



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

**THOMAZ MAIA DE ALMEIDA**

**MÉTODO DE CONTORNOS ATIVOS RADIAIS 3D: UMA NOVA ABORDAGEM**  
**PARA SEGMENTAÇÃO DE VOLUMES**

**FORTALEZA**

**2019**

THOMAZ MAIA DE ALMEIDA

MÉTODO DE CONTORNOS ATIVOS RADIAIS 3D: UMA NOVA ABORDAGEM PARA  
SEGMENTAÇÃO DE VOLUMES

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Orientador: Prof. Dr. Paulo César Cortez

FORTALEZA

2019

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)

---

A451m Almeida, Thomaz Maia de.  
Método de Contornos Ativos Radiais 3D: Uma nova abordagem para segmentação de volumes /  
Thomaz Maia de Almeida. – 2019.  
120 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação  
em Engenharia de Teleinformática, Fortaleza, 2019.  
Orientação: Prof. Dr. Paulo César Cortez.

1. Método dos Contornos Ativos. 2. Segmentação de Imagens. 3. 3D. 4. Raios Ativos. I. Título.

CDD 621.38

---

THOMAZ MAIA DE ALMEIDA

MÉTODO DE CONTORNOS ATIVOS RADIAIS 3D: UMA NOVA ABORDAGEM PARA  
SEGMENTAÇÃO DE VOLUMES

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas

Aprovada em: 31 de Janeiro de 2019

BANCA EXAMINADORA

---

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

---

Prof. Dr. José Marques Soares  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Pedro Pedrosa Rebouças Filho  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Auzuir Ripardo de Alexandria  
Instituto Federal do Ceará (IFCE)

---

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

À minha mãe, Luciliane Maia

## **AGRADECIMENTOS**

À minha mãe, Maria Luciliane Maia de Almeida, a quem dedico esse trabalho, pelo exemplo de vida e pela oportunidade de estudar.

À minha esposa, Luciana Araújo Gurgel, pela ajuda, paciência e compreensão em todos os momentos dessa jornada.

Ao professor Paulo César Cortez pelo acompanhamento e confiança no meu trabalho desde o mestrado.

Ao meu professor de graduação que me deu a oportunidade de conhecer a vida acadêmica através da iniciação científica e hoje é colega de trabalho, Auzuir Ripardo de Alexandria.

A todos os amigos que ajudaram e contribuíram para a conclusão desse curso de doutorado. Em especial aos amigos do Laboratório de Teleinformática (LATIN/UFC), Tarique da Silveira Cavalcante, Igor Rafael Silva Valente, Edson Cavalcanti Neto, Alyson Bezerra Nogueira Ribeiro, Valberto Enoc Rodrigues da Silva Filho e John Hebert da Silva Félix.

Ao Laboratório de Engenharia de Sistemas Computacionais (LESC/UFC).

Ao Instituto Federal de Ciência e Tecnologia do Ceará (IFCE), em especial ao campus Maranguape e ao Polo de Inovação do IFCE.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“Em dia de vitória ninguém fica cansado.”

(Provérbio Árabe)

## RESUMO

Os Métodos de Contornos de Ativos (MCAs) são técnicas de segmentação de imagens que consistem em segmentar regiões partindo de uma curva em volta do objeto que tende a se moldar às bordas do objeto através da minimização de uma energia que é uma função da geometria da curva e da intensidade dos *pixels* da imagem. Existe uma gama de variação de MCAs em 2D e em 3D. Porém, segmentação em três dimensões tende a demandar alto custo computacional e dentre essas técnicas, os Método de Contornos Ativos Radiais são os que possuem menor custo computacional mas estão limitados ao espaço 2D. Nesta tese é proposto um novo Método de Contornos Ativos Radiais para três dimensões (MCAR3D) que expande o conceito dos MCAs radiais 2D e que trata da análise das informações ao longo de feixes (1D) que divergem sobre um plano a partir do centro do objeto. Em três dimensões, os feixes divergem no espaço com uma combinação de angulação (azimute e elevação) a partir de um ponto interno ao objeto 3D. Dessa forma, apesar de três dimensões, a análise continua sendo ao longo do feixe/raios (1D). Esses feixes podem ser conectados de diferentes formas e formar diferentes malhas ou superfícies. Essas superfícies se deformam através de equações de energias, de modo a se expandir ou se contrair até atingir as bordas do volume de interesse. A principal vantagem dessa nova técnica é sua baixa complexidade computacional, quando comparado às técnicas da literatura para a segmentação 3D. Para avaliação do MCAR3D são utilizadas as seguintes métricas: ajuste de posição, ajuste de tamanho, ajuste de forma e coeficiente *dice*, além do cálculo do custo computacional. São realizados testes em cinco tipos de volumes sintéticos e cinco exames reais de tomografia computadorizada do tórax. Nestes, visa a segmentação dos pulmões como prova de conceito da nova técnica. A técnica proposta é comparada com as seguintes técnicas da literatura: MCA 3D, MCA Morfológico e Crescimento de Regiões 3D. Os resultados provaram a eficiência do MCAR3D na segmentação dos volumes sintéticos e reais com alta taxa de correspondência quanto à posição, forma e tamanho além do esperado baixo custo computacional, produzindo resultados 16 vezes mais rápido que o MCA Morfológico e duas vezes mais rápido que o Crescimento de Regiões 3D além de possuir segmentação superior e sem conexões indesejadas para outras regiões.

**Palavras-chave:** Método dos Contornos Ativos. Segmentação de Imagens. 3D. Raios Ativos.



## ABSTRACT

Active Contour Methods (ACMs) are image segmentation techniques that consist of segmenting regions from a curve around the object that tends to mold to the edges of the object by minimizing an energy that is a function of the geometry of the curve and the intensity of the pixels of the image. There are many 2D and 3D ACMs. However, three dimensions segmentation tend to demand a high computational cost and among these techniques, the Radial Active Contour Method is the one that has the lowest computational cost but is limited to 2D space. In this thesis, a new three-dimensional Radial Active Contours Method (3DRACM) is proposed, which expands the concept of 2D radial ACMs and that analyzes information along beams (1D) that diverge on a plane from the center of the object. In three dimensions, the beams diverge in space with a combination of angulation (azimuth and elevation) from an internal point to the 3D object. Thus, despite three dimensions, the analysis continues to be along the beam (1D). These beams can be connected in different shapes and form different meshes or surfaces. These surfaces deform through energy equations to expand or contract until they reach the edges of the volume of interest. The main advantage of this new technique is its low computational complexity when compared to the literature techniques for 3D segmentation. To evaluate 3DRACM, the following metrics are used: position adjustment, size adjustment, shape adjustment and dice coefficient, in addition to calculation of computational cost. We performed tests on five types of synthetic volumes and five real chest TC scans. In these CT scans, we segmentat the lungs as a proof of concept of the new technique. The proposed technique is compared with the following techniques in the literature: 3D ACM, Morphological ACM and 3D Regions Growing. The results showed the efficiency of 3DRACM in the segmentation of the synthetic and real volumes with high correspondence rate in position, shape and size beyond expected low computational cost, producing results 16 times faster than the Morphological ACM and twice as fast as the 3D Region Growing in addition to having superior segmentation and no leaks.

**Keywords:** Active Contour Models. Image Segmentation. 3D. Active Rays.

## LISTA DE FIGURAS

Figura 1 – exemplo de contorno inicial com detalhe para janela de busca da técnica a) MCA tradicional e b) MCA radial. . . . .	21
Figura 2 – em a) protocolo de aquisição de exame de TC e em b) fatias de imagens empilhadas do exame de TC. . . . .	28
Figura 3 – exemplo de segmentação por limiarização. a) volume 3D, b) fatia original do volume, c) baixo nível de limiarização, d) médio nível de limiarização e e) alto nível de limiarização. . . . .	30
Figura 4 – ilustração da aplicação do Crescimento de Regiões 3D. a) determinação do <i>voxel</i> semente em destaque em vermelho, b) primeira iteração da técnica analisando a vizinhança do <i>voxel</i> semente e c) resultado final da segmentação. . . . .	31
Figura 5 – operador Sobel 3D em que cada filtro pode ser representado por três matrizes 2D ou simplesmente por um cubo 3D. . . . .	32
Figura 6 – recorte de uma curva contendo pontos de controle e vizinhança de busca. . . . .	34
Figura 7 – destaque de vizinhança $5 \times 5$ de um ponto de controle de um MCA. . . . .	35
Figura 8 – ilustração do efeito da Força de Continuidade em que a) ilustra um contorno irregularmente espaçado e em b) o mesmo contorno após a regularização através do primeiro termo da Equação 2.4. . . . .	36
Figura 9 – ilustração do efeito da Força de Curvatura em que a) ilustra um contorno com um ponto com curvatura discrepante (em vermelho) dos demais e em b) o mesmo contorno após a regularização através do segundo termo da Equação 2.4. . . . .	37
Figura 10 – a) convergência de um MCA usando b) energia externa tradicional, e c) recorte com detalhe para a borda da concavidade. . . . .	39
Figura 11 – aplicação do GVF, a) imagem original e a) suavização de bordas. . . . .	40
Figura 12 – exemplos de malhas a) estruturada retangular, b) estruturada triangular e c) não estruturada. . . . .	43
Figura 13 – representação dos Raios Ativos. . . . .	44
Figura 14 – exemplo de segmentação de objeto por Raios Ativos em que a) e d) são objetos de referência; b) e e) são os resultados da aplicação da técnica e c) e f) são os resultados das segmentações. . . . .	46

