = [u_{gvf}(x, y), v_{gvf}(x, y)]. \quad (\text{A.21})$$

O campo de vetores V_{gvf} é definido de tal forma que minimize o funcional de energia

$$E_{gvf} = \int \int [\mu(u_{gvfx}^2 + u_{gvfy}^2 + v_{gvfx}^2 + v_{gvfy}^2) + |\nabla f_{gvf}|^2 |V_{gvf} - \nabla f_{gvf}|^2] dx dy, \quad (\text{A.22})$$

em que ∇f_{gvf} é o mapa de bordas derivado da imagem, u_{gvfx} , u_{gvfy} e v_{gvfx} , v_{gvfy} são as primeiras derivadas parciais de u_{gvf} e v_{gvf} em relação a x e y , respectivamente e μ é um parâmetro de regularização (XU; PRINCE, 1998; LV; GAO; ZOU, 2008).

O parâmetro μ na Equação A.22, controla a relação entre o primeiro e o segundo termo da integral, podendo esta relação diminuir a influência de ruído, aumentando ou diminuindo o valor de μ .

Quando o valor de ∇f_{gvf} é pequeno, a energia resultante é predominantemente no primeiro termo, resultando em um campo de pequena variação. Por outro lado, quando ∇f_{gvf} possui um valor grande, o segundo termo predomina na integral, sendo minimizado fixando-se $V_{gvf} = \nabla f_{gvf}$. Este comportamento produz o efeito de manter V_{gvf} semelhante ao gradiente do mapa de bordas, quando este valor é grande, mas forçando o campo a variar pouco em regiões homogêneas (FÉLIX, 2011).

A energia GVF é capaz de realizar, simultaneamente, a intensificação das bordas e a distribuição suave do gradiente em regiões homogêneas, conforme ilustrado na Figura A.3. Desta forma, essa energia proporciona ao MCA a possibilidade de detecção das bordas do objeto desejado por meio de uma faixa de captura mais ampla. Além disso, reduz a

sua sensibilidade do posicionamento do contorno inicial, bem como faz a identificação de regiões côncavas nos objetos de interesse de uma dada imagem, conforme apresentado na Figura A.3.

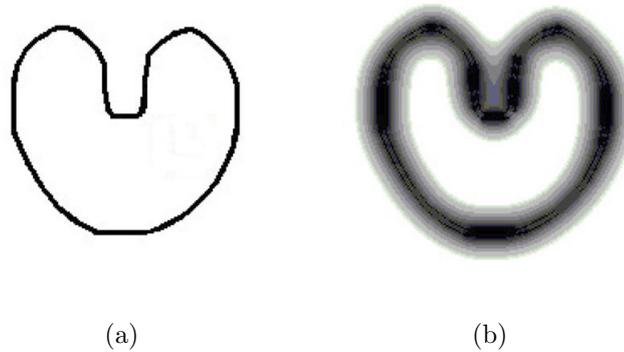


Figura A.3: aplicação do GVF, (a) imagem original; e (b) suavização das bordas.

Entretanto, o alto custo computacional, proveniente dos cálculos de difusão dos vetores gradiente na obtenção do campo de vetores (WEI Q.; ZHOU; WAN, 2004; CHENG; FOO, 2006); a sensibilidade ao ruído, principalmente ao ruído impulsivo (TANG et al., 2004; LI; ACTON, 2007), além da dificuldade de representar regiões com concavidades estreitas e profundas (FÉLIX, 2011) são algumas das limitações dessa energia.

A.1.6 Energia externa Crisp

Um bom exemplo de uma energia externa proposta para uma aplicação específica, é a energia externa Crisp (E_{crisp}). Proposta por Rebouças Filho, Cortez e Holanda (2011) a energia externa Crisp surge como opção para realizar a segmentação dos pulmões em imagens de TC, entretanto só permite ser aplicada nesse caso.

A energia baseia-se nas faixas de densidade pulmonar, descritas na Seção 2.1. Basicamente, é estabelecida uma função para calcular os percentuais de cada umas das regiões presentes na imagem. Com base nas faixas de densidade pulmonar são definidas 5 classes (c_i), sendo i o índice da classe (REBOUÇAS FILHO; CORTEZ; HOLANDA, 2011).

Neste sentido, considerando $D(x, y)$ uma matriz de densidades pulmonares, tem-se a função $f_i(x, y)$ que determina a quantidade de pontos com densidades presente em cada classe c_i dada por

$$f_i(x, y) = \sum_{l=-4}^4 \sum_{m=-4}^4 R(x-l, y-m), \quad (\text{A.23})$$

sendo R dado por

$$R(x, y) = \begin{cases} 1, & l_{inf}(c_i) < D(x, y) < l_{sup}(c_i) \\ 0, & \text{caso contrário,} \end{cases} \quad (\text{A.24})$$

em que $l_{inf}(c_i)$ e $l_{sup}(c_i)$ representam os limites inferior e superior da faixa de densidade da classe c_i (CAVALCANTE et al., 2013).

A partir do valor de $f_i(x, y)$, calcula-se o percentual P_i de cada classe i por

$$P_i = \frac{f_i(x, y)}{\sum_{i=0}^4 f_i(x, y)}. \quad (\text{A.25})$$

Por fim, a partir dos percentuais calculados é possível obter a energia Crisp (E_{crisp}), sendo esta

$$E_{crisp}(s) = \begin{cases} 0, & \text{para } P_3 < 0,2 \text{ e } P_4 < 0,15 \\ S(s), & \text{caso contrário.} \end{cases} \quad (\text{A.26})$$

em que $S(s)$ é o operador Sobel aplicado nos pontos do contorno $c(s)$. Um exemplo da (E_{crisp}), aplicada em uma imagem, é ilustrado na Figura A.4

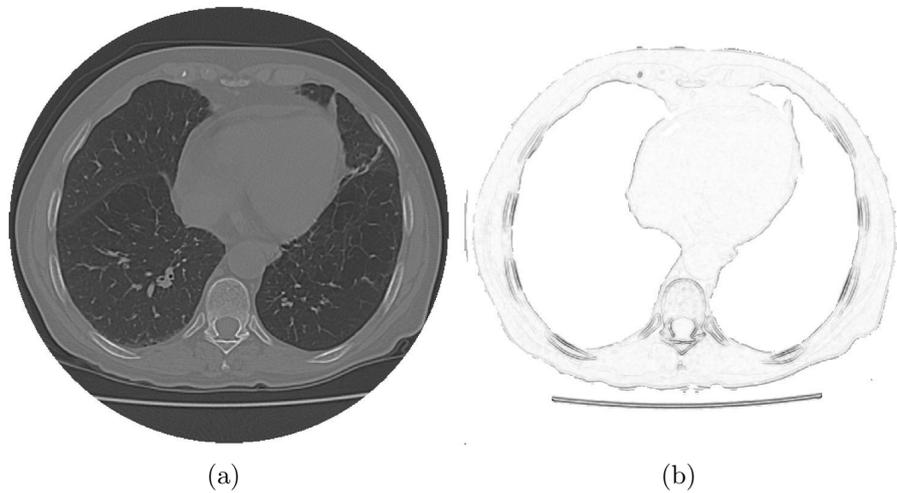


Figura A.4: imagem de TC dos pulmões: (a) imagem original e (b) Força Crisp (REBOUÇAS FILHO, 2013a).

A.2 MCA e suas variações

Diversos tipos de MCA são propostos na literatura (HE et al., 2008; MOORE; MOLLOY, 2007). As pesquisas realizadas propõem contribuições em diversos aspectos do MCA, como

por exemplo na inicialização automática do MCA (FELIX et al., 2012; REBOUÇAS FILHO, 2013a), na resolução da minimização da função de energia (AMINI; WEYMOUTH; JAIN, 1990; COHEN; COHEN, 1993; FAN; JIANG; EVANS, 2002), na representação de dados e topologia (ALEXANDRIA et al., 2014; MCINERNEY; TERZOPOULOS, 1996, 2000; SCHAEFFER; VESE, 2014; BESSA et al., 2015).

Todavia, a maior parte das contribuições consiste na forma como a energia do MCA é composta. Diversos trabalhos tem proposto novas forças, gerando novas energias a partir da combinação entre a força proposta e as demais. Originalmente a energia do MCA é composta pela energia externa, definida na Equação A.17, e pela energia interna composta pela soma das força de continuidade e força de curvatura, definidas na Seção A.1, sendo representada a seguir

$$E [c(s)] = E_{\text{int}} [c(s)] + E_{\text{ext}} [c(s)], \quad (\text{A.27})$$

em que

$$E_{\text{int}} [c(s)] = \alpha(s)F_{\text{cont}} [c(s)] + \beta(s)F_{\text{curv}} [c(s)]. \quad (\text{A.28})$$

Uma das variações mais populares do MCA é o MCA balão. Nessa variação, uma nova energia interna é proposta. Dessa forma, a energia do MCA é definida conforme Equação A.27, mas a energia interna, por sua vez é representada por (COHEN, 1991; MACKIEWICH, 1995)

$$E_{\text{int}} [c(s)] = \alpha(s)F_{\text{cont}} [c(s)] + \beta(s)F_{\text{bal}} [c(s)]. \quad (\text{A.29})$$

Como visto na Seção A.1, a força balão, representada na Equação A.29 por F_{bal} , pode ser interpretada de algumas formas, sendo possível a mesma assumir uma das definições descritas nas Equações A.9, A.10 ou A.13. Dessa forma, a definição da força balão adotada deve dotar o MCA de características e comportamentos distintos, possuindo cada uma suas vantagens e desvantagens conforme foram abordadas anteriormente.

Além de variações na formulação da energia interna, também existem diversas propostas de formulações para a energia externa do MCA. O MCA GVF, proposto por Xu e Prince (1998), é uma das mais populares variações que aborda alterações na energia externa. Esse MCA possui a mesma energia interna definida no MCA tradicional, enquanto a energia externa consiste na energia definida na Equação A.22.

Algumas energias externas propostas na literatura abordam áreas e aplicações específicas, fato este plenamente justificável por se tratar da energia que representa a imagem na qual o MCA deve ser aplicado. Nesse sentido, é desejável possuir uma formulação que seja representativa tanto da imagem em questão como da região de interesse que se deseja segmentar.

Partindo desse princípio, Rebouças Filho, Cortez e Holanda (2011) propõe o MCA Crisp. A energia interna desse MCA é a mesma definida na Equação A.29, sendo F_{bal} definido pela Equação A.13. Já a energia externa consiste na energia externa crisp (E_{crisp}) definida anteriormente na Equação A.26. O MCA Crisp foi proposto especificamente para a segmentação dos pulmões em imagens de TC e não apresenta resultados satisfatórios quando utilizados em outras aplicações. Todavia os resultados obtidos quando utilizados na aplicação para a qual o mesmo foi proposto são notórios.

Existem muitas abordagens diferentes para MCA que podem ser encontradas na literatura, variando em função da aplicação desejada. Normalmente, estas abordagens referem-se a métodos diferentes para a obtenção das energias, principalmente quanto a combinação de outras técnicas aliadas ao MCA, visando aproveitar-se das vantagens de cada uma individualmente formando assim um novo MCA.

Dentre as abordagens propostas, é possível citar: o MCA GGVF proposto por Xu e Prince (1998b) que adota funções de ponderação na formulação da energia externa GVF; o MCA VFC, proposto por Li e Acton (2006) que propõe uma energia externa chamada de convolução de campo de vetor; o MCA THR e MCA THRGD propostos por Félix (2011) que possuem a energia externa baseada na Transformada de Hilbert Radial e a Transformada de Hilbert Radial Generalizada, respectivamente.

Wu et al. (2015) propõem um MCA com energia externa baseada nas técnicas de filtro de gabor e análise de componentes principais. Darolti et al. (2008), por sua vez, propõem um MCA com energia externa baseada no conceito dos descritores região local, calculados a partir de amostras dentro de vizinhanças centradas sobre o contorno ativo.

Já Krinidis e Chatzis (2009) apresentam um MCA com energia baseada em lógica Fuzzy, dessa forma permite detectar objetos cujos limites não são necessariamente definidos por gradiente, ou objetos com limites descontínuos. O MCA proposto por Shang et al. (2011) possui energia que baseia-se em modelos gaussianos para segmentação de vasos sanguíneos de grosso calibre, enquanto para a segmentação de vasos sanguíneos de pequeno calibre, a energia externa consiste em um campo de vetores baseado nos autovalores da matriz hessiana.

Chin, Seng e Ang (2012) propõe MCA com energia baseada em watershed. Sun, Chen e Jiang (2012) também utiliza watershed a formulação da energia proposta, porém adiciona informações de morfologia e lógica fuzzy. Já Wu, An e Lin (2012) propõem energia baseada em texturas e análise de componentes principais.

Apêndice B

Rede Neural Artificial - RNA

RNA surgiram com o objetivo de modelar o sistema nervoso biológico para obter soluções de problemas computacionais complexos. A técnica da computação neural é estabelecer procedimentos similares aos usados na solução de problemas pelo cérebro humano e aplicá-los aos 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. Estas redes são compostas por unidades básicas, denominadas de neurônio artificial (HAYKIN, 2008).

O perceptron ou neurônio artificial é um modelo de um 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 B.1.

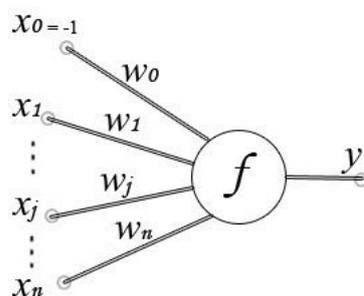


Figura B.1: representação de um perceptron.

A saída ou resposta de um neurônio depende das entradas e de seus pesos associados e pode servir de entrada para outros neurônios, formando uma rede disposta em camadas. A saída do perceptron é calculada de acordo com a equação a seguir (HAYKIN, 2008).

$$y = f \left(\sum_{i=0}^n x_i w_i \right) \quad (\text{B.1})$$

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

As redes perceptron possuem duas fases de operação distintas, a fase de treinamento e a de execução. Na fase de execução é apresentado um conjunto de dados, cuja resposta é desconhecida. Devendo a rede reconhecer o padrão apresentado (HAYKIN, 2008).

Já na fase de treinamento, os pesos w_i são adequadamente calculados para que a rede possa aprender o padrão e apresentar saídas satisfatórias. Em redes perceptron simples (PS), o treinamento é supervisionado, ou seja é apresentado um conjunto de dados com resposta conhecida e em seguida a resposta da rede é comparada com a resposta esperada. O erro obtido nessa comparação é utilizado para recalculando os pesos w_i da rede. Geralmente, esta fase se encerra quando o erro obtido é menor do que uma tolerância pré-estabelecida (MEDEIROS, 2008).

Existem várias limitações na capacidade dos perceptrons, pois, estes somente conseguem reconhecer padrões linearmente separáveis. O exemplo clássico desta limitação é a função Ou-Exclusivo que não pode ser implementada por este tipo de rede (MEDEIROS, 2008).

B.1 Rede Neural Perceptron Multicamadas - MLP

A rede MLP surgiu com o intuito de superar algumas limitações do perceptron simples, resolvendo problemas cujos padrões não são separáveis linearmente. Além disso, revela-se como 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 (MEDEIROS, 2008).

A rede MLP é subdividida em camada de entrada, pesos da camada oculta, saída da camada oculta que por sua vez consiste na entrada da camada oculta seguinte ou da camada de saída, pesos da camada de saída e resultado da camada de saída, interpretado como resultado final da rede (HAYKIN, 2008). Estas subdivisões podem ser observadas na Figura B.2.

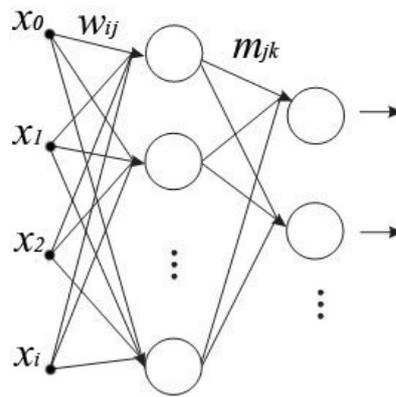


Figura B.2: representação de rede MLP com uma camada oculta.

As camadas ocultas, consistem naquelas camadas que não fazem parte da entrada e nem da saída, são essas camadas que tornam a rede capaz de extrair características mais representativas do sistema, possibilitando a resolução de problemas não separáveis linearmente. Observando a Figura B.2, percebe-se que a rede MLP apresenta interligações entre os neurônios das diferentes camadas e em cada ligação são associados os pesos também conhecidos como pesos sinápticos.

O vetor de pesos w_j associado ao j -ésimo neurônio da camada intermediária e m_k associado ao k -ésimo neurônio da camada de saída são dados respectivamente por (HAYKIN, 2008)

$$w_j = \begin{pmatrix} w_{0j} \\ \vdots \\ w_{Pj} \end{pmatrix} \text{ e } m_k = \begin{pmatrix} m_{0k} \\ \vdots \\ m_{Qk} \end{pmatrix} \quad (\text{B.2})$$

em que P representa a quantidade de entradas e Q a quantidade de neurônios na camada oculta.

Assim, da mesma forma que a rede perceptron, a rede 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. O que justifica-se pelo fato da MLP possuir camadas intermediárias que também necessitam da atualização de seus pesos, mas não possuem resposta esperada para as mesmas, uma vez que a resposta esperada é o resultado da rede conhecido apenas na camada de saída.

Logo, faz-se necessário utilizar algum algoritmo capaz de ajustar os pesos nas camadas intermediárias. A rede MLP tem sido aplicada a problemas utilizando na fase de treinamento o algoritmo de retropropagação do erro (*backpropagation*). Este algoritmo é baseado na regra de correção de erro e pode ser dividido em duas etapas.

A primeira etapa do treinamento da rede MLP, realizado pelo algoritmo de retropropagação do erro, é semelhante a etapa de execução, pois 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 x à rede MLP, calcula-se as ativações $u_j(t)$ de cada neurônio da camada oculta na iteração t por (HAYKIN, 2008)

$$u_j(t) = \sum_{i=0}^P w_{ij}(t)x_i(t), \quad j = 1, \dots, Q, \quad (\text{B.3})$$

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 P é a dimensão do vetor de entrada. A partir das ativações, são calculadas as saídas dos respectivos neurônios por

$$z_j(t) = \phi_j(u_j(t)), \quad (\text{B.4})$$

em que ϕ_j é a função de ativação do j -ésimo neurônio, e geralmente assume uma das seguintes funções lineares

- sigmóide logística

$$\phi_j(u_j(t)) = \frac{1}{1 + \exp[-u_j(t)]} \quad (\text{B.5})$$

- tangente hiperbólica

$$\phi_j(u_j(t)) = \frac{1 - \exp[-u_j(t)]}{1 + \exp[-u_j(t)]}. \quad (\text{B.6})$$

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 . Um processo análogo ocorre entre a última camada oculta e a camada de saída, dado por

$$u_k(t) = \sum_{j=0}^Q m_{jk}(t)z_j(t) \quad (\text{B.7})$$

$$y_k(t) = \phi_k(u_k(t)) \quad (\text{B.8})$$

em que $u_k(t)$ e $y_k(t)$ são o resultado da multiplicação da entrada da camada de saída pelos seus pesos e o resultado da função de ativação da camada de saída, respectivamente. A função de a ativação ϕ_k assume a forma da função sinal

$$y_k = \text{sign}(u_k(t)) = \begin{cases} +1, & y_k(t) > 0, \\ 0, & y_k(t) = 0, \\ -1, & y_k(t) < 0. \end{cases} \quad (\text{B.9})$$

Na segunda etapa do treinamento, é realizado o cálculo do erro e gradientes locais e o ajuste dos pesos dos neurônios das camadas ocultas e da camada de saída. Nessa etapa, o fluxo de informações dar-se da camada de saída para a entrada (sentido inverso). Inicialmente calcula-se o erro de cada neurônio da camada de saída por (HAYKIN, 2008)

$$e_k(t) = d_k(t) - y_k(t), \quad (\text{B.10})$$

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 $y_k(t)$.

O erro na camada oculta é calculado através da propagação do erro vindo da camada de saída, esta propagação é obtida pelo cálculo do gradiente local dos neurônios da camada de saída, dados por

$$\delta_k(t) = e_k(t)\phi'(u_k(t)), \quad (\text{B.11})$$

em que $\phi'(u_k(t))$ é a derivada da função de ativação adotada. A derivada da função de ativação pode assumir os valores de acordo com a função de ativação escolhida. Para a função de ativação sigmóide logística, $\phi'(u_k(t))$ é dada por

$$\phi'_k(u_k(t)) = \frac{d\phi_k(u_k(t))}{du_k(t)} = y_k(t)[1 - y_k(t)] \quad (\text{B.12})$$

Caso a função de ativação seja a função tangente hiperbólica, $\phi'(u_k(t))$ é dada por

$$\phi'_k(u_k(t)) = \frac{d\phi_k(u_k(t))}{du_k(t)} = \frac{1}{2}[1 - y_k^2(t)]. \quad (\text{B.13})$$

Utilizando os erros calculados, os pesos de todas as camadas são atualizados da seguinte forma

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}(t) \\ w_{ij}(t+1) &= w_{ij}(t) + \alpha \delta_i(t) x_j(t) \end{aligned} \quad (\text{B.14})$$

em que α é a taxa de aprendizagem, δ_i corresponde ao gradiente local do i -ésimo neurônio.

Para a camada de saída, a equação de atualização dos pesos é dada por

$$\begin{aligned}m_{ki}(t+1) &= m_{ki}(t) + \Delta m_{ki}(t) \\m_{ki}(t+1) &= m_{ki}(t) + \alpha \delta_k(t) z_i(t)\end{aligned}\tag{B.15}$$

em que α é a taxa de aprendizagem, δ_k corresponde ao gradiente local do k -ésimo neurônio.

Apêndice C

Resultados em Imagens Sintéticas

Para realizar os testes em imagens sintéticas, cinco formas geométricas 3D são selecionadas, com o intuito de englobar características como cantos pontiagudos, cantos arredondados, regiões planas e regiões curvadas. As formas selecionadas são: cilindro, cone, cubo, pirâmide e esfera. Logo, para gerar tais imagens 3D, um espaço de resolução $300 \times 300 \times 300$ é configurado, atribuindo valor 1 para todos os voxels. Em seguida as formas citadas foram criadas centralizadas neste espaço, atribuindo valor 0 para os voxels internos às mesmas.

As formas criadas possuem as seguintes dimensões em voxels:

- Cilindro
raio da base = 50; altura = 160;
- Cone
raio da base = 100; altura = 100;
- Cubo
altura, largura e profundidade = 100;
- Piramide
base quadrada= 200×200 ; altura = 100; e
- Esfera
raio = 50.

Na Figura C.1 são ilustradas no espaço tridimensional as formas geométricas utilizadas nos testes.

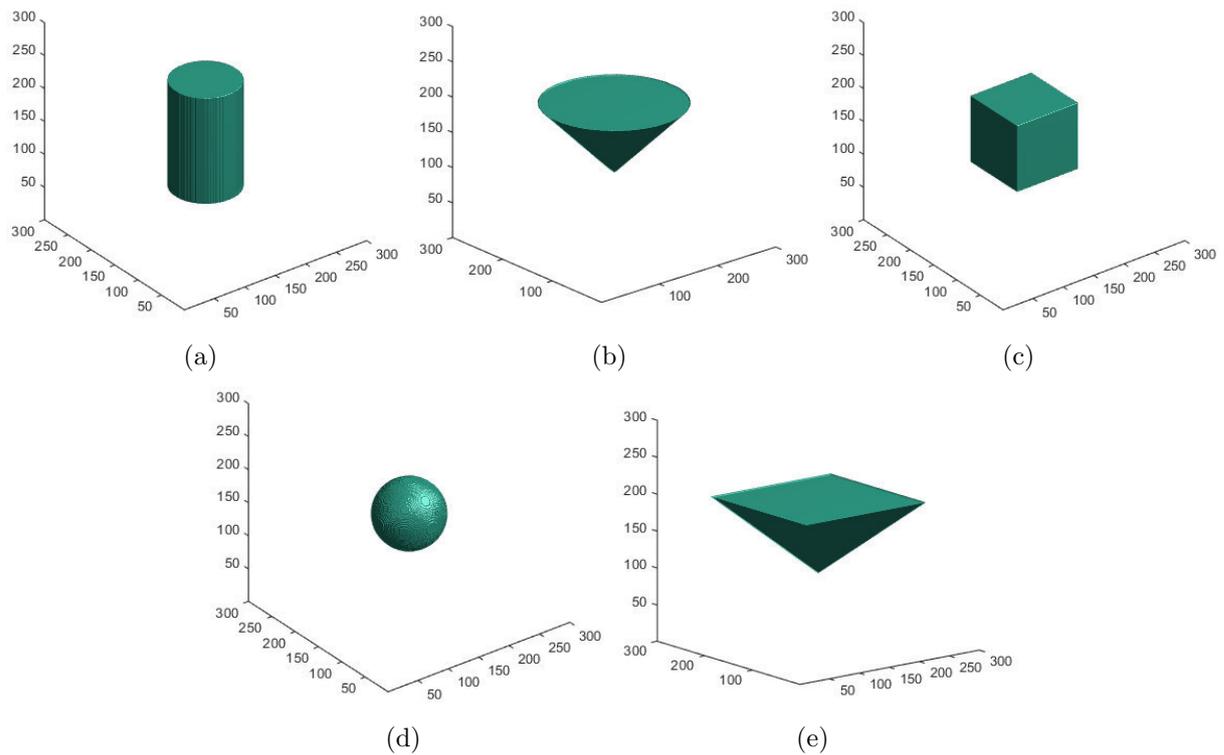


Figura C.1: volumes 3D utilizados nos tetes sintéticos, (a) cilindro; (b) cone; (c) cubo; (d) esfera; e (e) pirâmide.

O processo de segmentação do MSA proposto é testado com os três tipos diferentes de malha abordados na seção 2.2.1.1, sendo estas uma malha estruturada retangular, uma malha kNN e uma malha Crust que se baseia em Delaunay. Para a malha com kNN, baseado em testes, foi adotado empiricamente $k = 7$.

Em todos os casos de testes, o conjunto de pontos iniciais são distribuídos sobre a superfície de uma esfera. Para as malhas não estruturadas, kNN e Crust, a distribuição dos pontos é semelhante, dispendo-os o mais uniforme possível com o intuito de manter a mesma distância entre os pontos, possibilitando uma representação com a mesma precisão em todas as regiões. Já para a malha estruturada, os pontos são distribuídos obedecendo às regras de formação da malha, o que não permite uma distribuição tão uniforme quanto às obtidas com as outras malhas. Na Figura C.2 é ilustrada uma inicialização utilizada nos testes com cada um dos três tipos de malha adotados.

Com o objetivo de medir a acurácia da segmentação para cada tipo de malha, os testes são realizados com 14 quantidades distintas de pontos, sendo estas: 100, 200, 300, 400, 500, 600, 700, 800, 900, 1000, 1300, 1600, 2000 e 2500 pontos.

O valor adotado para o parâmetro α , que pondera a força de continuidade, e para o parâmetro β , que pondera a força de curvatura ou balão, é de 0,1. Com o intuito

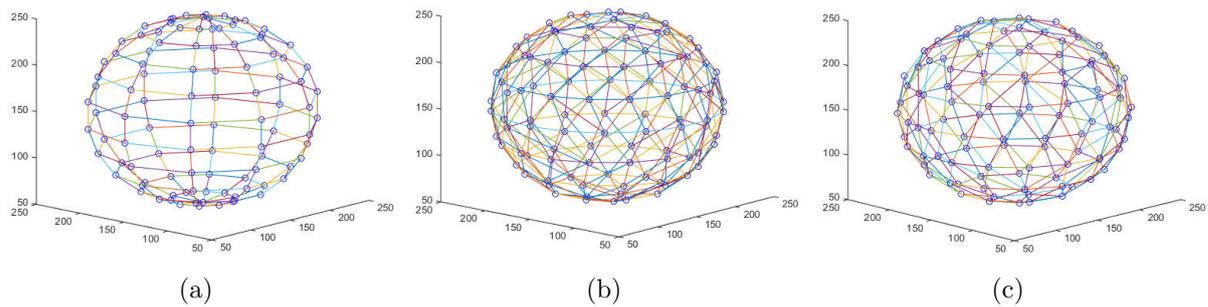


Figura C.2: inicialização do MSA com 100 pontos distribuídos sobre a superfície de uma esfera de raio igual a 100 voxels, (a) malha estruturada retangular; (b) malha kNN com $k = 7$; e (c) malha Crust.

de comparar o nível de representação de cada tipo de malha com quantidade de pontos semelhante, as funcionalidades de adição e remoção de pontos não são utilizadas nos testes em imagens sintéticas. Assim todas as segmentações são concluídas com a mesma quantidade de pontos inicial.

A energia interna é testada com duas composições, sendo a primeira formada pela força de continuidade definida na equação 3.2 e pela força de curvatura definida na equação 3.4, dessa forma a superfície deve-se retrair até atingir as bordas do objeto. A segunda composição é formada pela mesma força de continuidade, mas tem a força de curvatura substituída pela força balão definida na equação 3.5. Com esta segunda composição, a superfície inicial deve se expandir, conformando-se aos limites do objeto.

As inicializações adotadas no caso do MSA com a força de curvatura consistem na distribuição da quantidade de pontos disponíveis, para cada teste, sobre a superfície de uma esfera de raio igual a 150 voxels centralizada no espaço, englobando a forma a ser segmentada. Já para o MSA com força balão, a superfície inicial consiste em uma esfera de raio igual a 10 voxels centralizada no espaço, sendo esta interna à todos os objetos a serem segmentados.

Como o intuito deste teste é observar o desempenho da segmentação com malhas estruturadas e não estruturadas, além de mensurar a qualidade da segmentação para cada composição da energia interna, não é utilizado nenhum nível de ruído nas imagens sintéticas. Isto porque a adição de ruído na imagem influencia diretamente no mapa de energia externa.

Destaca-se que a energia externa proposta nesta tese deve ser aplicada exclusivamente para segmentação de lobos pulmonares em imagens de TC, uma vez que o processo de formação desta energia é baseado nas propriedades e limites dos pulmões e fissuras. Neste contexto, para a realização dos testes sintéticos, a energia externa utilizada é o resultado

do filtro de detecção de bordas Canny aplicado ao espaço que contém o volume.

Para a análise e discussão dos resultados são consideradas as medidas de distância média μ_d juntamente com desvio padrão σ_d e maior distância \max_d descritas na seção 3.2.3, além das medidas de ajustes descritas na seção 3.2.3.1.

Todavia dentre as medidas de ajustes descritas, apenas as métricas de ajuste de tamanho Fit_T e ajuste de forma Fit_F são consideradas, pois as demais medidas (Fit_{xy} e Fit_I) em todos os casos de testes obtêm resultados semelhantes próximo ao valor máximo. Assim, apesar de retratar o sucesso dos testes realizados, não agrega informação útil que possa ser utilizada em uma análise comparativa entre os distintos casos de testes.

Para proporcionar uma melhor interpretação dos dados e discussão dos resultados, os mesmos são apresentados em duas partes considerando a composição da energia interna utilizada. Por fim, é realizada uma discussão sobre os aspectos gerais contrapondo a energia interna com força de curvatura e com força balão.

C.1 Energia interna com Força de Curvatura

A seguir são apresentados os resultados da segmentação dos objetos sintéticos por MSA utilizando energia interna com força de curvatura. Os resultados são dispostos, para cada forma sintética, na seguinte configuração: tabela com métricas de distância, figura com gráfico comparativo da distância média μ_d , figura com exemplos da segmentação obtida para cada tipo de malha e figura com gráficos das métricas de ajuste de tamanho Fit_T e ajuste de forma Fit_F . Em seguida, uma discussão geral é realizada, abordando os aspectos observados nos resultados obtidos e os justificando.