Figura 15 – ilustração do efeito das Forças de Continuidade e Curvatura sobre um contorno formado por 8 pontos de controle em que a) ilustra um contorno irregular com pontos mal espaçados e cantos pontiagudos enquanto a ilustra o mesmo contorno após a regularização através de $F_{cont}$ e $F_{curv}$ . . . . .	47
Figura 16 – Problema de clusterização dos a) contornos ativos tradicionais e dos b) contornos ativos radiais. . . . .	49
Figura 17 – exemplo de configuração de a) pSnakes e b) <i>snakes</i> radial <i>dual</i> . . . . .	50
Figura 18 – transformada de Hilbert ao longo de um a) feixe partindo de uma origem e ultrapassando a borda de um objeto; b) transformada de Hilbert sobreposta ao sinal do feixe e c) energia hilbertiana sobreposta ao sinal do feixe. . . . .	51
Figura 19 – representação dos Contornos Ativos Radiais 3D. . . . .	52
Figura 20 – etapas de inicialização da técnica MCAR3D. . . . .	58
Figura 21 – refinamento de malha estruturada retangular com a) 8 nós, b) 12 nós, c) 32 nós e d) 112 nós. . . . .	60
Figura 22 – icosaedro formado pelos vértices de três planos ortogonais. . . . .	60
Figura 23 – subdivisão de faces para refinamento de malha. . . . .	61
Figura 24 – refinamento de malha estruturada triangular com a) 12 nós, b) 42 nós, c) 162 nós e d) 642 nós. . . . .	61
Figura 25 – inicialização das superfícies ativas do MCAR3D a) tradicional e b) balão. . . . .	62
Figura 26 – fluxograma do processo de segmentação pelo MCAR3D. . . . .	63
Figura 27 – influência da Força de Continuidade, a) antes da força atual e b) depois da atuação da força. . . . .	65
Figura 28 – influência da Força de Curvatura, a) antes da força atual e b) depois da atuação da força. . . . .	66
Figura 29 – exemplo de aplicação da Força Balão sobre um raio. . . . .	67
Figura 30 – derivada ao longo de um a) feixe partindo de uma origem e ultrapassando a borda de um objeto; b) derivada de primeira ordem; e c) derivada de segunda ordem. . . . .	69
Figura 31 – operador Gradiente ao longo de um a) feixe partindo de uma origem e ultrapassando a borda de um objeto; b) operador Sobel e c) operador Sobel superposto ao filtro passa-baixas. . . . .	70

Figura 32 – malha inicial (em azul) do MCAR3D com 12 (a), 36 (b), 156 (c), 625 (d) e 2500 (e) raios (em cinza). . . . .	72
Figura 33 – possíveis configurações de visualização da segmentação final sendo a) a malha final, b) a malha e os raios, c) os pontos de controle e os raios e d) a malha e os pontos de controle. . . . .	73
Figura 34 – exemplo de formas geométricas 3D utilizadas nos testes sintéticos, a) cilindro; b) cone; c) cubo; d) pirâmide; e e) esfera. . . . .	74
Figura 35 – variação do tempo médio de processamento (s) através do aumento da quantidade de pontos dos métodos MCAR 3D e MCA 3D. . . . .	79
Figura 36 – imagem de TC do tórax da base de dados LIDC-IDRI. . . . .	80
Figura 37 – imagem de TC, a) original com $512 \times 512$ pixels; b) redimensionada para $51 \times 51$ pixels; c) redimensionada para $512 \times 512$ pixels e d) limiarizada. . . . .	81
Figura 38 – evolução da segmentação de um pulmão via MCAR 3D com a) malha inicial; b) segmentação intermediária e c) e d) segmentação final. . . . .	82
Figura 39 – evolução da segmentação de um pulmão via MCA Morfológico com a) leve-set binário inicial; b) segmentação intermediária e c) segmentação final. . . . .	82
Figura 40 – tempo médio de processamento (s) nos exames reais testados pelo método MCAR 3D, MCA Morfológico e CR 3D. . . . .	85
Figura 41 – evolução da segmentação do volume cilíndrico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente. . . . .	98
Figura 42 – evolução da segmentação do volume cônico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente. . . . .	99
Figura 43 – evolução da segmentação do volume cúbico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente. . . . .	100

Figura 44 – evolução da segmentação do volume esférico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente. . . . .	101
Figura 45 – evolução da segmentação do volume piramidal com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente. . . . .	102
Figura 46 – resultados das medidas de ajuste aplicadas no volume cilíndrico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos. . . . .	107
Figura 47 – resultados das medidas de ajuste aplicadas no volume cônico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos. . . . .	108
Figura 48 – resultados das medidas de ajuste aplicadas no volume cúbico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos. . . . .	109
Figura 49 – resultados das medidas de ajuste aplicadas no volume esférico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos. . . . .	110
Figura 50 – resultados das medidas de ajuste aplicadas no volume piramidal com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos. . . . .	111
Figura 51 – segmentação do exame 1 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões. . . . .	112
Figura 52 – segmentação do exame 2 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões. . . . .	113
Figura 53 – segmentação do exame 3 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões. . . . .	114
Figura 54 – segmentação do exame 4 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões. . . . .	115
Figura 55 – segmentação do exame 5 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões. . . . .	116
Figura 56 – resultados da medida de ajuste de posição utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC. . . . .	118

Figura 57 – resultados da medida de ajuste de tamanho utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC. . . . .	118
Figura 58 – resultados da medida de ajuste de forma utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC. . . . .	119
Figura 59 – resultados de coeficiente <i>dice</i> utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC. . . . .	119

## LISTA DE TABELAS

Tabela 1	– trabalhos relacionados à busca por Raios Ativos nas bases de dados. . . . .	23
Tabela 2	– tempo de processamento para as técnicas MCAR 3D (malha retangular e triangular) e MCA 3D variando a quantidade de pontos entre 12 e 2500 pontos.	78
Tabela 3	– variação entre o melhor e o pior resultado das técnicas testadas nos exames reais. . . . .	84
Tabela 4	– tempo de processamento para as técnicas MCAR 3D (malha retangular e triangular), e MCA Morfológico e Crescimento de Região aplicadas nos exames de 1 a 5. . . . .	85
Tabela 5	– resultados entre as medidas de ajuste e coeficiente <i>dice</i> para o volume sintético cilíndrico. . . . .	103
Tabela 6	– resultados entre as medidas de ajuste e coeficiente <i>dice</i> para o volume sintético cônico. . . . .	104
Tabela 7	– resultados entre as medidas de ajuste e coeficiente <i>dice</i> para o volume sintético cubico. . . . .	104
Tabela 8	– resultados entre as medidas de ajuste e coeficiente <i>dice</i> para o volume sintético esférico. . . . .	105
Tabela 9	– resultados entre as medidas de ajuste e coeficiente <i>dice</i> para o volume sintético piramidal. . . . .	105
Tabela 10	– resultados entre as medidas de ajuste e coeficiente <i>dice</i> entre os exames de TC.117	

## LISTA DE ABREVIATURAS E SIGLAS

2D	Duas dimensões (Bidimensional)
3D	Três dimensões (Tridimensional)
CR3D	Crescimento de Regiões 3D
DDGVF	Fluxo do Vetor Gradiente Direcional Dinâmico ( <i>Dynamic Directional Gradient Vector Flow</i> )
DSC	Coefficiente de Similaridade Dice ( <i>Dice Similarity Coefficient</i> )
GVF	Fluxo do Vetor Gradiente ( <i>Gradient Vector Flow</i> )
GGVF	Fluxo do Vetor Gradiente Generalizado ( <i>Generalized Gradient Vector Flow</i> )
MCA	Método dos Contornos Ativos
MCAP	Método dos Contornos Ativos Polares
MCAR	Método dos Contornos Ativos Radiais
MCAR3D	Método dos Contornos Ativos Radiais 3D
NBGVF	Fluxo do Vetor Gradient Normal Enviesado ( <i>Normally Biased Gradient Vector Flow</i> )
NGVF	Fluxo do Vetor Gradiente Normal ( <i>Normal Gradient Vector Flow</i> )
MRI	Imagem por Ressonância Magnética
MSA	Método das Superfícies Ativos
TC	Tomografia Computadorizada
TH	Transformada de Hilbert
VC	Visão Computacional
VFC	Convolução de Campo de Vetores ( <i>Vector Field Convolution</i> )



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	18
<b>1.1</b>	<b>Motivação</b>	20
<b>1.2</b>	<b>Objetivos</b>	23
<b>1.2.1</b>	<i>Objetivos específicos</i>	24
<b>1.3</b>	<b>Organização do trabalho</b>	24
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	25
<b>2.1</b>	<b>Segmentação de Imagens</b>	25
<b>2.1.1</b>	<i>Bidimensional (2D)</i>	26
<b>2.1.2</b>	<i>Tridimensional (3D)</i>	27
<b>2.1.2.1</b>	<i>Limiarização</i>	29
<b>2.1.2.2</b>	<i>Crescimento de Regiões</i>	29
<b>2.1.2.3</b>	<i>Operadores convolucionais</i>	30
<b>2.2</b>	<b>Contornos Ativos</b>	32
<b>2.2.1</b>	<i>Bidimensional (2D)</i>	33
<b>2.2.1.1</b>	<i>Energia Interna</i>	35
<b>2.2.1.2</b>	<i>Energia Externa</i>	38
<b>2.2.2</b>	<i>Tridimensional (3D)</i>	41
<b>2.3</b>	<b>Contornos Ativos Radiais</b>	44
<b>2.3.1</b>	<i>Raios Ativos (Active Rays)</i>	44
<b>2.3.2</b>	<i>pSnakes</i>	49
<b>2.3.3</b>	<i>MCA Radiais 3D</i>	52
<b>2.4</b>	<b>Avaliação do Método</b>	54
<b>2.4.1</b>	<i>Medidas de Ajuste</i>	55
<b>2.4.2</b>	<i>Coefficiente Dice</i>	56
<b>2.4.3</b>	<i>Desempenho computacional</i>	56
<b>3</b>	<b>METODOLOGIA</b>	58
<b>3.1</b>	<b>MCA Radiais 3D</b>	58
<b>3.1.1</b>	<i>Inicialização</i>	58
<b>3.1.2</b>	<i>Dinâmica do MCAR3D</i>	62
<b>3.1.3</b>	<i>Janela de busca</i>	62

<b>3.1.4</b>	<b><i>Energia Interna</i></b> . . . . .	64
3.1.4.1	<i>Força de Continuidade</i> . . . . .	64
3.1.4.2	<i>Força de Curvatura</i> . . . . .	65
3.1.4.3	<i>Força Balão</i> . . . . .	66
<b>3.1.5</b>	<b><i>Energia Externa</i></b> . . . . .	67
3.1.5.1	<i>Força Gradiente</i> . . . . .	68
<b>3.2</b>	<b>Avaliação do Método</b> . . . . .	70
<b>4</b>	<b>RESULTADOS</b> . . . . .	72
<b>4.1</b>	<b>Testes em Volumes Sintéticos</b> . . . . .	73
<b>4.1.1</b>	<b><i>Medidas de Ajuste</i></b> . . . . .	74
4.1.1.1	<i>Cilindro</i> . . . . .	75
4.1.1.2	<i>Cone</i> . . . . .	76
4.1.1.3	<i>Cubo</i> . . . . .	76
4.1.1.4	<i>Esfera</i> . . . . .	77
4.1.1.5	<i>Pirâmide</i> . . . . .	77
<b>4.1.2</b>	<b><i>Custo Computacional</i></b> . . . . .	78
<b>4.2</b>	<b>Testes em Volume Reais</b> . . . . .	79
<b>4.2.1</b>	<b><i>Medidas de Ajuste</i></b> . . . . .	82
<b>4.2.2</b>	<b><i>Custo Computacional</i></b> . . . . .	84
<b>5</b>	<b>CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS</b> . . .	86
	<b>REFERÊNCIAS</b> . . . . .	89
	<b>APÊNDICES</b> . . . . .	97
	<b>APÊNDICE A</b> – Resultados visuais - Volumes sintéticos . . . . .	97
	<b>APÊNDICE B</b> – Resultados numéricos - Volumes sintéticos . . . . .	103
	<b>APÊNDICE C</b> – Resultados gráficos - Volumes sintéticos . . . . .	106
	<b>APÊNDICE D</b> – Resultados visuais - Volumes reais . . . . .	112
	<b>APÊNDICE E</b> – Resultados numéricos - Volumes reais . . . . .	117
	<b>APÊNDICE F</b> – Resultados gráficos - Volumes reais . . . . .	118

## 1 INTRODUÇÃO

O crescente progresso da tecnologia, em conjunto com o desenvolvimento de novos algoritmos, vem permitindo cada vez mais uma maior quantidade de aplicações que envolvam sistemas de Visão Computacional (VC). Sabe-se que esses sistemas dependem de uma série de etapas e procedimentos envolvendo processamento e análise de imagens digitais. Uma das etapas que recebe destaque é a etapa de segmentação de imagens. Segmentar uma imagem pode ser definido como um procedimento para extração de partes de interesse de uma cena qualquer de em uma imagem digital. Este é um dos procedimentos mais desafiadores nessa área, pois uma segmentação considerada de adequada não só economiza tempo de processamento como facilita o acesso às informações presentes na cena, bem como as etapas subsequentes de um sistema de VC (GONZALEZ; WOODS, 2018).

Com o passar dos anos, diversos trabalhos vem tentando classificar as técnicas de segmentação, haja vista que esta é uma tarefa complexa e todo dia surge uma nova técnica para uma aplicação específica. Contudo, existe uma categorização recorrente na literatura para as técnicas de segmentação de imagens. Jain (1989) divide as técnicas em cinco categorias: limiarização, rotulação de componentes conectados, técnicas baseadas em bordas, técnicas baseadas em regiões, casamento de padrões e segmentação por texturas. Enquanto Gonzalez e Woods (2018), em seu livro mais recente, adota uma taxonomia semelhante com apenas quatro categorias: limiarização, técnicas baseadas em bordas, técnicas baseadas em regiões e contornos ativos, que apesar de ser considerada uma técnica baseada em bordas, assumiu uma categoria devido à quantidade de métodos derivados da técnica original desenvolvida por Kass *et al.* (1987).

Os Métodos de Contornos Ativos (MCAs ou *snakes*), criados por Kass *et al.* (1987), são técnicas de segmentação de imagens que diferem das técnicas “tradicionais” que envolvem limiarização e crescimento de regiões, por exemplo. A ideia dos *snakes* é segmentar regiões, partindo de uma curva em volta do objeto e não apenas manipulando os *pixels* da imagem. O termo “ativo” dos MCAs está relacionado ao funcionamento e dinâmica da técnica, pois, a curva tende a se moldar às bordas dos objetos de interesse.

Por se tratar de uma técnica genérica, tem sofrido modificações por vários autores ao longo das décadas e, ainda assim, continua como uma metodologia representativa e funcional de segmentação de imagens. Os *snakes* foram criados para segmentar imagens no plano (2D) mas logo foram expandidos para segmentar volumes no espaço (3D). A esta nova técnica deu-se o nome de Métodos de Superfícies Ativas (MSAs), Modelos Deformáveis 3D, Método das Malhas

Ativas, *snakes* 3D ou, simplesmente, MCA 3D (CAVALCANTE, ).

O espaço tridimensional, diferente do espaço bidimensional, é limitado em razão das aplicações que geram esse tipo de imagem. Hoje em dia é comum a obtenção de imagens 2D devido à facilidade que se há de adquiri-las pelos mais diversos dispositivos. O mesmo não acontece no espaço em três dimensões, haja vista a quantidade limitada de dispositivos capazes de gerar imagens 3D.

Mesmo limitada, uma área em crescente ascensão que envolve a geração de imagens 3D é a área médica. Diversos equipamentos médicos produzem imagens desse tipo, pois, uma representação tridimensional contém mais detalhes a respeito da localização e do estado de estruturas do corpo humano. Equipamentos de Tomografia Computadorizada (TC) ou Ressonância Magnética (MRI), por exemplo, produzem uma pilha de imagens no plano axial<sup>1</sup> em que é necessário montá-las em um volume único para uma posterior segmentação da imagem 3D. Com esse volume é possível verificar estruturas com uma maior riqueza de detalhes em relação a uma única imagem no plano 2D.

As aplicações advindas do resultado da segmentação 3D de estruturas são diversas. Estas estão presentes na literatura há muito tempo e continuam em evidência, tais como, segmentação:

- dos pulmões (REBOUÇAS FILHO *et al.*, 2017);
- de lóbulos pulmonares (LASSEN *et al.*, 2017);
- do ventrículo cerebral fetal (QIU *et al.*, 2017);
- de árvores vasculares (WOŹNIAK *et al.*, 2017);
- do disco intervertebral (ZHENG *et al.*, 2017);
- de fragmentos de ossos (SHADID; WILLIS, 2018);
- de tumor cerebral (BANERJEE *et al.*, 2018);
- de vasos hepáticos (ZENG *et al.*, 2018) e
- do cérebro (CHEN *et al.*, 2018);

dentre outras.

De fato, imagens em três dimensões trazem mais informações que enriquecem a sua análise. Contudo, como é de se esperar, mais dados demandam mais tempo para processá-los e trazem uma dificuldade inerente à análise. Um inconveniente comum que permeia o âmbito dos volumes 3D é o custo computacional da segmentação. Às vezes, são necessárias diversas etapas

<sup>1</sup> Na anatomia humana, o plano axial é aquele que atravessa o eixo menor do corpo, do torso até o ventre.

como pré-processamento e uma combinação de técnicas posterior para produzir uma segmentação minimamente aceitável e, geralmente, cada etapa do pré-processamento envolvido é aplicada no volume completo. Lassen *et al.* (2013), por exemplo, utilizam técnicas como limiarização, crescimento de regiões, análise de componentes conectados, transformada da distância, entre outras, para segmentar os lóbulos pulmonares. O tempo envolvido na segmentação é tão relevante que, em trabalho recente, os mesmos autores utilizam uma metodologia para reduzir o tempo de processamento da segmentação dos lóbulos mas, mesmo assim, esta metodologia parte de uma segmentação inicial dos mesmos (LASSEN *et al.*, 2017).