C.1.1 Cilindro

São detalhados os valores μ_d , σ_d e \max_d obtidos com cada uma das malhas testadas para cada quantidade de pontos de controle utilizados na segmentação do cilindro na Tabela C.1. Um gráfico comparativo, entre as distâncias médias obtidas com cada tipo de malha utilizada na segmentação do cilindro, é ilustrado Na Figura C.3. As segmentações resultantes para os três tipos de malha com as quantidades de 100, 400 e 2500 pontos são ilustradas na Figura C.4. Já os gráficos com as medidas Fit_T e Fit_F são ilustrados na Figura C.5.

Tabela C.1: resultados de média, desvio padrão e máxima distâncias baseada na segmentação do cilindro obtida pelo MSA com força de curvatura.

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	1,20	2,32	10,00	1,10	2,30	11,00	1,02	1,12	5,00
200	0,95	0,96	6,32	0,67	0,81	5,00	0,73	1,26	7,00
300	0,74	0,89	5,66	0,58	0,84	5,66	0,55	1,15	6,00
400	0,60	1,41	7,00	0,51	1,33	6,40	0,43	0,68	4,00
500	0,53	0,86	5,00	0,48	0,78	5,00	0,42	0,73	4,47
600	0,48	1,08	5,83	0,43	1,03	5,39	0,39	0,82	5,00
700	0,47	0,59	4,00	0,41	0,55	4,00	0,31	0,61	4,00
800	0,40	0,99	5,66	0,32	0,89	5,00	0,27	0,46	3,00
900	0,35	0,58	4,47	0,26	0,66	4,00	0,24	0,56	4,00
1000	0,28	0,51	4,35	0,25	0,46	3,00	0,23	0,43	2,83
1300	0,28	0,54	3,61	0,23	0,45	2,83	0,22	0,48	3,00
1500	0,24	0,49	3,61	0,23	0,46	3,00	0,22	0,48	3,00
2000	0,24	0,51	3,00	0,23	0,48	3,00	0,22	0,42	2,24
2500	0,23	0,46	3,00	0,23	0,44	2,83	0,21	0,43	2,00

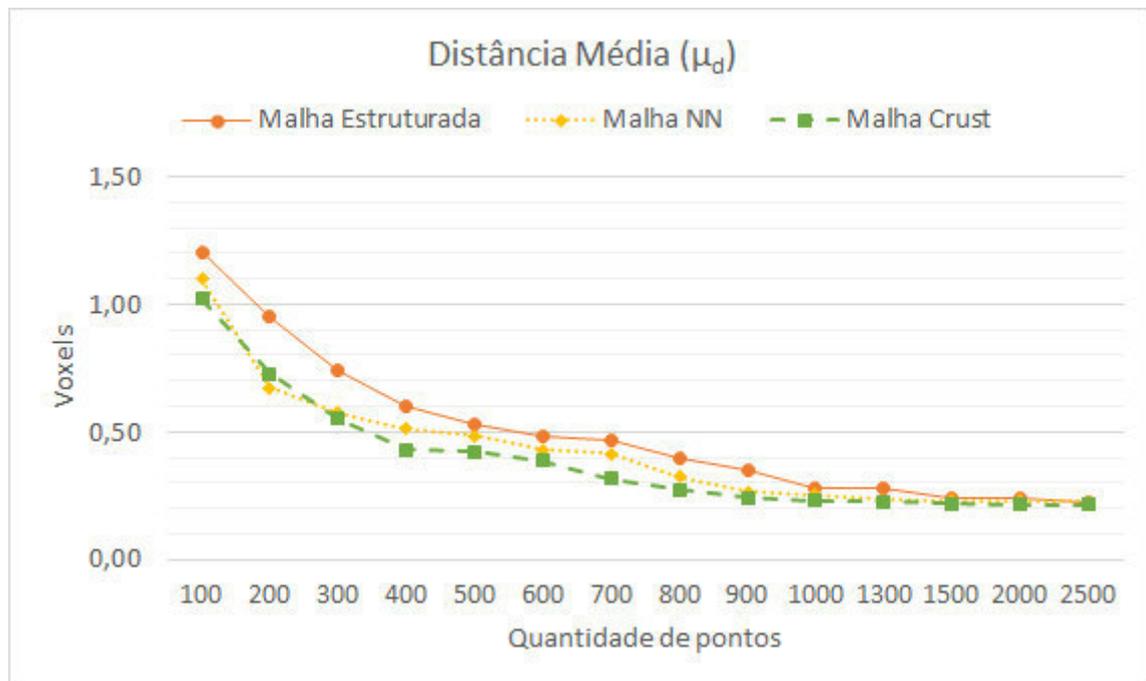


Figura C.3: gráfico da distância média μ_d baseada na segmentação do cilindro obtida pelo MSA com força de curvatura para número de pontos variando de 100 a 2500.

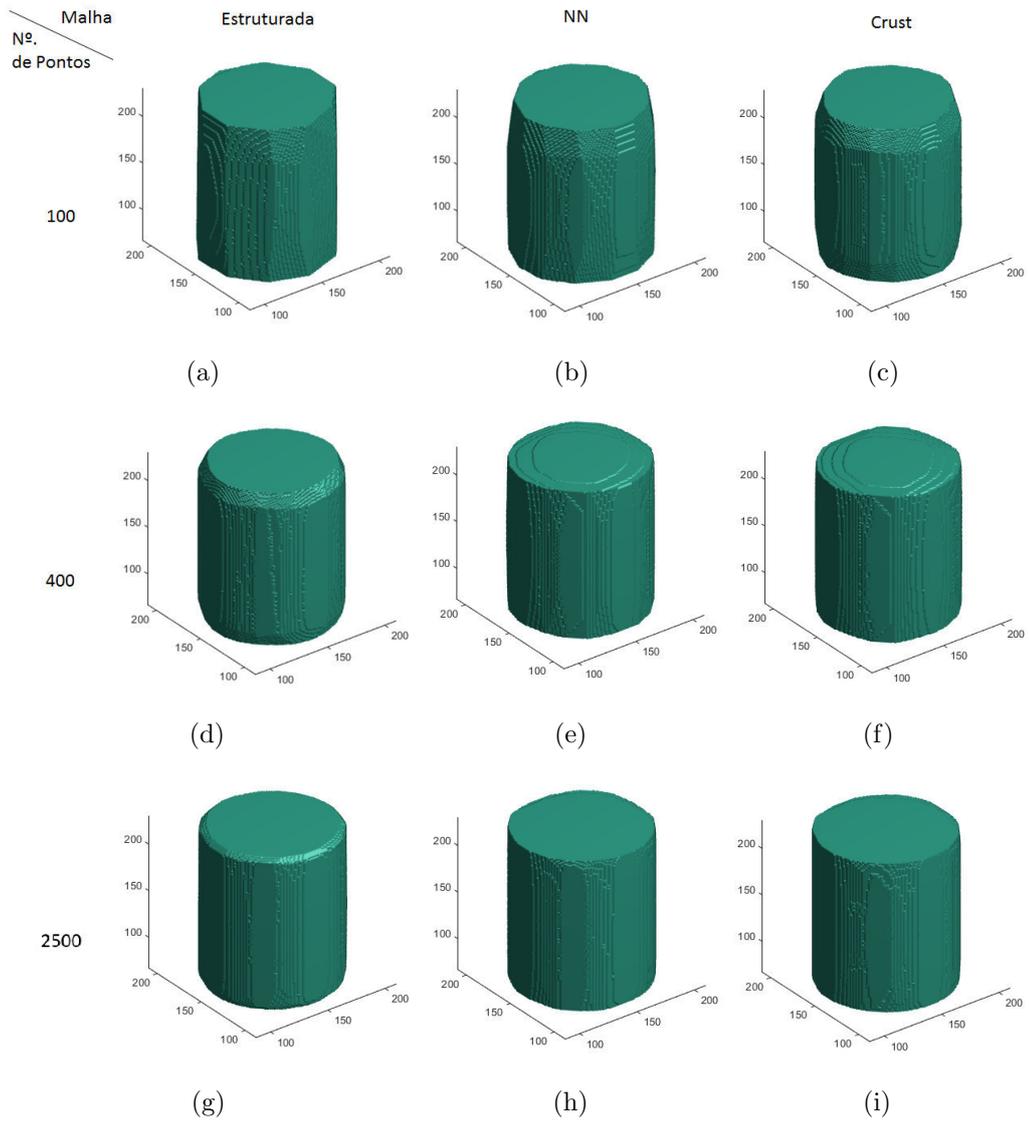
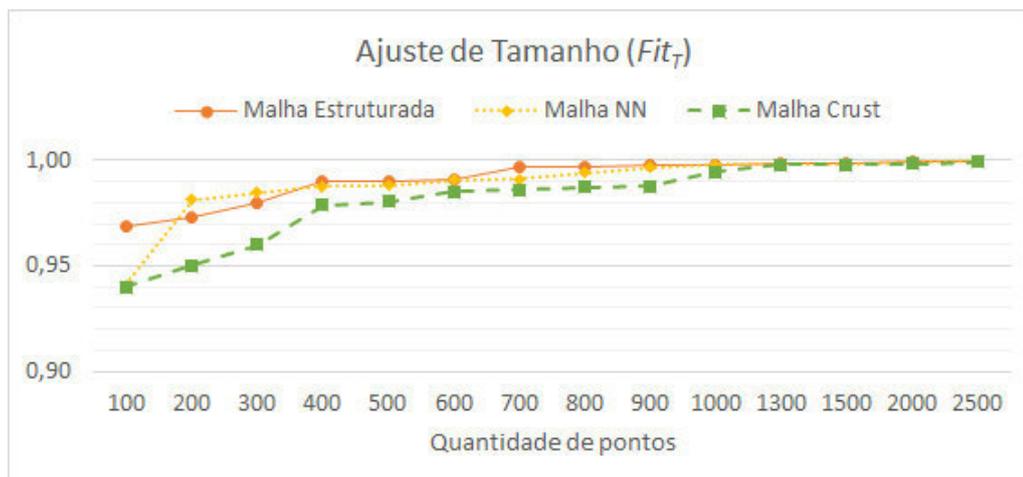
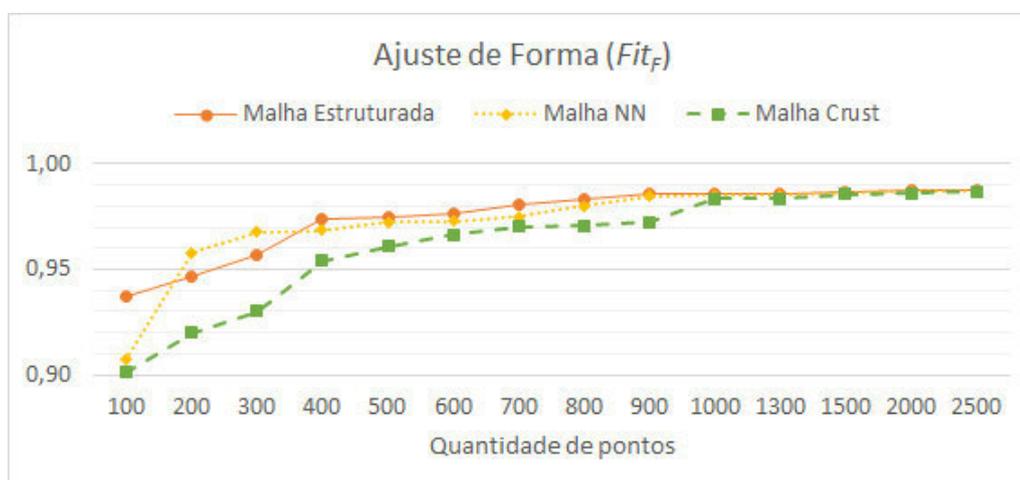


Figura C.4: segmentações obtidas para o cilindro com força de curvatura, para as malhas estruturada, NN e Crust, com 100, 400 e 2500 pontos.



(a)



(b)

Figura C.5: gráficos das medidas de ajuste baseada nas segmentações do cilindro obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500 (a) Fit_T ; e (b) Fit_F .

C.1.2 Cone

Para analisar os resultados da segmentação do cone os valores μ_d , σ_d e \max_d obtidos com cada uma das malhas e quantidade de pontos de controle utilizados são apresentados na Tabela C.2. É ilustrado um gráfico comparativo entre as distâncias médias obtidas na Figura C.6. São ilustradas as segmentações resultantes para os três tipos de malha com as quantidades de 200, 700 e 2500 pontos na Figura C.7. Já os gráficos com as medidas Fit_T e Fit_F também obtidas a partir da segmentação do cone são ilustrados na Figura C.8.

Tabela C.2: resultados de média, desvio padrão e máximo das distâncias baseada na segmentação do cone, obtida pelo MSA com força de curvatura.

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	2,95	1,74	7,0	2,56	4,09	17,0	2,54	3,24	14,0
200	2,72	3,01	10,5	2,19	2,57	9,3	2,36	2,09	9,0
300	2,50	2,42	9,9	1,84	1,46	7,0	1,93	1,64	7,5
400	1,99	1,63	8,0	1,76	1,97	8,5	1,23	1,51	8,0
500	1,74	3,53	13,5	1,61	4,22	15,0	1,11	1,85	8,0
600	1,63	2,91	12,0	1,34	4,24	14,0	1,04	2,31	13,3
700	1,47	2,55	11,0	1,04	1,13	6,4	0,85	1,21	6,0
800	1,39	2,92	11,3	1,01	0,98	5,8	0,72	0,99	6,0
900	0,87	2,47	10,0	0,75	2,54	11,3	0,61	5,11	34,7
1000	0,67	0,88	5,0	0,60	2,64	10,6	0,51	5,20	33,9
1300	0,53	1,38	7,8	0,57	0,82	5,0	0,46	0,93	5,8
1500	0,53	1,08	6,0	0,46	1,88	8,1	0,44	1,03	6,4
2000	0,46	1,09	6,0	0,41	1,14	6,0	0,43	0,89	5,4
2500	0,44	0,94	5,4	0,38	0,81	5,9	0,42	0,86	5,0

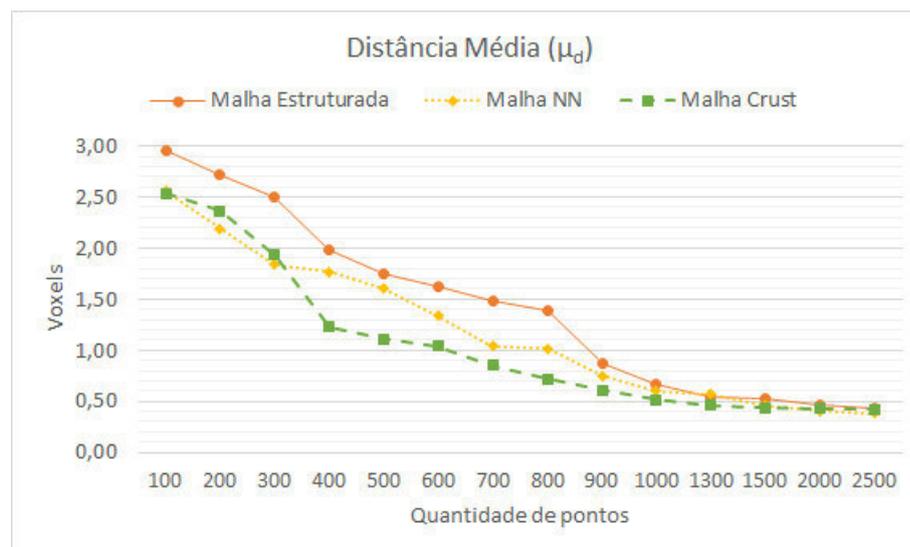


Figura C.6: gráfico da distância média baseada nas segmentações do cone obtidas pelo MSA com força de curvatura para número de pontos variando de 100 a 2500.