## 1.1 Motivação

Apesar de ser uma técnica muito utilizada na segmentação de imagens, os MCAs 3D tendem a ter um alto custo computacional a depender de fatores tais como a topologia utilizada na malha de pontos, função de adição e remoção de pontos, tamanho da máscara de busca, quantidade de pontos, etc.

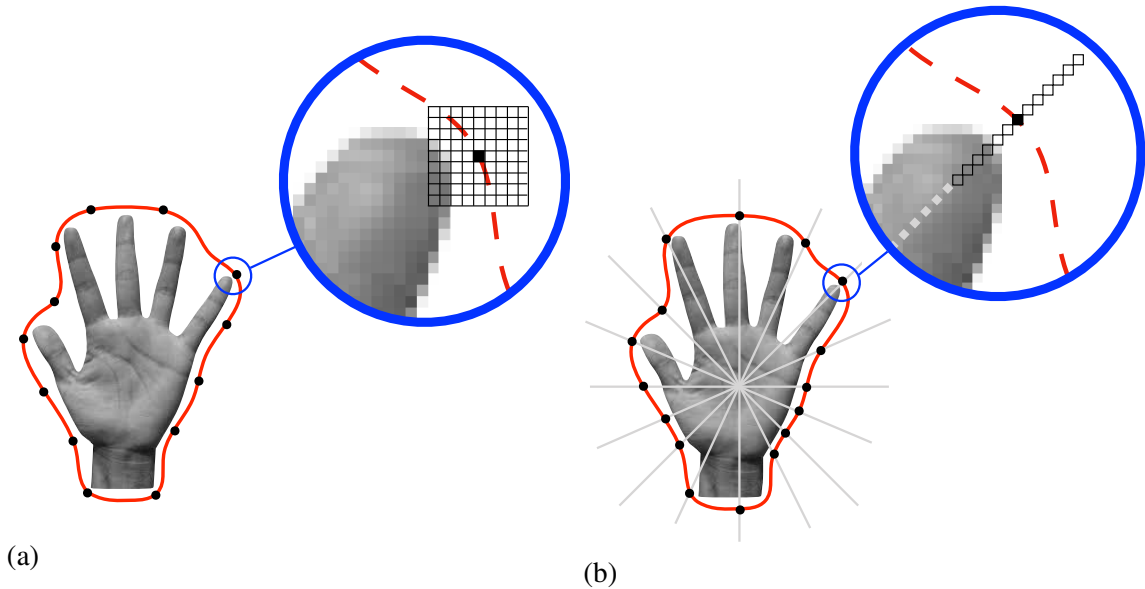
Visando reduzir o custo computacional das técnicas envolvendo MCAs, foram criados os chamados Métodos de Contornos Ativos Radiais (MCAR), também chamados de *snakes* radiais, que são metodologias semelhante aos MCAs mas que se baseiam nos Raios Ativos de Denzler e Niemann (1996).

Os *snakes* radiais possuem o mesmo conceito dos *snakes* tradicionais. Isto é, trata-se de uma técnica de segmentação de imagens por meio da definição de uma curva em volta do objeto a ser segmentado, onde esta curva tende a se contrair sobre as bordas desse objeto. A contração e evolução dessa curva ocorre por meio de forças que agem com a finalidade de minimizar uma função de energia. Essa energia, por sua vez, é dividida em outras duas energias, sendo uma referente às informações presentes na imagem e a outra referente à forma da curva (DENZLER; NIEMANN, 1996).

A maior diferença entre os *snakes* radiais e os *snakes* tradicionais está no espaço de busca das técnicas, onde cada ponto do contorno pode se locomover. Ambas as técnicas possuem contornos formados por uma série de pontos conectados sequencialmente como uma lista circular, em que cada ponto tem dois vizinhos. Contudo, enquanto o *snake* tradicional realiza uma busca em duas dimensões, podendo ocupar qualquer local dentro dessa janela de busca. Por outro lado, o *snake* radial faz uma busca ao longo de um feixe em uma dimensão, podendo ocupar qualquer local, desde o ponto central do contorno até a extremidade do feixe.

Assim, cada ponto do *snake* radial só se locomove em uma única direção, como ilustrado na Figura 1.

Figura 1 – exemplo de contorno inicial com detalhe para janela de busca da técnica a) MCA tradicional e b) MCA radial.



Fonte: Autor.

O contorno inicial (em vermelho) de um MCA tradicional em volta de um objeto (uma mão) com o detalhe para a janela de busca 2D com  $9 \times 9$  elementos centrada em um ponto de controle do contorno é mostrado na Figura 1a). Dessa maneira, esse ponto tem 80 possíveis novos locais para se locomover. Já a Figura 1b) mostra o contorno inicial (em vermelho) de um MCA radial em torno do mesmo objeto, com o detalhe para a janela de busca 1D de tamanho  $6 + 6$ , centrada em um ponto de controle do contorno. Neste caso, o ponto de controle só pode se movimentar ao longo do feixe (em cinza) que parte do interior do objeto a ser segmentado. Logo, só há 12 possíveis novos locais para este ponto se locomover.

É importante ressaltar que a quantidade de pontos de controle do MCA tradicional varia conforme a evolução do contorno através de funções de adição e remoção de pontos, podendo chegar a ter dezenas de pontos. Em contrapartida, enquanto a quantidade de pontos do MCA radial é fixa e limitada ao número de feixes que é pré-definido. Cada ponto de controle possui uma janela de busca onde são realizados todos os cálculos de energia para cada possível ponto, dentro de cada uma dessas janelas de busca. Sendo assim, o contorno da Figura 1a) possui 13 pontos de controle com uma região de busca de tamanho  $9 \times 9$  cada um. Isso totaliza 1053 cálculos de energia em cada iteração do método. Já o contorno da Figura 1b) possui 16 raios

e, por consequência, 16 pontos de controle com uma região de busca de tamanho 6 + 6 cada um. Isto totaliza 208 cálculos de energia em cada iteração do método, que é uma redução de aproximadamente 20% nos cálculos sem considerar o custo computacional para verificar se é necessário adicionar mais pontos ou remover pontos no MCA tradicional, processo este que nem sempre existe no MCA radial.

Os *snakes* radiais derivam da técnica chamada Raios Ativos (ou *active rays*) (DENZLER; NIEMANN, 1996; DENZLER; NIEMANN, 1999) que, apesar de ser uma técnica criada há mais de 20 anos, não foi tão explorada quanto os *snakes* tradicionais de Kass *et al.* (1987), criados 10 anos antes dos Raios Ativos.

Em uma pesquisa na base de dados Scopus<sup>2</sup> da editora Elsevier e em outras bases como IEEE Xplore, por exemplo, buscara-se todos os artigos que citavam os artigos originais de Denzler e Niemann (1996) ou de Denzler e Niemann (1999). Excluindo os resultados duplicados entre as bases e aqueles que não se enquadram na temática de segmentação ou apenas citam o artigo original, mas não trazem ganho relevante para este trabalho, a busca retornou um total de 22 artigos. Ainda assim, sendo categorizados em cinco grandes áreas quanto à aplicação: rastreamento em tempo real; segmentação de imagens médicas; segmentação de imagens aplicadas em automação; segmentação de imagens sintéticas e segmentação de volumes 3D. A Tabela 1 traz os resultados da busca em detalhes.

A maioria dos trabalhos apresentados na Tabela 1 trata da segmentação de imagens médicas nas mais diversas modalidades e aplicações como, por exemplo, segmentação do fêmur em imagens de TC, segmentação da medula espinhal em imagens de MRI, segmentação de microcalcificações de mamografias, etc. Dentre as outras áreas são apresentados cinco trabalhos sobre rastreamento em tempo real, visando auxiliar robôs para perceber pessoas e seus comportamentos, rastrear pessoas e animais ou, ainda, rastrear células em imagens de microscopia. Existem dois trabalhos sobre segmentação de imagens voltados para a área de automação, envolvendo detecção de contornos de volantes e detecção de contornos para auxílio de grandes máquinas. Dois trabalhos tratam da segmentação de imagens sintéticas, sendo um deles uma recente análise comparativa de *snakes* radiais. Finalmente é apresentado somente um único trabalho descrevendo essa a metodologia aplicada em volumes (3D), que é um artigo oriundo desta tese.

Neste sentido, esta tese propõe a formalização da generalização dos MCAs radiais

---

<sup>2</sup> Scopus é uma das maiores bases de dados de citações e resumo de literatura revisada por pares: revistas científicas, livros e conferências.

Tabela 1 – trabalhos relacionados à busca por Raios Ativos nas bases de dados.