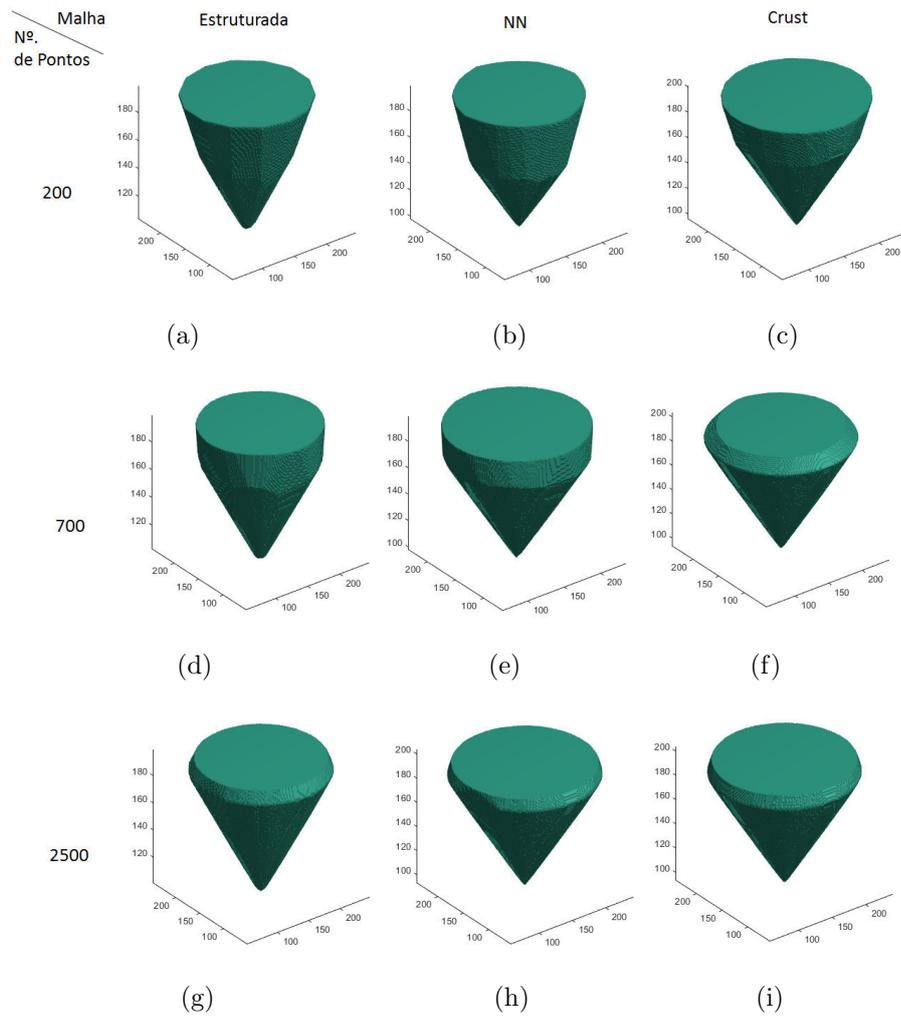
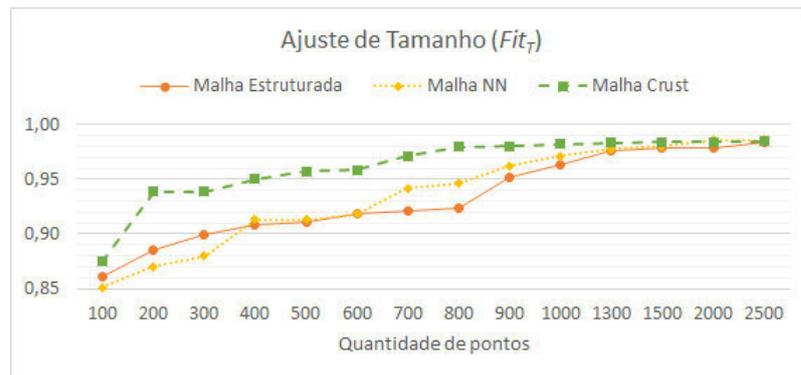
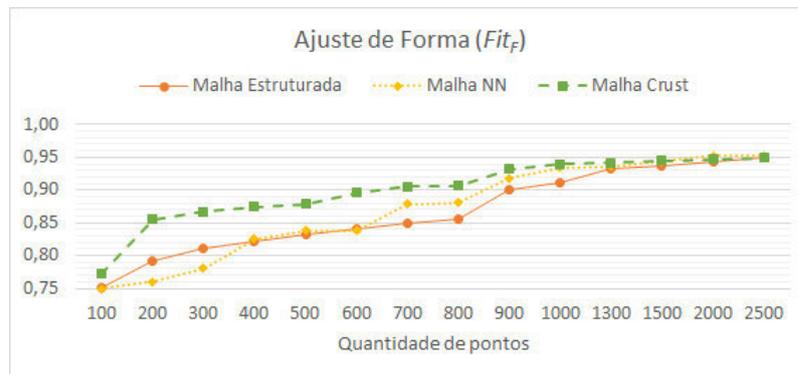


Figura C.7: segmentações obtidas para o cone com força de curvatura e malhas estruturada, NN e Crust, com 200, 700 e 2500 pontos.



(a)



(b)

Figura C.8: gráficos das medidas de ajuste para a segmentação do cone, obtida pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500 (a) Fit_T ; e (b) Fit_F .

C.1.3 Cubo e Pirâmide

Os volumes em forma de cubo e pirâmide são analisados em conjunto, pois ambos são compostos por superfícies planas, e arestas e vértices com alta curvatura. Basicamente, além do formato, a diferença que influencia diretamente a segmentação do MSA consiste na maior curvatura presente nos vértices e arestas da pirâmide.

São descritos os valores μ_d , σ_d e \max_d obtidos com cada uma das malhas testadas para cada quantidade de pontos utilizados na segmentação do cubo e da pirâmide nas Tabelas C.3 e C.4, respectivamente. São ilustrados os gráficos comparativos entre as distâncias médias para o cubo e da pirâmide nas Figuras C.9 e C.11, respectivamente. Na Figura C.10 são ilustradas as segmentações do cubo para os tipos de malha com as quantidades de 200 e 2500 pontos, enquanto na Figura C.12 são ilustradas as segmentações da pirâmide sob as mesmas circunstâncias com as quantidades de 200, 700 e 2500. Por fim, os gráficos de

Fit_T e Fit_F para cubo e pirâmide são ilustrados nas figuras C.13 e C.14, respectivamente.

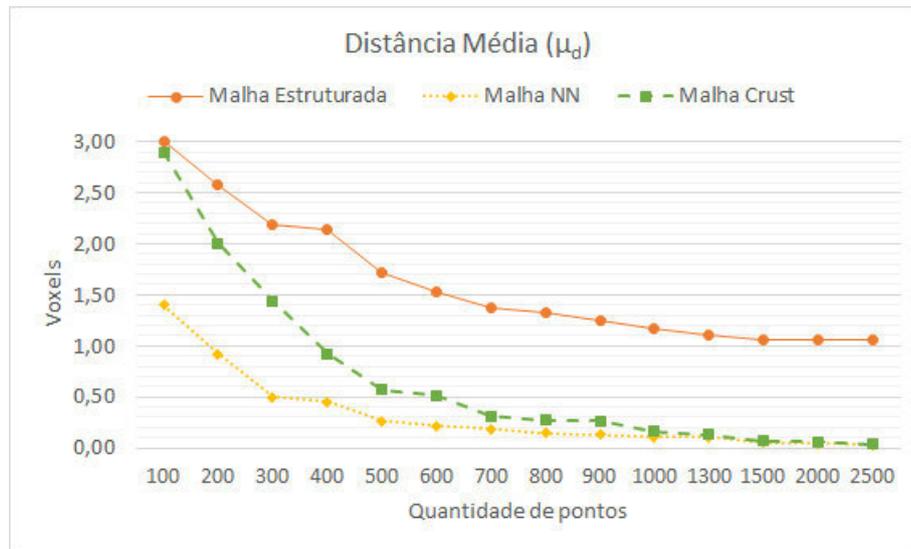


Figura C.9: gráfico da distância média baseada nas segmentações do cubo obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500.

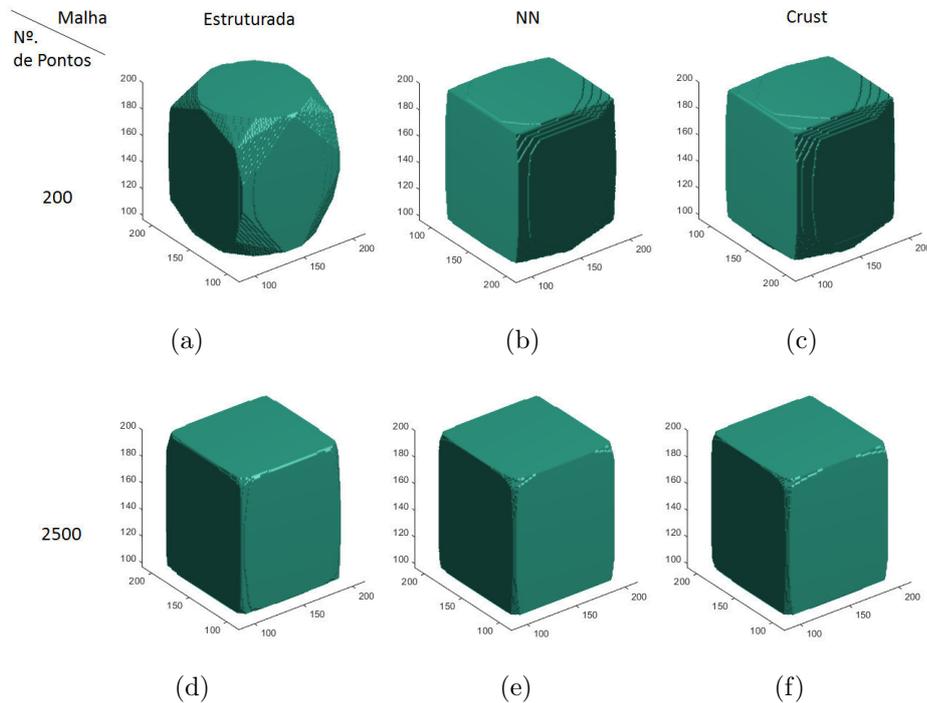


Figura C.10: segmentações obtidas para o cubo com força de curvatura e malhas estruturada, NN e Crust, com 200 e 2500 pontos.

Tabela C.3: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações do cubo obtidas pelo MSA com força de curvatura

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	3,00	3,71	16	1,40	2,13	12	2,90	2,21	12
200	2,57	2,65	12	0,92	1,83	11	2,00	1,87	11
300	2,19	2,09	12	0,50	1,03	7	1,44	1,11	7
400	2,15	2,32	12	0,45	1,12	8	0,92	1,21	8
500	1,71	1,58	9	0,26	0,54	5	0,57	0,67	5
600	1,52	0,71	7	0,22	0,77	7	0,51	0,88	7
700	1,37	1,28	8	0,18	0,67	6	0,31	0,76	7
800	1,33	1,23	8	0,15	0,46	5	0,27	0,53	5
900	1,25	0,99	7	0,13	0,49	5	0,26	0,52	5
1000	1,16	0,68	7	0,11	0,45	5	0,16	0,50	5
1300	1,11	0,91	7	0,11	0,43	5	0,13	0,48	5
1500	1,06	0,58	5	0,05	0,27	4	0,07	0,30	4
2000	1,06	0,69	6	0,05	0,24	3	0,06	0,28	3
2500	1,05	0,46	4	0,03	0,19	2,82	0,04	0,20	3

Tabela C.4: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da pirâmide obtidas pelo MSA com força de curvatura

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	4,00	6,84	26,00	3,62	5,01	23,35	3,40	6,84	26,00
200	3,16	4,24	20,00	2,59	3,79	18,38	2,51	4,24	20,00
300	2,95	4,25	20,52	2,57	3,38	19,80	2,21	4,25	20,52
400	2,57	3,84	19,00	2,02	2,96	17,00	1,99	3,84	19,00
500	2,35	3,76	16,97	1,82	3,45	16,00	1,84	3,76	16,97
600	2,33	2,84	15,56	1,76	4,10	19,00	1,72	2,84	15,56
700	2,13	3,88	20,52	1,61	3,14	18,00	1,52	3,88	20,52
800	1,93	3,62	19,80	1,44	2,50	15,00	1,31	3,62	19,80
900	1,80	3,27	16,00	1,26	3,23	16,97	1,19	3,27	16,00
1000	1,37	3,50	18,38	1,25	2,70	15,00	1,15	3,50	18,38
1300	1,34	2,64	15,56	1,13	2,32	15,00	1,10	2,64	15,56
1500	1,24	2,68	15,00	1,10	2,56	15,00	1,05	2,68	15,00
2000	1,22	2,51	15,00	0,95	2,68	15,56	0,95	2,51	15,00
2500	1,03	2,39	15,00	0,92	2,28	14,87	0,89	2,39	15,00

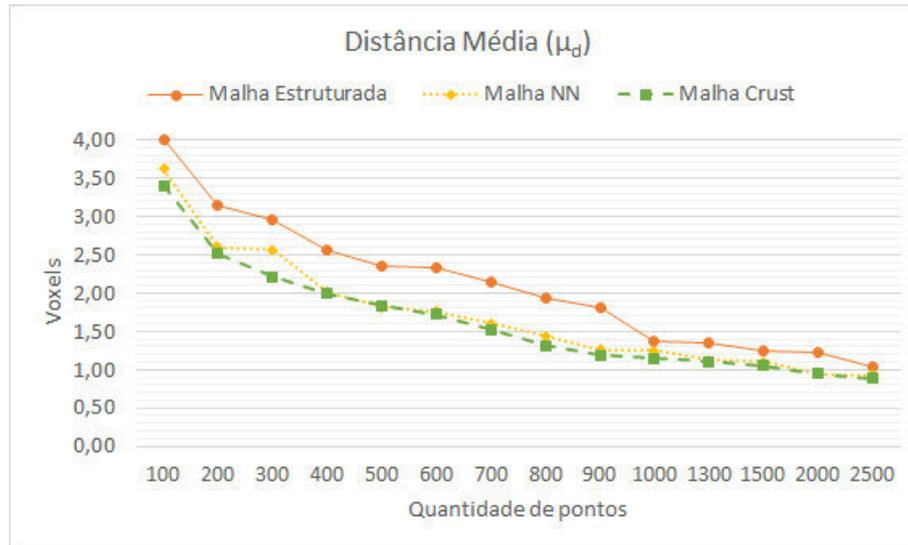


Figura C.11: gráfico da distância média baseada nas segmentações da pirâmide obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500.

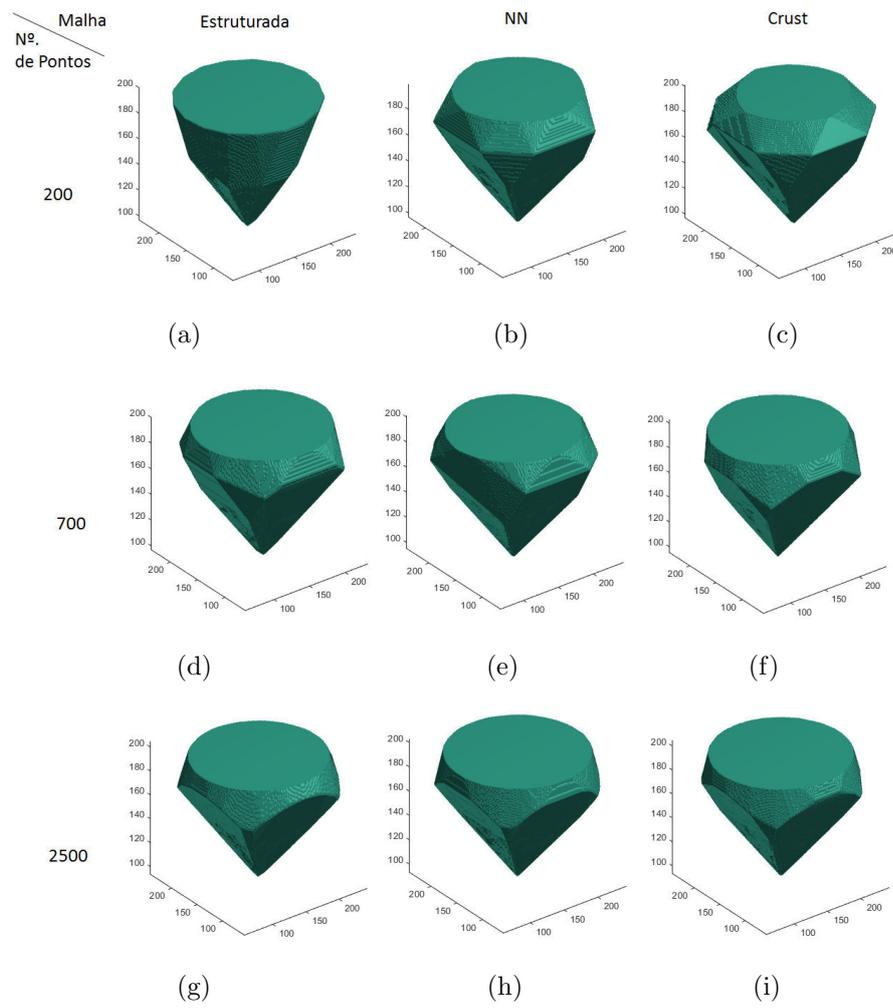
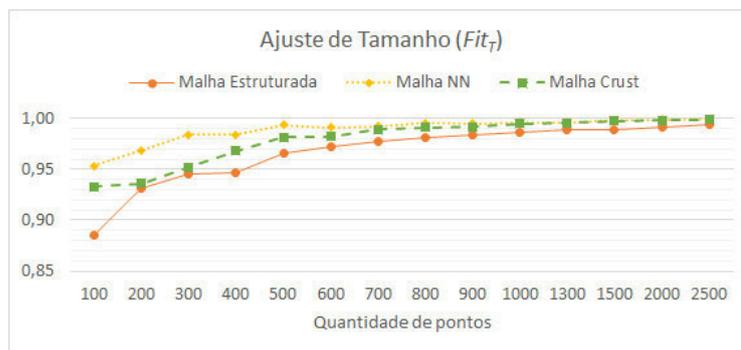
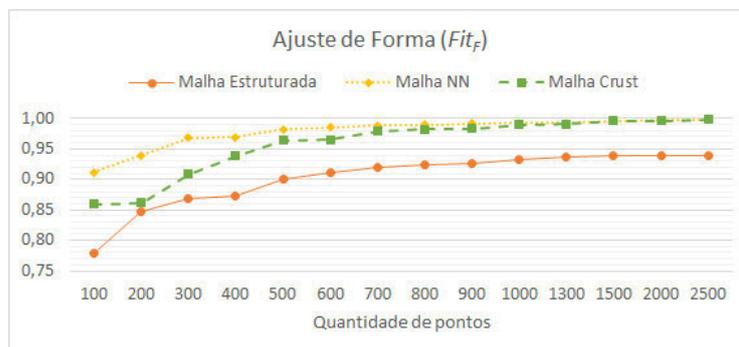


Figura C.12: segmentações obtidas para a pirâmide com força de curvatura e malhas estruturada, NN e Crust, com 200, 700 e 2500 pontos.

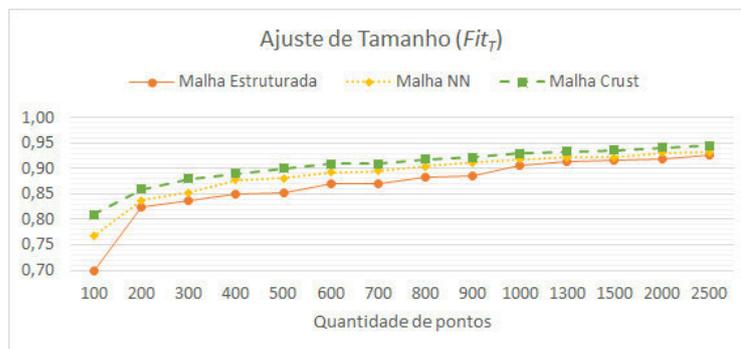


(a)

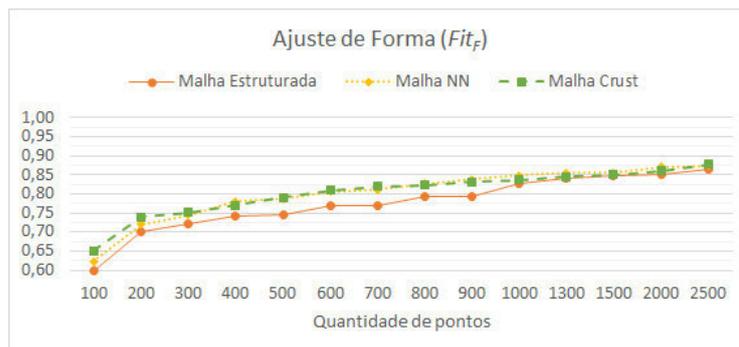


(b)

Figura C.13: gráficos das medidas de ajuste baseada na segmentação do cubo obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .



(a)



(b)

Figura C.14: gráficos das medidas de ajuste baseada na segmentação da pirâmide obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500,

C.1.4 Esfera

Por fim, os resultados das segmentações da esfera por MSA com força de curvatura são descritos. Vale ressaltar que a esfera possui característica diferente dos demais volumes testados, pois nela não há nenhum ponto ou região com alta curvatura, como também não há regiões planas com curvatura nula. Basicamente a curvatura por toda a superfície da esfera é constante.

Para analisar os resultados da segmentação da esfera são apresentados os valores μ_d , σ_d e \max_d , para cada uma das malhas e quantidade de pontos de controle utilizados, na Tabela C.5. Na Figura C.15 são ilustrados em um gráfico comparativo os mesmos valores de μ_d . As segmentações resultantes para os três tipos de malha com as quantidades de 200, 700 e 2500 pontos são ilustradas na Figura C.16. Já na Figura C.17 são ilustrados os gráficos com as medidas Fit_T e Fit_F também obtidas a partir da segmentação da esfera.

Tabela C.5: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da esfera obtidas pelo MSA com força de curvatura

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	2,59	1,83	9,00	2,65	1,21	5,83	2,90	1,01	4,69
200	1,63	1,21	5,74	1,31	0,70	3,46	2,30	0,67	3,00
300	1,20	0,92	4,24	1,01	0,59	2,83	1,77	0,59	2,45
400	0,98	0,71	3,00	0,80	0,56	2,24	1,20	0,57	2,24
500	0,80	0,65	3,00	0,70	0,55	2,24	0,92	0,56	2,24
600	0,67	0,59	2,45	0,63	0,55	2,24	0,81	0,56	2,24
700	0,66	0,58	2,24	0,57	0,54	2,00	0,70	0,55	1,73
800	0,61	0,57	2,24	0,53	0,53	1,73	0,67	0,54	1,73
900	0,53	0,55	2,24	0,47	0,52	1,73	0,64	0,53	1,73
1000	0,46	0,52	2,00	0,42	0,51	1,41	0,62	0,53	1,73
1300	0,43	0,51	1,73	0,39	0,50	1,73	0,47	0,52	1,41
1500	0,36	0,49	1,41	0,35	0,48	1,41	0,43	0,51	1,41
2000	0,33	0,48	1,41	0,32	0,47	1,41	0,39	0,50	1,41
2500	0,30	0,46	1,41	0,31	0,46	1,41	0,38	0,50	1,41

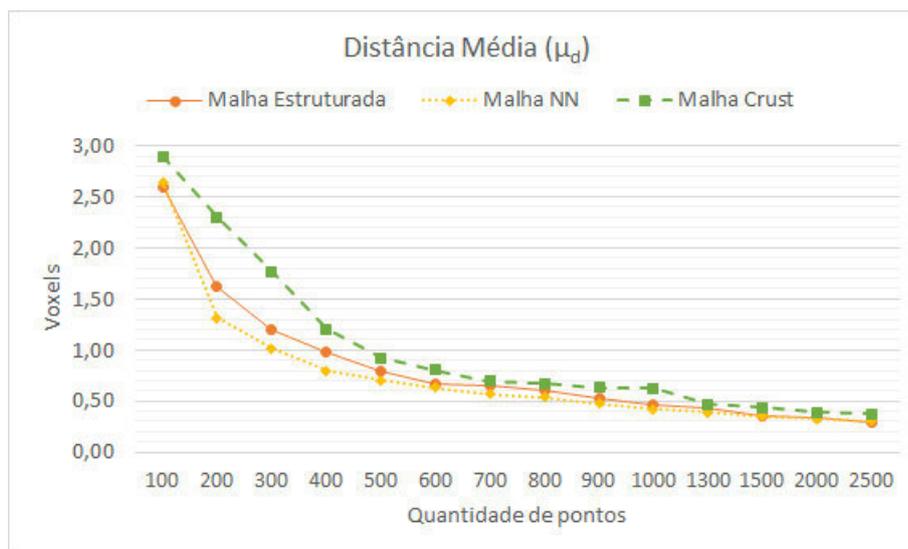


Figura C.15: gráfico da distância média baseada nas segmentações da esfera obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500.

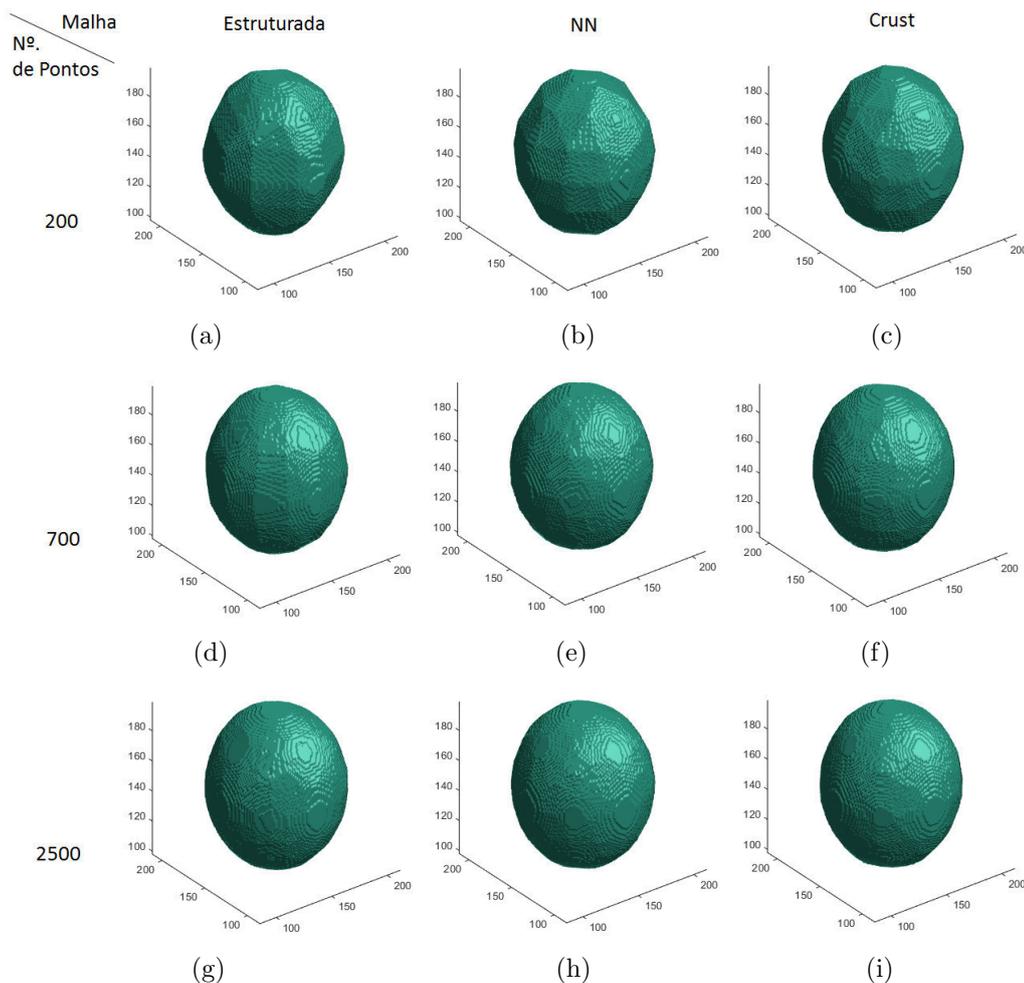
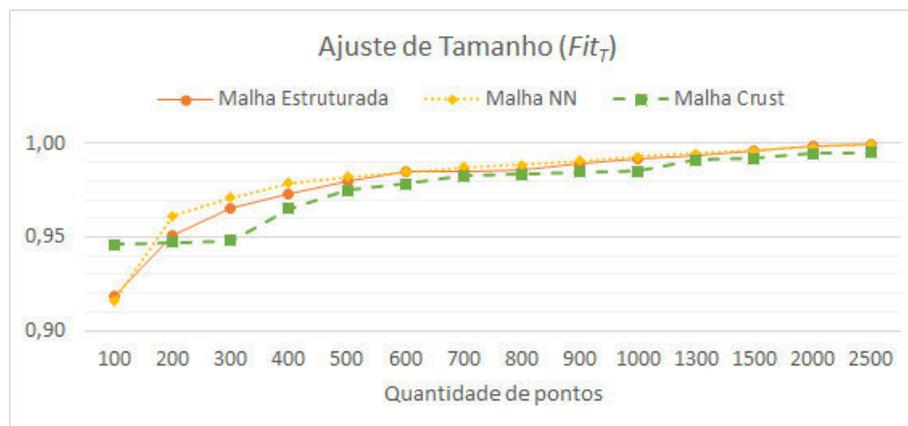
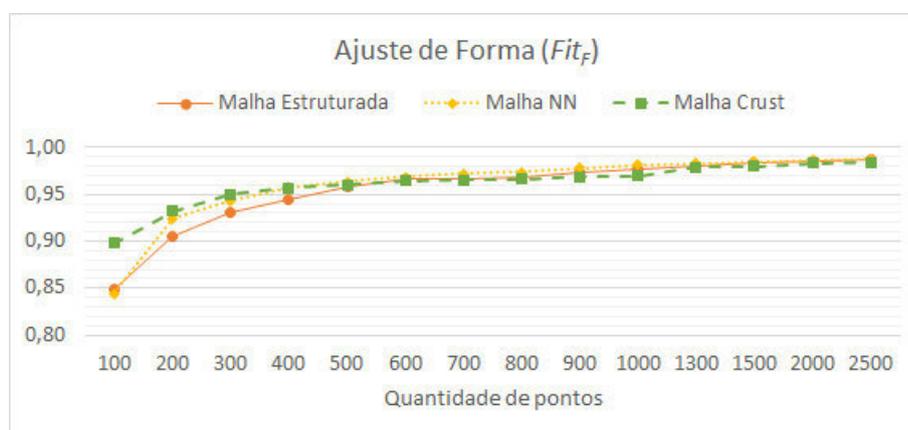


Figura C.16: segmentações obtidas para a esfera com força de curvatura e malhas estruturada, NN e Crust, com 200, 700 e 2500 pontos.



(a)



(b)

Figura C.17: gráficos das medidas de ajuste baseada na segmentação da esfera obtidas pelo MSA com força de curvatura, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .

C.1.5 Análises e Discussões

O fato da malha estruturada retangular possuir as ligações dos pontos praticamente da mesma forma, com quatro ligações sendo uma em cada sentido (esquerda, direita, cima e baixo) sem considerar a topologia do volume em questão, limita o movimento dos pontos não permitindo que os mesmos se distribuam, reposicionando-se para gerar superfícies com menores energia.

É clara a constatação dessa problemática ao se observar, por exemplo, as medidas de distância para a segmentação do cilindro. A melhor solução para o formato em questão é possuir uma maior concentração de pontos na base e no topo do mesmo, porém a estrutura e organização dos pontos na malha estruturada são responsáveis por uma distribuição que, em nenhum nível do eixo vertical, obtém-se uma representação mais precisa

das circunferências que compõem o cilindro. Fato este que se contrasta com a segmentação das malhas não estruturadas NN e Crust. Estas por sua vez conseguem de forma automática posicionar a mesma quantidade de pontos representando com mais precisão a topologia do objeto segmentado. Já o cubo e a pirâmide, por exemplo, não possuem regiões arredondadas, logo, a malha estruturada não apresenta a desvantagem em relação a quantidade de pontos necessária para aproximar bem as regiões curvas.

Uma forma de diminuir tal desvantagem da malha estruturada, melhorando a precisão de sua segmentação final, consiste em aumentar a quantidade de pontos utilizados. A diferença entre as distâncias médias obtidas diminui à medida que a quantidade de pontos aumenta, sendo maior conseqüentemente a quantidade de pontos em cada nível do eixo vertical, tornando mais precisa a representação.