<b>Autor (Ano)</b>	<b>Área de Aplicação</b>
Feyrer e Zell (2000)	Rastreamento em tempo real
Chen <i>et al.</i> (2001)	Rastreamento em tempo real
Kalafatic <i>et al.</i> (2001)	Rastreamento em tempo real
Lehmann <i>et al.</i> (2003)	Segmentação de imagens (médicas)
Long e Fan (2003)	Segmentação de imagens (sintéticas)
Marti <i>et al.</i> (2004)	Segmentação de imagens (médicas)
Deng <i>et al.</i> (2007)	Segmentação de imagens (médicas)
Arikidis <i>et al.</i> (2008)	Segmentação de imagens (médicas)
Arikidis <i>et al.</i> (2008)	Segmentação de imagens (médicas)
Arikidis <i>et al.</i> (2009)	Segmentação de imagens (médicas)
Sage <i>et al.</i> (2010)	Rastreamento em tempo real
Arikidis <i>et al.</i> (2010)	Segmentação de imagens (médicas)
Chen <i>et al.</i> (2011)	Segmentação de imagens (automação)
Breier <i>et al.</i> (2011)	Segmentação de imagens (médicas)
Alexandria <i>et al.</i> (2011)	Segmentação de imagens (médicas)
Zhang <i>et al.</i> (2011)	Segmentação de imagens (automação)
Baust <i>et al.</i> (2011)	Segmentação de imagens (médicas)
Baust <i>et al.</i> (2012)	Segmentação de imagens (médicas)
Alexandria <i>et al.</i> (2014)	Segmentação de imagens (médicas)
Bessa <i>et al.</i> (2015)	Segmentação de imagens (sintéticas)
Versari <i>et al.</i> (2017)	Rastreamento em tempo real
Almeida <i>et al.</i> (2017)	Segmentação de volumes (3D)

Fonte: Autor.

para três dimensões, visando contribuir para a literatura com essa nova metodologia como uma técnica mais rápida e funcional. Esta nova técnica é detalhada por completo, seja matematicamente com as equações de energia interna, seja computacionalmente com a geração de malhas e disparo de feixes. São propostos diferentes tipos de malhas e diferentes metodologias possíveis para serem utilizadas como energia externa da técnica. O MCA Radial 3D é comparado com o MCA Tradicional 3D, o MCA Morfológico e a clássica técnica de Crescimento de Regiões 3D. O método é avaliado quanto à qualidade da segmentação em nível volumétrico e quanto ao tempo de processamento aplicado em volumes gerados sinteticamente e aplicado em estruturas médicas.

## 1.2 Objetivos

O principal objetivo dessa tese é desenvolver um novo Método de Contornos Ativos Radiais em Três Dimensões para segmentar volumes.



### **1.2.1 *Objetivos específicos***

Os objetivos específicos desse trabalho que podem ser citados são:

- uma nova técnica para segmentar volumes (3D);
- visualização 3D da dinâmica da técnica proposta;
- criar modelos 3D de imagens sintéticas para validação da técnica proposta;
- verificar a eficiência da técnica através da segmentação de volumes sintéticos; e
- aplicar a técnica proposta na segmentação de estruturas biológicas.

### **1.3 *Organização do trabalho***

Esta tese está organizada em 5 Capítulos da seguinte maneira: o Capítulo 2 apresenta uma breve revisão sobre segmentação de imagens e as técnicas envolvidas em duas e três dimensões com ênfase nos Métodos dos Contornos Ativos 2D/3D e nos Métodos de Contornos Ativos Radiais. No Capítulo 3 é apresentada formalmente a técnica proposta nesta tese onde são detalhados todos os fluxos necessários para implementá-la, bem como as equações que a descrevem. Ainda neste Capítulo são mostradas diferentes transformações que podem ser utilizadas como funções de energia externa da técnica (a depender da característica da aplicação específica) e diferentes malhas computacionais e ao final do Capítulo há uma descrição da metodologia utilizada nos testes. No Capítulo 4 são mostrados e discutidos os resultados obtidos com a implementação da técnica proposta e sua comparação com as técnicas já existentes na literatura. Por fim, são apresentadas as conclusões e contribuições dessa tese no Capítulo 5.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo, primeiramente, são apresentados os conceitos envolvendo Segmentação de Imagens em duas dimensões (2D) e em três dimensões (3D). Nesse assunto são destacadas técnicas de segmentação de conhecimento comum e largamente utilizadas na literatura. Em seguida, aprofunda-se em um conjunto de técnicas em constante ascensão que são os Métodos dos Contornos Ativos (MCAs) e sua teoria sobre forças, energias e dinâmica. Para isso, é realizada uma revisão bibliográfica nos MCAs 2D e 3D em diversas aplicações. Por fim, é apresentado um estudo sobre os Métodos dos Contornos Ativos Radiais (MCAR) e os trabalhos relacionados para ser apresentado o Método de Contorno Ativo Radial 3D (MCAR3D).

### 2.1 Segmentação de Imagens

A segmentação de imagens é, sem dúvidas, uma das tarefas mais complexas no Processamento de Imagens Digitais, sendo geralmente a segunda ou terceira etapa em sistemas de Visão Computacional e consiste basicamente em se decompor uma cena em seus componentes ou objetos constituintes de interesse (JAIN, 1989). Dessa forma, o processo de segmentação pode ser definido como a atribuição de rótulo a cada *pixel* da imagem (ou a cada *voxel* do volume, para imagens com três dimensões), identificando a qual região pertence, de acordo com suas propriedades (GONZALEZ; WOODS, 2008).

Ao segmentar uma imagem, deve-se ter em mente que esta etapa, em si, é extremamente restritiva e não envolve a classificação dos objetos segmentados e nem busca identificar algum objeto específico ou, ainda, sua relação com algum outro objeto (PRATT, 2013). O objetivo da segmentação é puramente simplificar e/ou alterar a representação de uma cena através de uma imagem, em algo que seja mais significativo e de análise mais acessível (SHAPIRO; STOCKMAN, 2001). Logo, é comum encontrar diversas técnicas cada vez mais específicas para segmentar imagens de diversos tipos e, por esse motivo, as aplicações que envolvem segmentação de imagens está em constante evolução e atualização (GONZALEZ; WOODS, 2018).

Diversos trabalhos vêm categorizando as técnicas de segmentação de imagens ao longo dos anos. Uma dos primeiros trabalhos foi o de Jain (1989), que divide as técnicas em cinco categorias: limiarização, rotulação de componentes conectados, técnicas baseadas em bordas, técnicas baseadas em regiões, casamento de padrões e segmentação por texturas. Enquanto Gonzalez e Woods (2018), em seu livro mais recente, adota uma taxonomia semelhante

com apenas quatro categorias: limiarização, técnicas baseadas em bordas, técnicas baseadas em regiões e contornos ativos, que apesar de ser considerada uma técnica baseada em bordas, transformou-se uma categoria devido à quantidade de métodos derivados da técnica original desenvolvida por Kass *et al.* (1987). Uma outra maneira de tentar subdividir essas técnicas é quanto ao tipo da imagem a ser segmentada: se é uma segmentação em duas dimensões ou em três dimensões.

### 2.1.1 *Bidimensional (2D)*

É natural que as técnicas de segmentação de imagens 2D tenham surgido antes das técnicas 3D. Um dos trabalhos pioneiros sobre a reunião de técnicas envolvendo segmentação de imagens 2D é o de Haralick e Shapiro (1985), onde se estabelece um guia para definição de uma boa segmentação de maneira qualitativa, já que métricas quantitativas ainda não haviam sido criadas. Neste guia, Haralick e Shapiro (1985) definem que uma boa segmentação acontece quando as regiões são uniformes e homogêneas quanto a algumas características como tons de cinza ou texturas, por exemplo. Regiões adjacentes devem ter valores significativamente diferentes, respeitando a característica que a torna uniforme. Por fim, as bordas das regiões devem ser simples, bem definidas e sem muitas irregularidades.

Em sua pesquisa, Haralick e Shapiro (1985) reúnem as principais técnicas de segmentação da época nas categorias de: 1) limiarização ou clusterização espacial; 2) crescimento de regiões; e 3) divisão e conquista. Outro importante trabalho da década de 1980 é o de Fu e Mui (1981) em que são consideradas as técnicas de: 1) segmentação por limiarização ou clusterização; 2) detecção de bordas; e 3) extração de regiões através de crescimento de regiões ou divisão e conquista. Percebe-se, assim, a recorrência e a limitação de algumas categorias quanto às primeiras técnicas de segmentação de imagens.

Com o passar dos anos aumentou a quantidade de técnicas de segmentação e, por sua vez, a quantidade de estudos sobre as mesmas. Pal e Pal (1993) e Spirkovska (1993) realizaram outro levantamento a respeito das metodologias utilizadas. Spirkovska (1993) segue basicamente as mesmas categorias apresentadas em estudos anteriores: técnicas de segmentação baseadas em: 1) *pixel*; 2) bordas; e 3) regiões. A primeira categoria trata apenas dos valores dos tons de cinza dos *pixels*, a segunda busca detectar discontinuidades para poder dividir a imagem em regiões e a última categoria parte de um *pixel* semente para aumentar ou dividir a região de acordo com algum critério específico. Já Pal e Pal (1993) adicionam técnicas envolvendo

lógica *fuzzy*, redes neurais artificiais, técnicas para segmentação de imagens coloridas e técnicas para segmentação de imagens de ressonância magnética. A conclusão desse estudo é que não há uma técnica suficientemente boa para todos os tipos de imagens testadas e ainda não há métricas quantitativas para poder avaliar a qualidade da segmentação.

À medida que a quantidade de técnicas de segmentação aumenta, torna-se cada vez mais difícil concluir estudos que possibilitem a categorização de todas sem que se tenha uma aplicação definida. Freixenet *et al.* (2002) reconhecem a quantidade de técnicas citadas nos estudos anteriores, resumindo como técnicas baseadas nas propriedades dos *pixels* ou na relação da sua vizinhança: similaridade (técnicas de segmentação baseadas em região) ou descontinuidade (técnicas de segmentação baseadas em bordas). Em seu estudo, Freixenet *et al.* (2002) não apresentam nenhuma técnica nova, mas evidenciam as técnicas que englobam as duas características ao mesmo tempo: segmentação por região e por bordas. Neste estudo estão descritos sete algoritmos a partir da combinação de diferentes técnicas, tais como crescimento de região, divisão e conquista e contornos ativos (*snakes*). Hoje em dia, torna-se cada vez mais comum a combinação de técnicas para gerar métodos de segmentação em aplicações específicas.

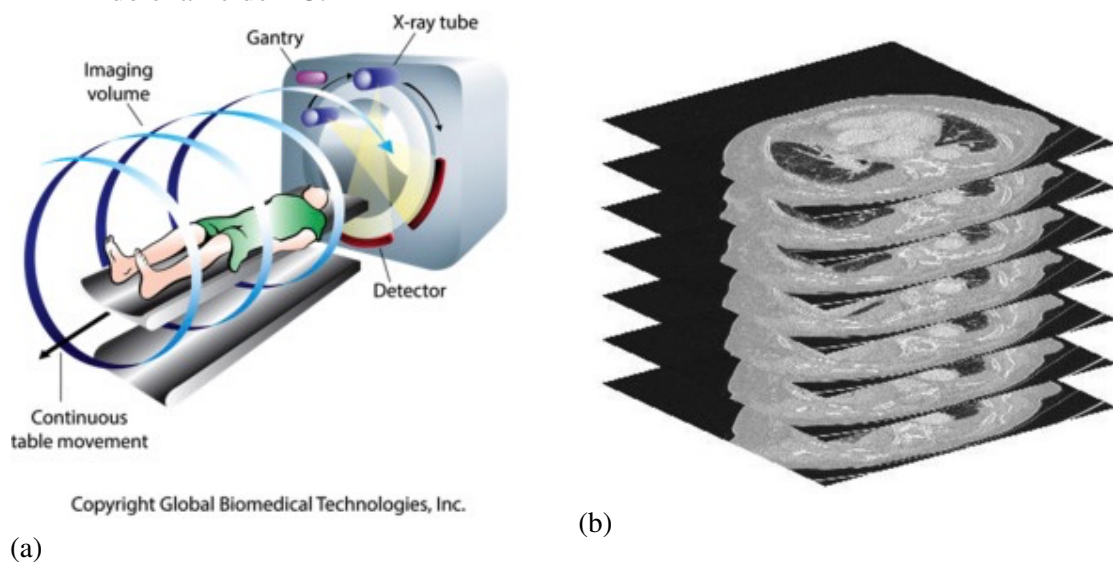
### 2.1.2 *Tridimensional (3D)*

Enquanto existem dezenas de técnicas e metodologias para segmentação de imagens em duas dimensões, o mesmo não acontece na segmentação 3D. É fácil constatar que o maior motivo disso se dá pela dificuldade na obtenção de imagens em três dimensões. Contudo, esse cenário vem se modificando ao longo dos anos com a introdução de sensores como câmeras stereo, RGB-D, câmeras *time-of-flight*, lasers e *LiDARs* (*Light Detection And Ranging*), que geram nuvens de pontos e são muito utilizados em construção de mapas (SOUZA *et al.*, 2002), reconhecimento de ambientes (SAXENA *et al.*, 2008), realidade aumentada (KAHN, 2013), localização e mapeamento simultâneo (SLAM) (CHOI *et al.*, 2013) e segmentação semântica de objetos (LAWIN *et al.*, 2017).

Apesar de haver várias áreas que lidam com imagens 3D, a grande maioria das aplicações ainda está no domínio de imagens médicas. Isso acontece devido às suas importantes aplicações no auxílio ao diagnóstico e aos seus equipamentos que, ao invés de produzirem uma nuvem de pontos, possibilitam mapear o corpo humano através dos volumes dos órgãos e das regiões do mesmo. Equipamentos de Tomografia Computadorizada (TC) ou Ressonância Magnética (MRI), por exemplo, produzem uma pilha de imagens no plano axial que, quando

organizadas, produzem o volume do corpo humano com seus órgãos internos constituintes nos planos sagital e coronal. Na Figura 2a) é ilustrado um procedimento típico de TC no qual um indivíduo entra em um tubo contendo um anél de feixes de raios-X que gira 360° em torno dele. Do lado oposto ao tubo de raios-X existem detectores de fótons que absorvem a energia desses feixes e transforma os fótons em um sinal que é posteriormente convertido em um sinal digital que forma as fatias ilustradas na Figura 2b) Than *et al.* (2017).

Figura 2 – em a) protocolo de aquisição de exame de TC e em b) fatias de imagens empilhadas do exame de TC.



Fonte: Than *et al.* (2017).

A partir do volume gerado pelo empilhamento das fatias das imagens, diversas técnicas podem ser aplicadas ou combinadas para segmentar órgãos específicos. Dou *et al.* (2017) combinam redes neurais convolucionais profundas a um mecanismo de aprendizagem supervisionado para segmentar as regiões do coração e do fígado em imagens de MRI. Shadid e Willis (2018) utilizam uma variação da transformada de *watershed* baseada em probabilidades, chamada de transformada de *watershed* probabilística, para segmentar fragmentos de ossos em imagens de TC. Zheng *et al.* (2017), em seu trabalho, analisam diversas técnicas e metodologias aplicadas não só na segmentação mas também na localização dos discos intervertebrais em 25 imagens de MRI submetidas a um dos *Grand Challenges in Biomedical Image Analysis*<sup>1</sup>.

Encontra-se, na literatura, uma infinidade de combinações de técnicas já bem estabelecidas e a cada dia surgem outras que podem ser novamente recombinadas produzindo novos resultados. Wirjadi (2007) foi um dos pioneiros a realizar um estudo a respeito das técnicas

<sup>1</sup> <[https://grand-challenge.org/site/grand-challenges/all\\_challenges/](https://grand-challenge.org/site/grand-challenges/all_challenges/)>

envolvidas na segmentação de imagens 3D e, assim como Gonzalez e Woods (2018) e outros autores citados na seção 2.1.1, dividem-nas em técnicas baseadas em *voxels*<sup>2</sup>, regiões e bordas.

### 2.1.2.1 Limiarização

Existe uma grande quantidade de métodos de segmentação baseados em níveis de cinza usando informações dos *voxels*. A técnica de segmentação por Limiarização é técnica mais simples e mais usada na segmentação de objetos. Esta assume, em uma imagem com histograma bimodal, que o objeto de interesse pode ser caracterizado pelo seu brilho e diferenciado do plano de fundo da imagem e pode ser completamente descrito por (WIRJADI, 2007)

$$g(\mathbf{x}) = \begin{cases} 1, & \text{se } f(\mathbf{x}) \geq \theta \\ 0, & \text{caso contrário,} \end{cases}, \quad (2.1)$$

em que  $g$  é a imagem transformada a partir da imagem de entrada  $f$ , em função do *voxel*  $\mathbf{x}$ . Enquanto  $\theta$  é um valor de limiar dado que  $\min_x(f(x)) \leq \theta \leq \max_x(f(x))$  totalmente arbitrário e dependente da aplicação. Exemplos da influência do valor de  $\theta$  são ilustrados na Figura 3. Dada uma fatia (Figura 3b) de um volume 3D (Figura 3a) é possível aplicar diversos valores de  $\theta$  e produzir diversas segmentações diferentes (Figuras 3c), 3d) e 3e)).

Escolher um valor adequado de limiar nem sempre é um trabalho trivial. Técnicas de otimização de limiar, como a técnica de Otsu (1979), foram criadas para solucionar esse problema. Contudo, mesmo com o valor de  $\theta$  for otimamente selecionado, não há garantia que esse limiar seja suficientemente representativo para segmentar o volume por completo.


A técnica de limiarização é, de fato, muito utilizada em sistemas de Visão Computacional. Entretanto, por ser simples e não tão eficaz, muitas vezes é reduzida a uma etapa de pré-processamento para posterior segmentação final utilizando outra(s) técnica(s).

### 2.1.2.2 Crescimento de Regiões

O Crescimento de Regiões é uma das técnicas baseadas em agrupamento de regiões mais utilizadas na segmentação de imagens. A ideia é agrupar subgrupos ou grupos de *pixels* em regiões maiores, de acordo com um determinado critério de adesão. Esse agrupamento normalmente se inicia a partir de um *pixel* chamado de semente que vai agregando *pixels*

<sup>2</sup> *Voxel* é a menor parte da imagem 3D. Análogo ao *pixel* (2D).

Figura 3 – exemplo de segmentação por limiarização. a) volume 3D, b) fatia original do volume, c) baixo nível de limiarização, d) médio nível de limiarização e e) alto nível de limiarização.