O quanto maior a quantidade de pontos, além de menores μ_d , mais uniforme e regular é a segmentação resultante, como pode ser observado pelo decréscimo de σ_d e max_d nos resultados em geral. O decréscimo do desvio padrão retrata que, apesar de maior a quantidade de pontos utilizada, a distância entre a superfície obtida com MSA e a superfície de referência não varia tanto. Os maiores valores de distância obtidos também são drasticamente reduzidos com o aumento de pontos de controle.

Comparando o desempenho entre as três malhas utilizadas, no geral, os pontos organizados na malha Crust se distribuem de melhor forma e conseguem para a maioria dos testes, valores de μ_d inferiores às demais malhas. A malha NN teve seu desempenho próximo ao da Crust e superior ao desempenho da malha estruturada, que por sua vez, apesar de mais regular, quando não apresenta a média mais baixa, resulta em valores próximos aos da malha NN. Logo, mais uma vez destaca-se a superioridade de malhas não estruturadas e a importância de uma energia interna que seja capaz de atuar nesse tipo de malha.

Outro fator que merece destaque na análise dos resultados apresentados, é a atuação da força de curvatura. A utilização desta força, que tende a deixar a superfície mais suave em detrimento de cantos pontiagudos, dificulta a permanência de pontos nos cantos e arestas, pois essas regiões possuem uma curvatura maior que às demais. Logo, o processo de minimização de energia faz com que os pontos não se fixem nestas extremidades, apresentando falhas nas segmentações.

Esse tipo de falha, decorrente do comportamento característico da força de curvatura, é repetitivo e pode ser observada nos resultados de segmentação dos volumes que possuem cantos e arestas pontiagudas.

O cone, por exemplo, se diferencia do cilindro por possuir regiões de maior curvatura em seu contorno. Regiões estas representadas pelo ponto inferior do cone, além de toda a borda da face superior. Neste caso, a falha na representação destas regiões de alta curvatura deve proporcionar maior erro às segmentações realizadas. Fato que é notório ao se analisar os valores apresentados na Tabela C.2 e o gráfico ilustrado na Figura C.3. Em geral, os valores relacionados à distância apresentados, para a segmentação do cone, são maiores do que os valores obtidos na segmentação do cilindro.

Analisando a segmentação do cubo e da pirâmide, verifica-se um desempenho como esperado, pois os cantos pontiagudos, principalmente para a pirâmide, não são corretamente representados por nenhuma das malhas, conforme pode ser observado nas Figuras C.10 e C.12 e retratado pelos altos valores de max_d apresentado nas Tabelas C.3 e C.4.

Em relação às segmentações da pirâmide, as medidas de ajuste de forma Fit_F também são extremamente afetadas pela incapacidade do MSA com força de curvatura segmentar corretamente os cantos pontiagudos principalmente da pirâmide. Na Figura C.14 constata-se que os valores de Fit_F não ultrapassam 0,90 e para a menor quantidade de pontos testada as malhas estruturada, NN e Crust obtém-se 0,60, 0,62 e 0,65, respectivamente.

Já a esfera, por exemplo, por não apresentar regiões de alta curvatura, apresenta resultados de segmentação consistentes com a configuração do MSA utilizada. Para a segmentação da esfera, após atingir a energia externa mínima no espaço, só resta ao MSA distribuir os pontos sobre a superfície do objeto a fim de obter uma melhor representação. É notório que para a representação completamente correta de uma esfera em um espaço digital, a quantidade de pontos ideal é a quantidade total de pontos que forma a superfície desta esfera, pois para quantidades menores, arestas são geradas e a superfície em vez de totalmente curva começa a apresentar traços retos.

Nesse sentido, as grandes distâncias obtidas para quantidades menores de pontos observadas na Tabela C.5, bem como os menores valores das métricas de ajuste, ilustrados na Figura C.17 são plenamente justificáveis. À medida em que a quantidade de pontos de controle é majorada, a segmentação obtém melhores resultados, chegando a atingir valores de μ_d menores que um voxel juntamente com pequenos valores de σ_d .

C.2 Energia interna com Força Balão

Nesta seção são apresentados e analisados os resultados da segmentação dos objetos sintéticos por MSA utilizando energia interna com força balão. Os resultados são dispostos de forma semelhante à realizada na seção anterior. Para cada forma sintética é apresentada uma Tabela com métricas de distância, μ_d , σ_d e max_d , uma Figura com gráfico comparativo das distâncias médias, uma Figura com exemplos da segmentação obtida para cada tipo de malha com quantidade distinta de pontos e, por fim, uma Figura com gráficos das métricas de ajuste de tamanho (Fit_T) e ajuste de forma (Fit_F).

C.2.1 Cilindro

Os dados referente as segmentações do cilindro com força balão são apresentados na Tabela C.6 que contém os valores de μ_d , σ_d e max_d obtidos com cada uma das malhas testadas para cada quantidade de pontos de controle utilizados. Na Figura C.18 é ilustrado um gráfico comparativo entre as distâncias médias obtidas com cada tipo de malha utilizada na segmentação do cilindro. Na Figura C.19 são ilustradas as segmentações resultantes para os três tipos de malha com as quantidades de 200, 600 e 2500 pontos e na Figura C.20 são ilustrados os gráficos com as medidas Fit_T e Fit_F também obtidas a partir da segmentação do cilindro.

Tabela C.6: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações do cilindro obtidas pelo MSA com força balão

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	max_d	μ_d	σ_d	max_d	μ_d	σ_d	max_d
100	1,16	1,42	9,85	0,96	1,47	9,00	0,29	0,48	3,61
200	1,10	1,56	8,00	0,92	1,44	8,00	0,26	0,44	1,41
300	0,96	1,59	8,00	0,90	1,57	7,00	0,26	0,43	1,00
400	0,92	1,13	7,00	0,81	1,31	9,00	0,25	0,44	1,00
500	0,87	1,40	7,00	0,76	1,27	7,00	0,24	0,43	1,00
600	0,80	1,45	7,00	0,65	0,83	6,00	0,24	0,42	1,00
700	0,70	1,54	7,00	0,54	1,06	7,00	0,23	0,43	1,00
800	0,50	0,75	4,00	0,53	1,10	7,00	0,23	0,42	1,41
900	0,49	0,74	4,00	0,49	0,60	3,61	0,23	0,42	1,41
1000	0,45	1,02	7,00	0,38	0,96	7,00	0,22	0,41	1,00
1300	0,44	0,59	3,00	0,37	0,65	3,16	0,22	0,41	1,00
1500	0,41	0,83	5,00	0,24	0,45	3,00	0,21	0,41	1,41
2000	0,38	0,58	3,16	0,19	0,39	1,00	0,21	0,41	1,00
2500	0,35	0,66	4,00	0,19	0,39	2,00	0,21	0,41	1,00

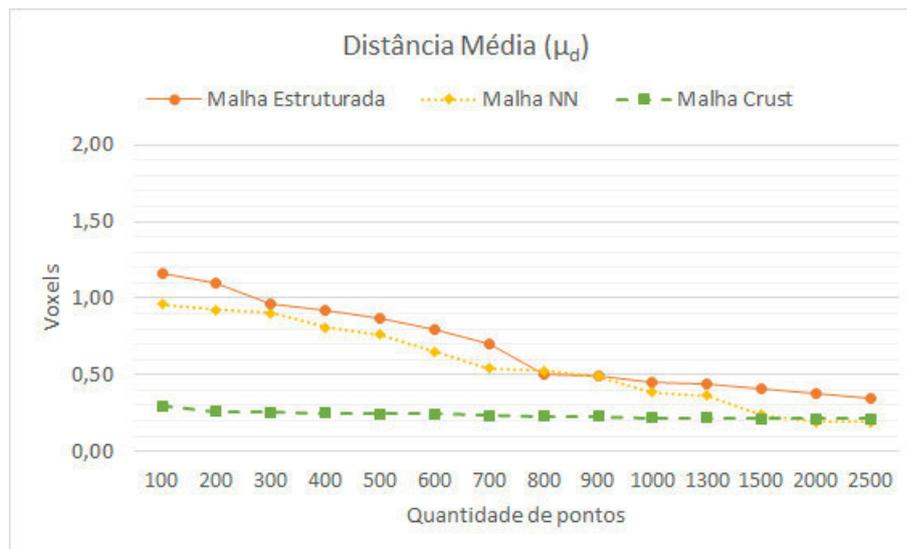


Figura C.18: gráfico da distância média baseada nas segmentações do cilindro obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.

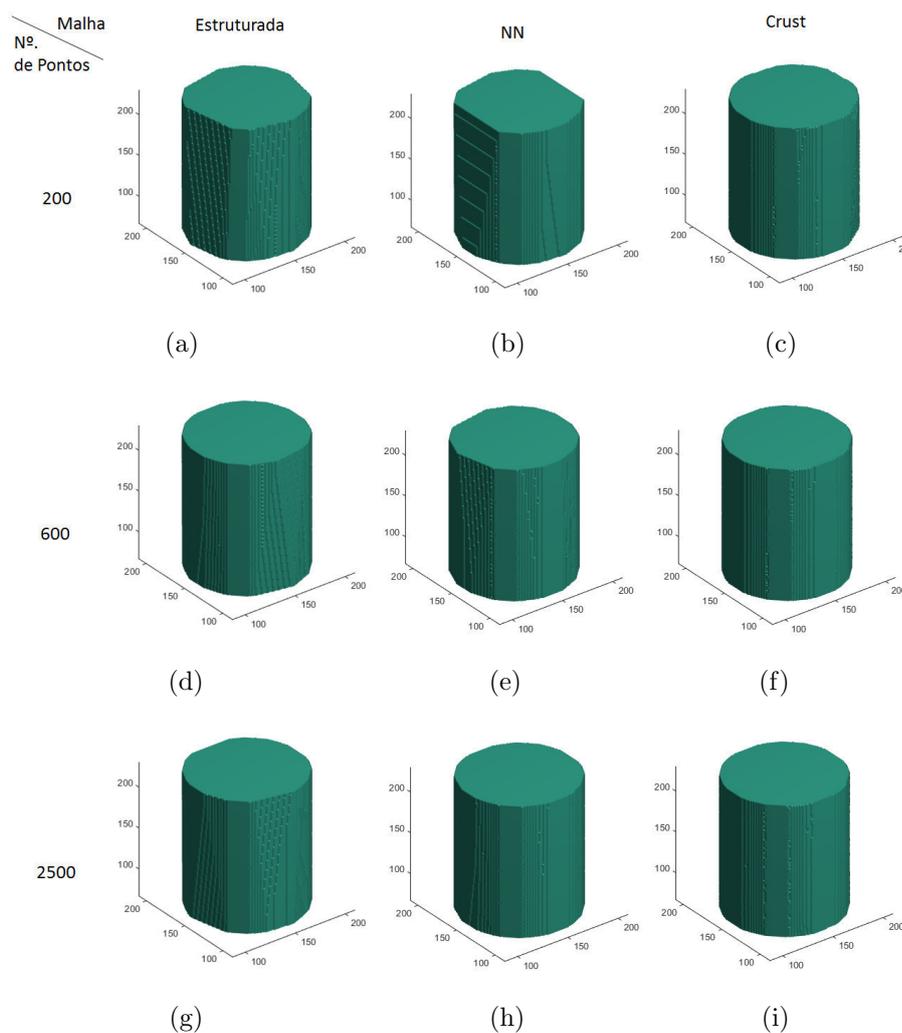
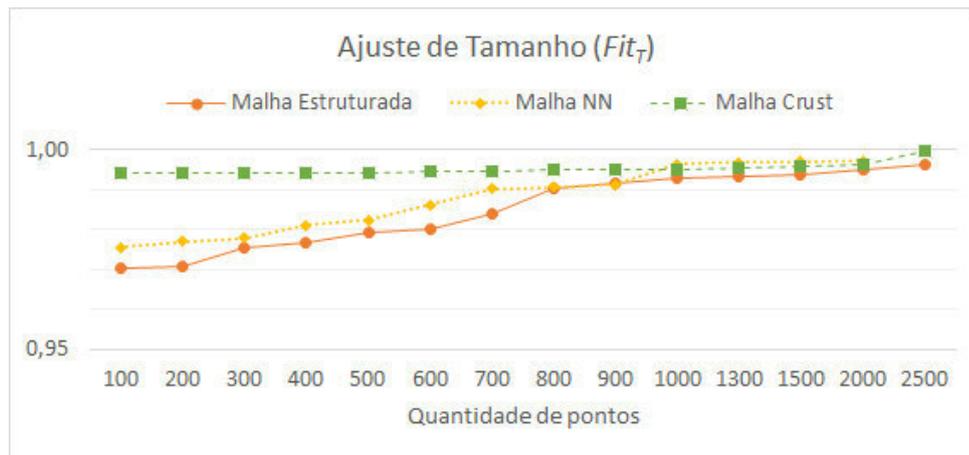
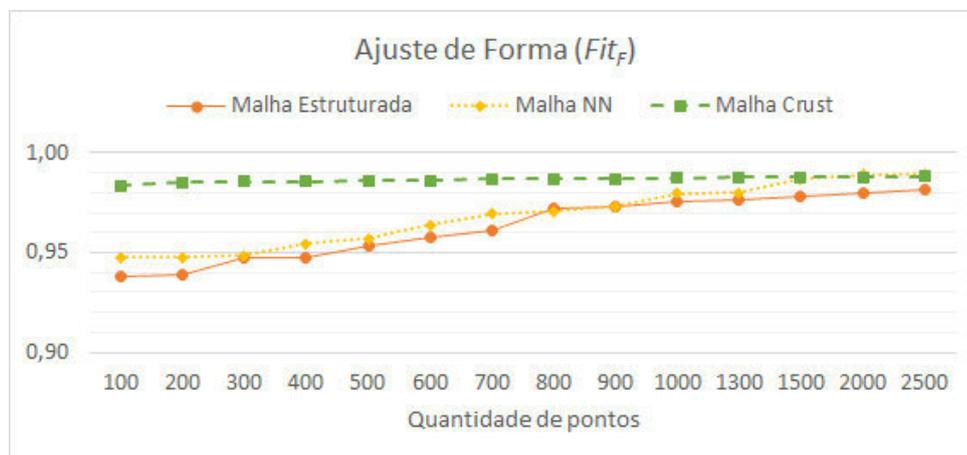


Figura C.19: segmentações obtidas para o cilindro com força balão e malhas estruturada, NN e Crust, com 200, 600 e 2500 pontos.



(a)



(b)

Figura C.20: gráficos das medidas de ajuste baseada na segmentação do cilindro obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .

C.2.2 Cone

Para analisar os resultados da segmentação do cone são apresentados na Tabela C.7 os valores μ_d , σ_d e \max_d obtidos com cada uma das malhas e quantidade de pontos de controle utilizados. Na Figura C.21 é ilustrado um gráfico comparativo entre as distâncias médias obtidas, na Figura C.22 são ilustradas as segmentações resultantes para os três tipos de malha com as quantidades de 100 e 2500 pontos e na Figura C.23 são ilustrados os gráficos com as medidas Fit_T e Fit_F também obtidas a partir da segmentação do cone.