Fonte: Wirjadi (2007)

vizinhos e expandindo a região até que não haja mais vizinhos diretos que obedecem ao critério de adesão e que já não estejam agrupados (GONZALEZ; WOODS, 2018).

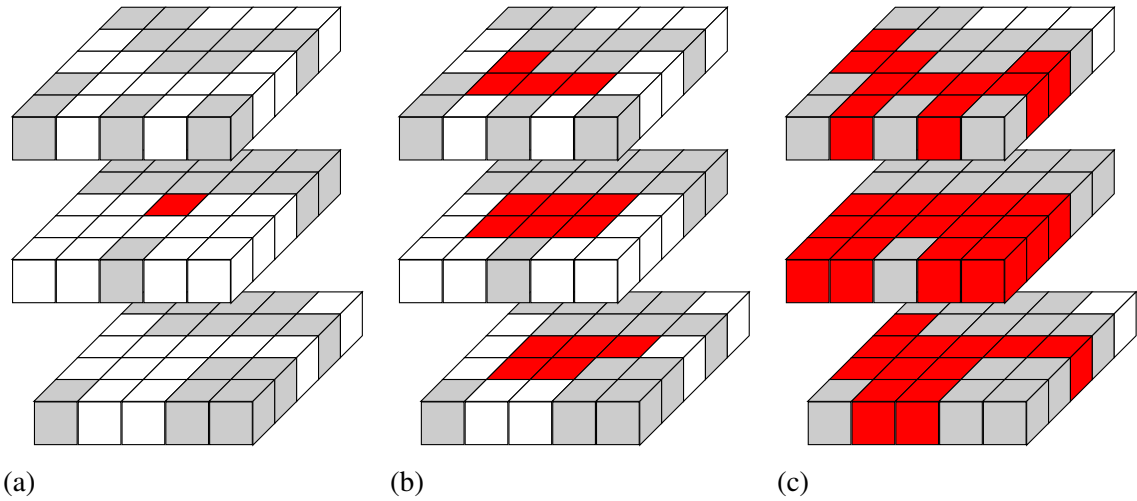
O conceito do Crescimento de Regiões pode ser expandido para 3D ao expandir a vizinhança do *voxel* para a análise em planos vizinhos. Nesse caso, ao segmentar um volume a partir de um *voxel* semente, analisa-se também os *voxels* do plano anterior e os *voxels* do plano posterior e se agrupam aqueles que atenderem ao mesmo critério de adesão, como está ilustrado na Figura 4.

Aplicações médicas como segmentação de artéria coronária (KERKENI *et al.*, 2016), comparação na segmentação dos pulmões (REBOUÇAS FILHO *et al.*, 2017) e pré-processamento para extração de ventrículo cerebral fetal (QIU *et al.*, 2017) são alguns exemplos envolvendo essa técnica. Crescimento de Regiões 3D vem sendo bastante aplicada e utilizada como referência para comparação na literatura ao longo dos anos por ser simples de implementar e, ainda assim, produzir bons resultados em algumas aplicações.

### 2.1.2.3 Operadores convolucionais

As técnicas baseadas em bordas partem da premissa básica que, ao se detectar o contorno de um objeto, está se detectando o próprio objeto. Gonzalez e Woods (2008) definem três estruturas primitivas que podem ser segmentadas em uma imagem: pontos isolados, linhas e

Figura 4 – ilustração da aplicação do Crescimento de Regiões 3D. a) determinação do *voxel* semente em destaque em vermelho, b) primeira iteração da técnica analisando a vizinhança do *voxel* semente e c) resultado final da segmentação.



Fonte: Adaptado de Ribeiro ().

bordas. Pontos isolados são *pixels* em uma imagem cuja intensidade luminosa na imagem varia abruptamente. As linhas são conjuntos desses *pixels* que formam, na verdade, um segmento. As bordas, por fim, são possíveis junções de pontos e linhas que formam as fronteiras de objetos dentro da imagem.

Inúmeras técnicas buscam identificar as descontinuidade da imagem (pontos, linhas e bordas). Contudo, a maneira mais simples se dá através de um processo convolucional entre uma imagem de entrada e um operador de convolução, onde cada estrutura primitiva possui uma máscara convolucional específica. Outra simples maneira de se identificar descontinuidades é através do operador gradiente na imagem, que também utiliza máscaras para filtragem específicas, como os operadores Sobel, Roberts e Prewitt (GONZALEZ; WOODS, 2008). Uma forma comum de se apresentar o operador Sobel 3D é ilustrada na Figura 5, em que são usadas três diferentes máscaras para fazer o cálculo da convolução em três fatias de um volume em sequência ao longo das direções X, Y e Z (HAFIZ *et al.*, 2011).

Em geral, a técnica de Limiarização, operadores convolucionais muitas vezes são utilizados como uma etapa de um fluxo maior. É comum o aparecimento desses operadores durante a fase de pré-processamento, onde se descartam objetos indesejáveis da cena. Outra aplicação para esses operadores é a sua utilização como energia externa para contornos ativos, que são metodologias de segmentação baseadas em bordas que tem ganhado destaque ao longo dos anos, e que a cada dia surgem novas variações da mesma.



Figura 5 – operador Sobel 3D em que cada filtro pode ser representado por três matrizes 2D ou simplesmente por um cubo 3D.

	Fatia anterior	Fatia atual	Fatia posterior	Operador Sobel 3D																											
Gradiente em X:	<table border="1"> <tr><td>-1</td><td>0</td><td>1</td></tr> <tr><td>-2</td><td>0</td><td>2</td></tr> <tr><td>-1</td><td>0</td><td>1</td></tr> </table>	-1	0	1	-2	0	2	-1	0	1	<table border="1"> <tr><td>-2</td><td>0</td><td>2</td></tr> <tr><td>-4</td><td>0</td><td>4</td></tr> <tr><td>-2</td><td>0</td><td>2</td></tr> </table>	-2	0	2	-4	0	4	-2	0	2	<table border="1"> <tr><td>-1</td><td>0</td><td>1</td></tr> <tr><td>-2</td><td>0</td><td>2</td></tr> <tr><td>-1</td><td>0</td><td>1</td></tr> </table>	-1	0	1	-2	0	2	-1	0	1	
-1	0	1																													
-2	0	2																													
-1	0	1																													
-2	0	2																													
-4	0	4																													
-2	0	2																													
-1	0	1																													
-2	0	2																													
-1	0	1																													
Gradiente em Y:	<table border="1"> <tr><td>1</td><td>2</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>-2</td><td>-1</td></tr> </table>	1	2	1	0	0	0	-1	-2	-1	<table border="1"> <tr><td>2</td><td>4</td><td>2</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-2</td><td>-4</td><td>-2</td></tr> </table>	2	4	2	0	0	0	-2	-4	-2	<table border="1"> <tr><td>1</td><td>2</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>-2</td><td>-1</td></tr> </table>	1	2	1	0	0	0	-1	-2	-1	
1	2	1																													
0	0	0																													
-1	-2	-1																													
2	4	2																													
0	0	0																													
-2	-4	-2																													
1	2	1																													
0	0	0																													
-1	-2	-1																													
Gradiente em Z:	<table border="1"> <tr><td>-1</td><td>-2</td><td>-1</td></tr> <tr><td>-2</td><td>-4</td><td>-2</td></tr> <tr><td>-1</td><td>-2</td><td>-1</td></tr> </table>	-1	-2	-1	-2	-4	-2	-1	-2	-1	<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table>	0	0	0	0	0	0	0	0	0	<table border="1"> <tr><td>1</td><td>2</td><td>1</td></tr> <tr><td>2</td><td>4</td><td>2</td></tr> <tr><td>1</td><td>2</td><td>1</td></tr> </table>	1	2	1	2	4	2	1	2	1	
-1	-2	-1																													
-2	-4	-2																													
-1	-2	-1																													
0	0	0																													
0	0	0																													
0	0	0																													
1	2	1																													
2	4	2																													
1	2	1																													

Fonte: Autor.

## 2.2 Contornos Ativos

O Método dos Contornos Ativos (MCA) é conhecido na literatura como *snakes* e foi introduzido por Kass *et al.* (1987). Este método tem por objetivo a detecção de contornos de objetos em imagens digitais. O MCA se baseia em métodos variacionais cujo propósito é encontrar uma aproximação para minimizar uma função que representa a energia de uma curva. A ideia da técnica é estabelecer uma curva paramétrica em torno de um objeto de interesse de modo que essa curva seja conduzida, através de forças, até as bordas do objeto, que é o local onde a menor energia deve ser encontrada. A movimentação da curva é realizada mediante iterações sucessivas buscando-se a menor energia em uma vizinhança local, pois, parte-se do pressuposto que se todos os pontos da curva atingirem um mínimo local, a curva atinge seu mínimo global.

Paralelamente à criação dos MCA tradicionais, Osher e Sethian (1988) desenvolveram uma metodologia chamada *level-set* que serviria de base para a criação de *snakes level-set* chamados de MCA geométricos (ou geodésicos). Estes são definidos implicitamente como curvas geodésicas de uma topologia pré-existente implementados através do método *level-set*. Os MCA geométricos são representados por curvas de nível partindo de uma formulação Euleriana podendo ser expandido para múltiplas dimensões.