Tabela C.7: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações do cone obtidas pelo MSA com força balão

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	0,71	0,82	6,40	0,53	0,54	3,61	0,58	0,56	3,00
200	0,56	0,54	2,83	0,49	0,51	2,24	0,55	0,50	1,41
300	0,55	0,51	2,24	0,45	0,49	1,41	0,55	0,50	1,41
400	0,55	0,50	1,41	0,44	0,46	1,41	0,54	0,50	1,41
500	0,55	0,50	1,41	0,44	0,50	1,41	0,54	0,50	1,41
600	0,54	0,50	1,41	0,44	0,50	1,41	0,54	0,50	1,41
700	0,54	0,50	1,41	0,43	0,50	1,41	0,54	0,50	1,41
800	0,54	0,50	1,41	0,43	0,50	1,41	0,54	0,50	1,41
900	0,54	0,50	1,41	0,43	0,50	1,41	0,54	0,50	1,41
1000	0,52	0,50	1,41	0,42	0,49	1,41	0,54	0,50	1,41
1300	0,52	0,50	1,41	0,40	0,50	1,41	0,54	0,50	1,41
1500	0,51	0,50	1,41	0,38	0,50	1,41	0,54	0,50	1,41
2000	0,50	0,50	1,41	0,29	0,50	1,41	0,54	0,50	1,41
2500	0,47	0,50	1,41	0,27	0,50	1,41	0,53	0,50	1,41

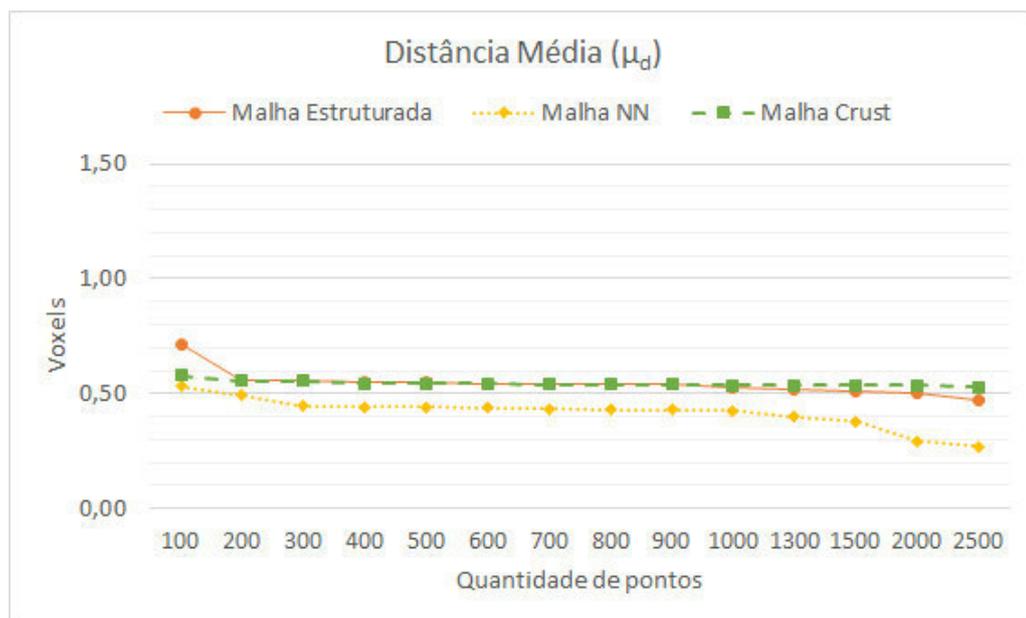


Figura C.21: gráfico da distância média baseada nas segmentações do cone obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.

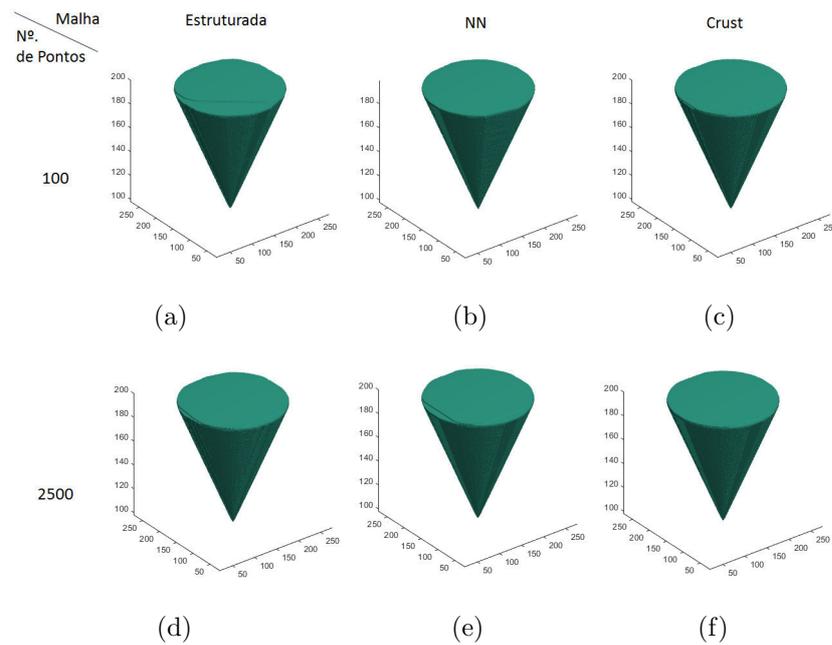
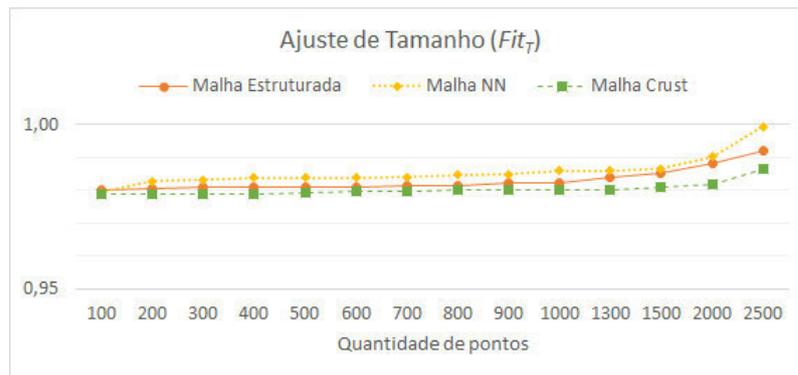


Figura C.22: segmentações obtidas para o cone com força balão e malhas estruturada, NN e Crust, com 100 e 2500 pontos.

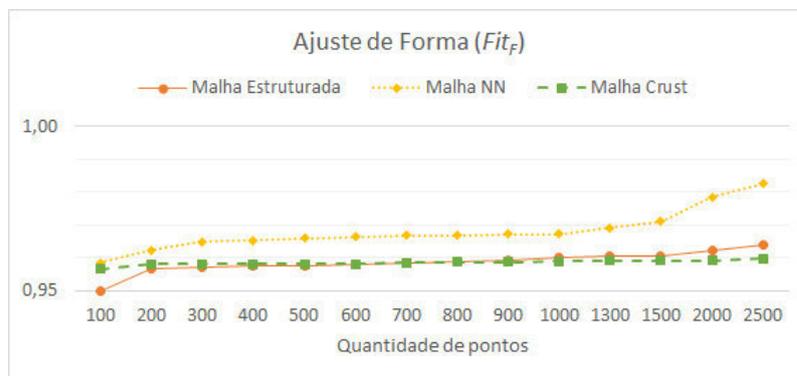
C.2.3 Cubo e Pirâmide

Nesta seção os volumes em forma de cubo e pirâmide são novamente analisados em conjunto, pelos mesmos motivos apresentados na seção anterior.

As métricas μ_d , σ_d e \max_d obtidas na segmentação do cubo foram as mesmas para todas as quantidades de pontos e malhas, sendo estas 0,01, 0,09 e 1 respectivamente. Na Tabela C.8 são descritos os valores de μ_d , σ_d e \max_d obtidos com cada uma das malhas testadas para cada quantidade de pontos utilizados na segmentação da pirâmide. Os gráficos comparativos entre as distâncias médias obtidas na segmentação do cubo e da pirâmide são ilustrados nas Figuras C.24 e C.25, respectivamente. As segmentações do cubo e pirâmide para os tipos de malha apenas com a quantidades de 100 pontos são ilustradas na Figura C.26. Finalmente, nas Figuras C.13 e C.14 são ilustrados os gráficos de Fit_T e Fit_F para cubo e pirâmide, respectivamente.



(a)



(b)

Figura C.23: gráficos das medidas de ajuste baseada na segmentação do cone obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .

Tabela C.8: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da pirâmide obtidas pelo MSA com força balão

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	0,49	0,49	1,41	0,48	0,50	1,41	0,47	0,50	1,41
200	0,49	0,49	1,41	0,48	0,50	1,41	0,40	0,61	1,41
300	0,49	0,50	1,41	0,46	0,50	1,41	0,40	0,61	1,41
400	0,46	0,50	1,41	0,46	0,49	1,41	0,40	0,61	1,41
500	0,45	0,50	1,41	0,45	0,50	1,41	0,40	0,61	1,41
600	0,44	0,50	1,41	0,45	0,49	1,41	0,40	0,61	1,41
700	0,44	0,50	1,41	0,45	0,49	1,41	0,39	0,61	1,41
800	0,44	0,50	1,41	0,45	0,50	1,41	0,39	0,61	1,41
900	0,44	0,50	1,41	0,44	0,50	1,41	0,39	0,62	1,41
1000	0,43	0,50	1,41	0,42	0,49	1,41	0,39	0,62	1,41
1300	0,42	0,49	1,41	0,41	0,50	1,41	0,39	0,62	1,41
1500	0,41	0,50	1,41	0,41	0,50	1,41	0,38	0,62	1,41
2000	0,41	0,50	1,41	0,41	0,50	1,41	0,38	0,61	1,41
2500	0,41	0,50	1,41	0,41	0,50	1,41	0,38	0,61	1,41

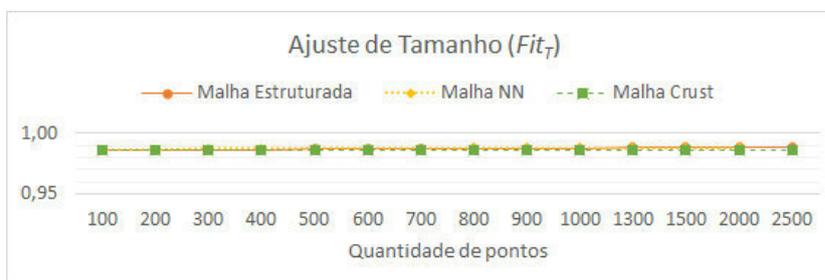


(a)



(b)

Figura C.27: gráficos das medidas de ajuste baseada na segmentação do cubo obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .



(a)



(b)

Figura C.28: gráficos das medidas de ajuste baseada na segmentação da pirâmide obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .



Figura C.24: gráfico da distância média baseada nas segmentações do cubo obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.

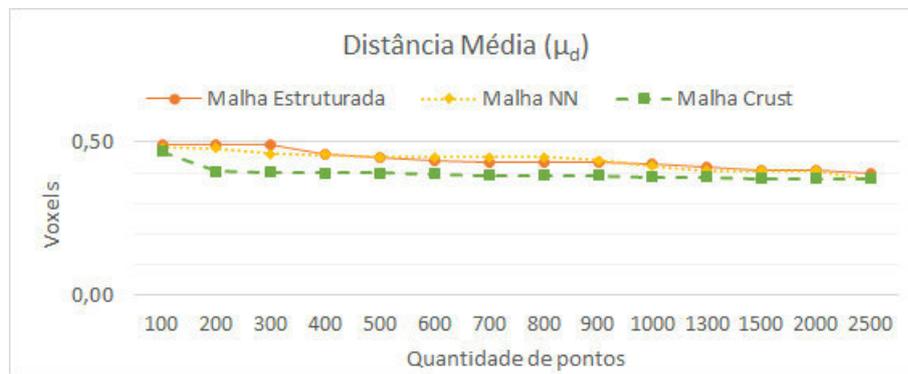


Figura C.25: gráfico da distância média baseada nas segmentações da pirâmide obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.

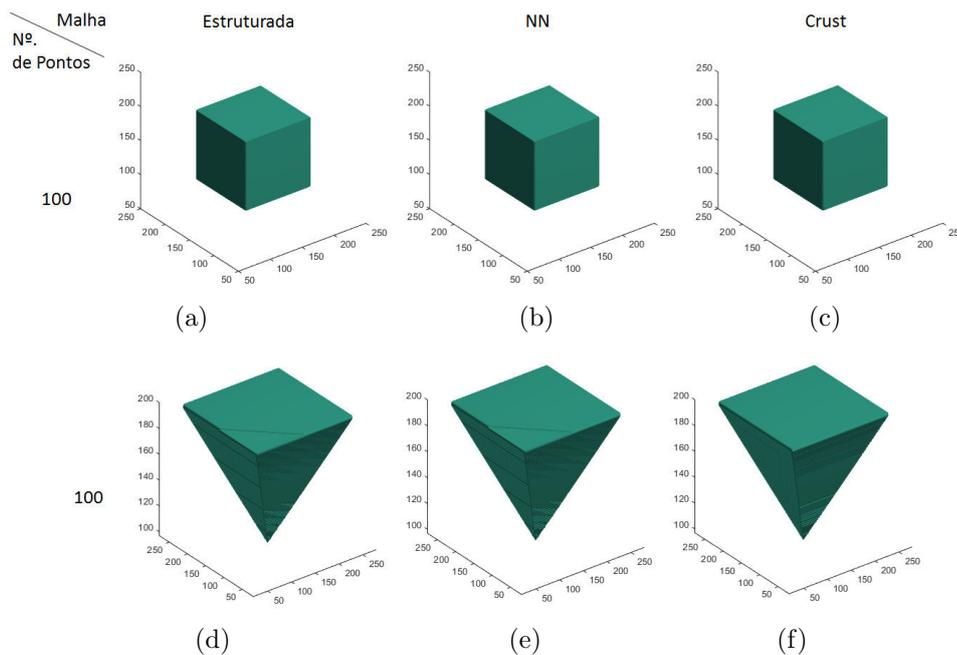


Figura C.26: segmentações obtidas para o cubo e para a pirâmide com força balão com as malhas estruturada, NN e Crust, com 100 pontos.

C.2.4 Esfera

Por fim, são apresentados os resultados das segmentações da esfera por MSA com força balão. Como na esfera não há nenhum ponto ou região com alta curvatura, a curvatura por toda a superfície da esfera é constante, todavia para o MSA a curvatura só é considerada nos pontos de controle, que por sua vez tem o cálculo da força de curvatura ligado diretamente ao posicionamento de seus pontos vizinhos. Por isto, os resultados obtidos para a segmentação da esfera devem depender mais da força de continuidade do que da força balão em si.

Para analisar os resultados da segmentação da esfera na Tabela C.9 são apresentados os valores μ_d , σ_d e \max_d para cada uma das malhas e quantidade de pontos de controle utilizados, bem como na Figura C.29 são ilustrados em um gráfico comparativo os mesmos valores de μ_d . As segmentações resultantes para os três tipos de malha com as quantidades de 500 e 2500 pontos são ilustradas na Figura C.30 e os gráficos com as medidas Fit_T e Fit_F também obtidas a partir da segmentação da esfera são ilustrados na Figura C.31.

Tabela C.9: resultados de média, desvio padrão e máximo das distâncias baseada nas segmentações da esfera obtidas pelo MSA com força balão

Nº de pontos	Malha estruturada			Malha kNN			Malha Crust		
	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d	μ_d	σ_d	\max_d
100	2,50	1,62	8,31	1,91	1,76	8,77	1,23	1,02	4,90
200	2,16	2,83	13,08	1,89	1,55	7,00	0,62	0,64	3,46
300	2,06	1,62	7,35	1,84	1,75	7,68	0,44	0,54	2,45
400	2,02	1,85	9,00	1,77	1,69	7,00	0,43	0,54	2,24
500	1,98	2,07	9,00	1,72	1,64	7,00	0,38	0,50	2,00
600	1,88	2,10	9,00	1,64	1,55	7,14	0,38	0,51	2,00
700	1,73	2,18	10,00	1,41	1,32	7,00	0,38	0,48	1,73
800	1,65	1,45	7,00	1,28	1,37	6,00	0,37	0,48	1,41
900	1,58	1,80	9,00	1,27	1,24	6,00	0,37	0,49	2,00
1000	1,42	1,80	8,00	1,17	1,43	6,00	0,37	0,48	1,41
1300	1,33	1,43	7,00	1,03	1,13	6,00	0,37	0,49	2,00
1500	1,33	1,38	7,00	0,80	0,99	5,00	0,36	0,49	1,41
2000	1,23	1,57	8,00	0,80	0,90	4,00	0,36	0,49	1,41
2500	1,13	1,40	8,00	0,69	1,04	5,00	0,36	0,49	1,41

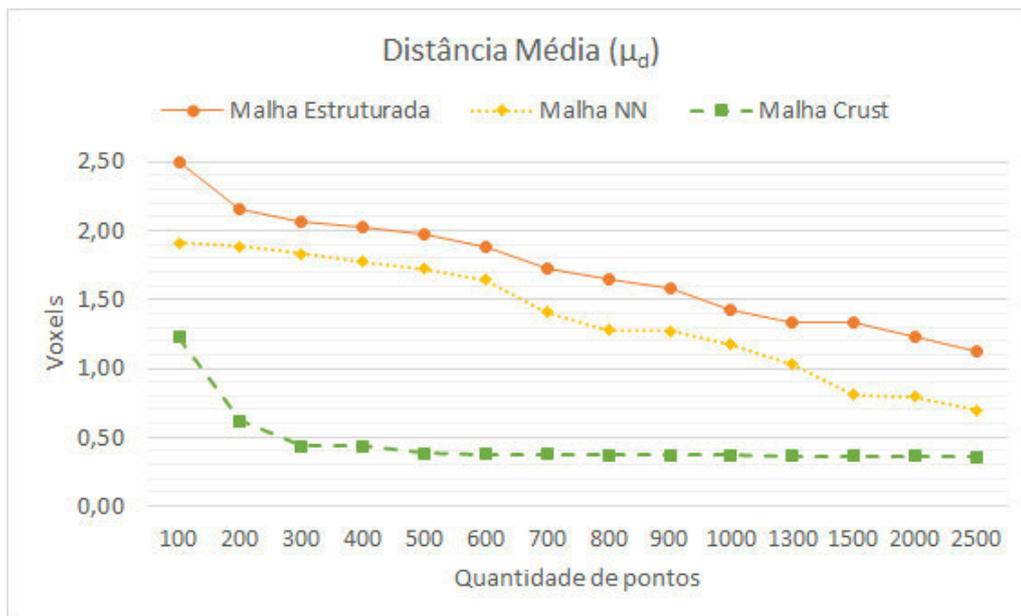


Figura C.29: gráfico da distância média baseada nas segmentações da esfera obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500.

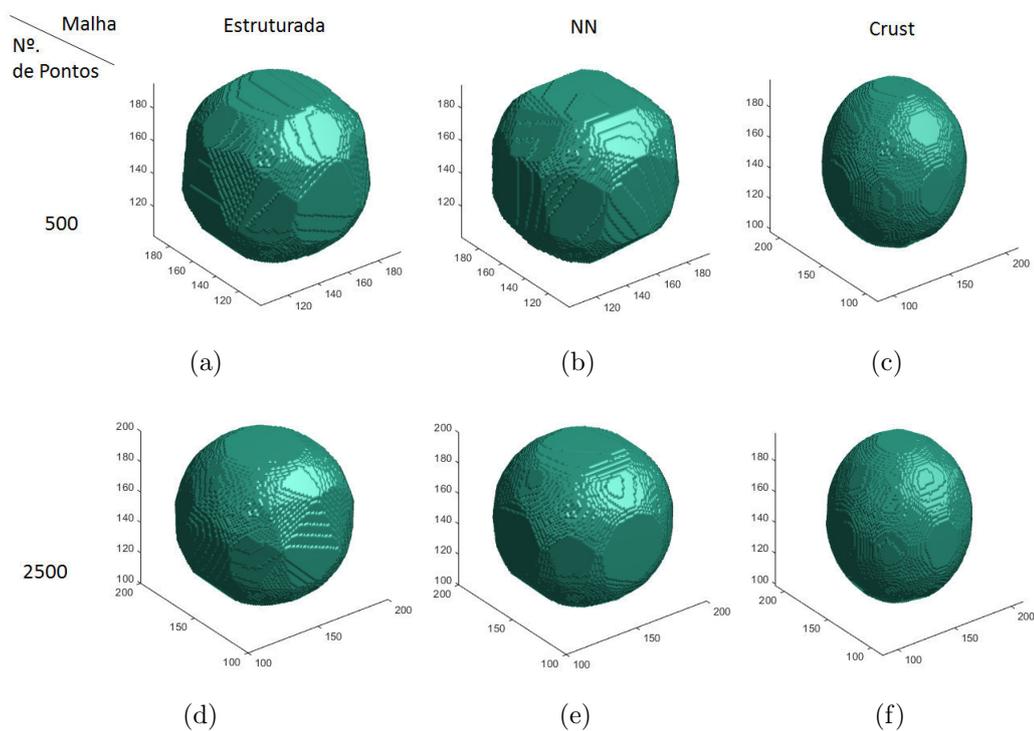
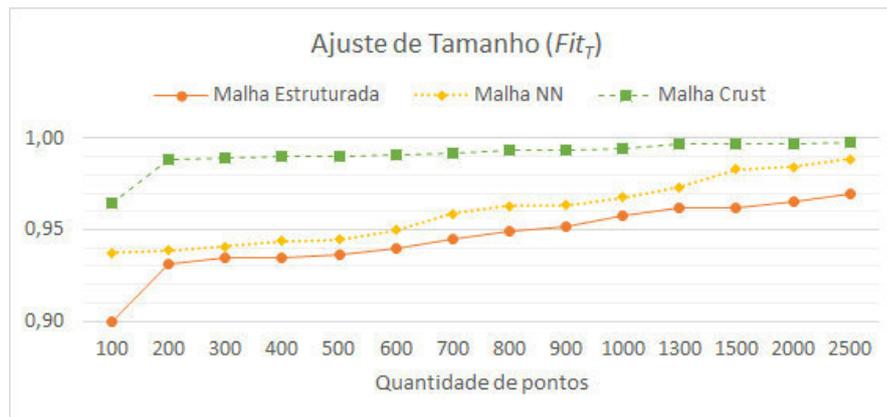
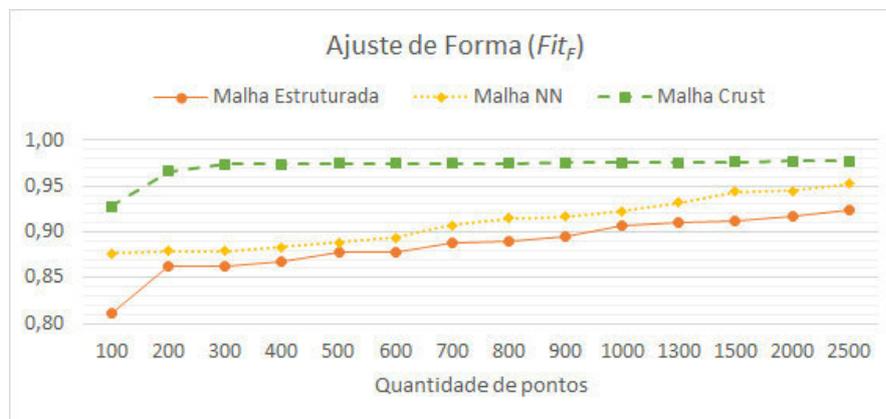


Figura C.30: segmentações obtidas para a esfera com força balão e malhas estruturada, NN e Crust, com 500 e 2500 pontos.



(a)



(b)

Figura C.31: gráficos das medidas de ajuste baseada na segmentação da esfera obtidas pelo MSA com força balão, para número de pontos variando de 100 a 2500, (a) Fit_T ; e (b) Fit_F .

C.2.5 Análises e Discussões

Em geral, todos os casos de testes apresentam resultados precisos com a maioria das distâncias médias menores que um voxel. A malha Crust obtém resultados superiores as demais, provando ter uma maior capacidade de distribuir seus pontos e representar melhor as superfícies alvo. Já a malha estruturada, assim como na maioria dos casos testados com força de curvatura, apresenta piores resultados.

Analisando a segmentação da esfera, por exemplo, observa-se que a malha estruturada obtém o pior desempenho com todos os valores de μ_d acima de 1 voxel, chegando a ultrapassar 2 voxels com as quantidades de 100, 200 e 300 pontos, além de altos valores de max_d . As malhas não estruturadas obtém melhor desempenho com destaque para a malha Crust. Com apenas 200 pontos a malha Crust obtém μ_d de 0,62 voxels e a partir

de 300 pontos de controle os valores de μ_d estão abaixo 0,5 voxels.

É nítido a superioridade da malha Crust sobre as demais, sendo a única malha que obteve resultados na segmentação da esfera melhores ou semelhantes aos resultados obtidos nas segmentações por MSA com força de curvatura. Fato este que comprova, que neste caso, as ligações realizadas na malha Crust conseguem maior equilíbrio na energia interna, fazendo com que os pontos sejam uniformemente distribuídos pela superfície da esfera.

Além disso, é possível notar uma grande vantagem da força balão na composição da energia interna em detrimento da força de curvatura. A força balão por se tratar de uma força que expande a superfície, priorizando as altas curvaturas, não apresenta falha nos cantos pontiagudos e de alta curvatura existentes.

O cone, por exemplo, apresenta uma segmentação com maior qualidade quando utilizada a força balão. As bordas da face superior são bem representadas o que facilita uma melhor distribuição e concentração dos pontos nas regiões de maior importância para obtenção de uma boa representatividade do volume. Além das baixas medidas de distância, as métricas de ajustes retratadas reforçam a qualidade da segmentação do cone realizada pelo MSA com força balão.

As segmentações do cubo e da pirâmide por MSA com força balão compondo a energia interna obtêm alto nível de qualidade independente da quantidade de pontos. As distâncias obtidas são semelhantes para as três malhas e para praticamente todas as quantidades de pontos testadas. Isto acontece porque para uma boa representação dessas formas basta que haja pelo menos um ponto em cada um de seus vértices. Considerando toda a superfície do cubo e da pirâmide, são os vértices que possuem as maiores curvaturas, logo são preferidos pela força balão.

Todavia, justamente por não obter nenhum canto pontiagudo ou região de alta curvatura comparada com as demais regiões do mesmo objeto, a esfera é o único formato utilizado em que as segmentações obtidas com a energia interna composta pela força balão não são totalmente melhores do que as obtidas com energia interna composta pela força de curvatura. O equilíbrio é nítido ao notar que, com a força balão, a malha Crust obtêm os melhores resultados comparando as três diferentes malhas com as duas energias internas, da mesma forma que as malhas estruturada e NN, ainda com força balão, obtêm os dois piores desempenhos.

Apêndice D

Resultados da Segmentação dos Lobos

A segmentação 3D dos lobos pulmonares é realizada por 4 métodos testados, sendo estes:

- Hessiana/Crust - MSA com energia externa Hessiana e malha Crust;
- Hessiana/NN - MSA com energia externa Hessiana e malha NN;
- LBP/Crust - MSA com energia externa LBP e malha Crust; e
- LBP/NN - MSA com energia externa LBP e malha NN.

Neste apêndice são detalhados os valores μ_d e σ_d em milímetros, obtidos para cada método testado na segmentação dos lobos pulmonares. Os valores obtidos para as segmentações dos lobos superior e inferior esquerdo são detalhados nas Tabelas D.1 e D.2, respectivamente. Já os valores obtidos para as segmentações dos lobos superior, médio e inferior direito são detalhados nas Tabelas D.3, D.4 e D.5.

Tabela D.1: resultados de μ_d e σ_d obtidos nas segmentações do lobo superior esquerdo para cada método testado.

Exame	Hessiana/Crust		Hessiana/NN		LBP/Crust		LBP/NN	
	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d
1	0,40	0,97	0,53	1,43	0,57	1,72	0,62	1,53
2	0,72	1,67	0,96	1,93	0,74	1,41	0,80	1,72
3	1,07	2,77	1,57	2,89	0,94	3,23	1,00	3,72
4	0,87	1,72	1,03	2,20	0,80	0,85	0,76	1,09
5	1,54	3,41	1,33	3,57	1,51	2,30	1,55	1,65
6	1,20	3,14	1,19	3,29	1,25	1,39	1,33	1,91
7	0,94	2,49	0,90	2,19	0,80	2,36	0,76	3,02
8	1,69	4,97	1,80	5,38	2,56	8,16	2,64	9,46
9	1,54	4,23	1,44	4,42	0,94	4,73	1,05	5,42
10	0,99	2,30	1,17	2,48	0,92	2,78	1,02	3,22

Tabela D.2: resultados de μ_d e σ_d obtidos nas segmentações do lobo inferior esquerdo para cada método testado.

Exame	Hessiana/Crust		Hessiana/NN		LBP/Crust		LBP/NN	
	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d
1	0,30	0,77	0,42	1,13	0,50	1,51	0,58	2,22
2	1,77	3,75	1,89	4,57	1,53	0,94	1,48	1,14
3	0,70	1,51	1,06	1,74	1,01	8,50	1,07	8,77
4	0,57	1,61	0,63	2,06	0,40	1,23	0,52	1,58
5	0,64	1,86	0,97	2,14	0,48	0,70	0,67	0,80
6	1,34	3,01	1,25	3,12	1,10	2,91	1,18	3,29
7	0,52	1,52	0,56	1,94	1,63	4,99	1,68	5,40
8	1,28	3,42	1,37	3,39	2,55	7,61	2,58	7,75
9	0,90	2,45	0,85	3,14	0,80	2,94	0,90	3,08
10	0,52	1,62	0,57	2,45	0,38	0,61	0,51	0,92

Tabela D.3: resultados de μ_d e σ_d obtidos nas segmentações do lobo superior direito para cada método testado.

Exame	Hessiana/Crust		Hessiana/NN		LBP/Crust		LBP/NN	
	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d
1	3,31	6,87	2,50	6,54	1,51	4,26	1,61	5,13
2	3,33	6,84	3,13	8,34	2,52	2,61	2,45	3,08
3	3,21	10,39	3,46	9,94	3,29	12,12	3,31	12,93
4	1,26	2,63	1,41	3,08	2,16	7,10	2,19	8,10
5	4,82	12,37	4,98	11,74	4,18	2,95	4,28	2,39
6	1,51	3,18	1,39	3,35	1,06	3,98	1,04	4,45
7	2,61	5,93	2,46	6,61	1,51	3,70	1,58	3,74
8	2,41	4,30	2,27	4,51	2,46	2,84	2,40	3,64
9	3,98	6,48	3,81	7,11	4,13	5,98	4,23	6,11
10	1,05	2,27	1,39	2,44	0,77	1,93	0,93	1,92

Tabela D.4: resultados de μ_d e σ_d obtidos nas segmentações do lobo médio direito para cada método testado.

Exame	Hessiana/Crust		Hessiana/NN		LBP/Crust		LBP/NN	
	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d
1	4,57	5,84	4,56	7,59	3,79	2,89	4,07	3,25
2	3,86	7,60	3,99	8,27	3,91	0,00	4,03	0,00
3	–	–	–	–	–	–	–	–
4	2,52	4,10	3,28	5,06	3,57	7,80	3,86	8,21
5	2,45	4,86	2,70	5,21	2,64	2,08	2,89	2,09
6	–	–	–	–	–	–	–	–
7	2,38	3,82	2,28	3,90	2,88	2,32	3,13	1,97
8	3,69	4,64	3,99	4,95	3,47	4,10	3,88	4,25
9	2,65	4,37	2,96	4,60	3,12	4,87	3,21	5,23
10	2,40	4,53	2,68	4,86	2,27	4,00	2,19	5,03

Tabela D.5: resultados de μ_d e σ_d obtidos nas segmentações do lobo inferior direito para cada método testado.

Exame	Hessiana/Crust		Hessiana/NN		LBP/Crust		LBP/NN	
	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d	μ_d	σ_d
1	1,58	3,31	1,79	3,01	1,45	1,03	1,57	1,52
2	0,61	1,52	0,92	1,86	1,92	5,84	2,34	6,12
3	0,94	2,65	1,17	3,04	1,07	9,11	1,31	9,47
4	1,82	3,71	1,98	4,51	1,74	6,40	1,80	7,10
5	2,49	4,86	2,56	4,98	2,59	0,93	2,45	1,07
6	1,71	3,41	1,76	3,67	1,30	4,00	1,28	4,41
7	1,20	3,05	1,15	2,91	1,43	5,12	1,54	6,57
8	2,23	4,59	2,35	4,88	1,55	1,28	1,67	1,64
9	2,11	4,27	2,14	4,58	2,19	4,45	2,50	5,36
10	3,53	8,97	3,93	10,59	4,27	11,66	3,95	10,98