A principal diferença entre esses e os *snakes* tradicionais é que os tradicionais se baseiam em uma representação explícita da segmentação do contorno como curvas paramétricas, enquanto a abordagem *level-set* depende de uma representação implícita do contorno como uma interseção de uma superfície 3D com um plano (GONZALEZ; WOODS, 2018).

Um conhecido tipo de *snakes* são os chamados morfológicos (MÁRQUEZ-NEILA *et al.*, 2014) que possuem comportamento similar aos contornos ativos baseados em *level-set*. Esta técnica se baseia no trabalho de Chan e Vese (2001) que propuseram um novo MCA baseado em regiões, sem uma função de parada dependente de bordas (independente de gradiente) que utiliza informações de intensidade das regiões de interesse para guiar os contornos. Para isso, parte-se da premissa que a intensidade das regiões de interesse são homogêneas. No entanto, o MCA morfológico utiliza operadores morfológicos (tais como erosão e dilatação) em uma matriz binária ao invés de resolver equações de derivadas parciais em matrizes com valores decimais. Logo, isso faz com que *snakes* morfológicos tendam a ser numericamente mais rápidos do que os métodos tradicionais.

O método proposto nessa tese deriva dos MCAs explícitos e, por esse motivo, a descrição a seguir enfatiza a construção matemática dos *snakes* paramétricos e não os geométricos. Contudo, ao final do trabalho a técnica proposta é comparada com o MCA morfológico visando a avaliação do seu custo computacional.

### 2.2.1 Bidimensional (2D)

O MCA consiste na parametrização 2D de uma curva geométrica  $c$  da forma (KASS *et al.*, 1987)

$$\begin{cases} [0, 1] \rightarrow \mathbb{R}^2 \\ c(s) = [x(s), y(s)], \end{cases} \quad (2.2)$$


em que cada ponto  $c(s)$  está localizado no par ordenado  $[x(s), y(s)]$ . Este modelo pode ser chamado de deformável porque é descrito através de uma função de energia  $E$  definida por (KASS *et al.*, 1987)

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

no qual a energia total de cada ponto da curva é representada pelo termo  $E_s$ ,  $E_{int}$  e  $E_{ext}$  são termos que denotam a energia interna e a energia externa do *snake* naquele ponto, respectivamente.

Visando maximizar a eficiência do MCA, alguns pontos de controle são definidos e, a partir da ligação entre estes, forma-se a curva. Dessa maneira, apenas esses pontos de controle são considerados no cálculo das energias. Como o objetivo do método é minimizar a função de energia  $E_s$  da Equação 2.3, e o *snake* é definido pelos pontos de controle  $c(s)$ , costuma-se analisar a vizinhança de cada um dos pontos buscando o local mais adequado para que  $E_s$  possua seu menor valor. Na Figura 6 é ilustrado um recorte de uma curva contendo alguns pontos de controle e evidenciada a vizinhança de busca do ponto  $c(s)$  com seus oito possíveis destinos, além da sua localização atual, que não é descartada como posição de menor energia.

Figura 6 – recorte de uma curva contendo pontos de controle e vizinhança de busca.




Fonte: Autor.

Neste sentido, quanto maior a quantidade de pontos mais precisa é a curva. Todavia, maior é o custo computacional para a minimização da energia. Além disso, a quantidade de pontos de controle é definida inicialmente, mas pode variar no decorrer das iterações da curva. Assim, esta curva pode se alongar ou encurtar por meio de regras de adição e remoção de pontos (ALEXANDRIA *et al.*, 2011; REBOUÇAS FILHO, ). Outro fator que pode interferir no custo computacional é o tamanho da janela de busca da vizinhança, pois, quanto maior a janela maior a quantidade de operações que são feitas e mais possíveis destinos se tem para cada ponto de controle, conforme ilustrado na Figura 7. Nesta Figura é mostrado um ponto de controle com uma vizinhança de  $5 \times 5$  pixels e 24 possíveis destinos para onde se movimenta esse ponto.

A geometria da curva, definida a partir dos pontos de controle, depende dos cálculos das energias interna e externa, definidas a seguir.

Figura 7 – destaque de vizinhança  $5 \times 5$  de um ponto de controle de um MCA.



Fonte: Adaptado de Cavalcante ().

### 2.2.1.1 Energia Interna

O primeiro termo da Equação 2.3  $E_{int}$  é chamado de energia interna e depende unicamente de parâmetros provenientes da geometria da curva. Essa energia controla o movimento natural do contorno mantendo-o suave e constante (NIXON; AGUADO, 2002) e é dividido em dois termos conforme definição inicial de Kass *et al.* (1987)


$$E_{int}[c(s)] = \alpha(s) \left| \frac{d}{ds} c(s) \right|^2 + \beta(s) \left| \frac{d^2}{ds^2} c(s) \right|^2, \quad (2.4)$$

em que  $\alpha(s)$  e  $\beta(s)$  são parâmetros que servem para quantificar a importância de cada termo de  $E_{int}$ , sendo o primeiro chamado de Força de Continuidade ( $F_{cont}$ ) ou de Força de Elasticidade e o segundo termo chamado de Força de Curvatura ( $F_{curv}$ ).

A Força de Continuidade está ligada à capacidade elástica da curva, isto é, à capacidade que os pontos da curva possuem de se distanciarem ou de se aproximarem dos pontos adjacentes de modo que o contorno fique o mais uniforme possível (ALMEIDA, ). Para extrair essa informação, aproxima-se o cálculo da derivada de primeira ordem da Equação 2.4 como a norma entre dois pontos, proposto no trabalho original de Kass *et al.* (1987). Contudo, esse cálculo deve ser realizado com relação ao ponto  $c(s)$  e toda a janela de busca de um ponto adjacente com os possíveis destinos que, apesar de trivial, demanda um certo custo computacional, dependendo do tamanho da região de busca. O efeito da Força de Continuidade está ilustrado na Figura 8 em que o maior valor implica em uma maior taxa de mudança naquela região do contorno. A Figura 8a) ilustra um contorno com regiões com pontos próximos e regiões com

pontos distantes. Após o cálculo do primeiro termo da Equação 2.4, o contorno tende a se ajustar, mantendo uma forma contínua com os pontos mais equidistantes, como mostrado na Figura 8b).

Figura 8 – ilustração do efeito da Força de Continuidade em que a) ilustra um contorno irregularmente espaçado e em b) o mesmo contorno após a regularização através do primeiro termo da Equação 2.4.




Fonte: Autor.

Já a Força de Curvatura está ligada à suavização do contorno de modo a deixá-lo o mais suave possível através da redução de trechos irregulares e pontiagudos (NIXON; AGUADO, 2002). Por se tratar da derivada de segunda ordem do contorno, sua aproximação pode ser obtida através de diferenças finitas e, assim, calculada a curvatura entre o ponto anterior  $c(s - 1)$  e o ponto posterior  $c(s + 1)$ . Portanto, são necessárias informações da janela de busca da vizinhança de três pontos para o cálculo desta força. O efeito da Força de Curvatura está ilustrado na Figura 9 na qual a Figura 9a) mostra um contorno com um ponto discrepante com alto valor de curvatura se comparado com os demais. Após o cálculo do segundo termo da Equação 2.4, o contorno tende a regularizar os valores de curvatura mantendo-se suave como ilustrado na Figura 9b).

Além das forças citadas anteriormente, novas forças foram criadas com o passar do tempo. Cohen (1991) foi um dos primeiros a adicionar um termo à Equação da energia interna quando percebeu que a Força de Curvatura, que sempre busca maximizar a angulação entre os pontos do contorno de modo a evitar trechos pontiagudos, não permite que o contorno possa crescer e com isso ser inicializado internamente ao objeto.

Para solucionar o problema apresentado, Cohen (1991) introduz a Força Balão  $F_{bal}$  para inflar e expandir o contorno a partir de seu interior. Esse conceito é largamente conhecido (SONKA *et al.*, 2008) e de fundamental importância haja visto que o interior de um objeto de interesse tende a ter regiões semelhantes e/ou homogêneas. Por outro lado, as regiões externas ao objeto podem, possuir qualquer tipo de estrutura e, com isso, dificultarem a movimentação do

Figura 9 – ilustração do efeito da Força de Curvatura em que a) ilustra um contorno com um ponto com curvatura discrepante (em vermelho) dos demais e em b) o mesmo contorno após a regularização através do segundo termo da Equação 2.4.



Fonte: Autor.

*snake* produzindo uma falsa segmentação.

Cohen (1991) define a Força Balão ( $F_{bal}[c(s)]$ ) como uma pressão interna ao contorno que o empurra para fora, de modo análogo a um balão que infla ao ser preenchido. Originalmente definida em função do vetor unitário  $n(s)$  normal a curva no ponto  $c(s)$  como

$$F_{bal}[c(s)] = n(s). \quad (2.5)$$

Logo, é necessário o cálculo do vetor unitário normal a cada ponto da curva. Isso demanda um certo custo computacional, uma vez que uma curva pode ter tantos pontos quanto forem necessário, pois, como dito anteriormente, a quantidade de pontos é variável em cada iteração e movimentação do *snake*. Soma-se a isso, o fato de ser necessário calcular as forças para cada possível destino de cada ponto em uma nova iteração, pois, o *snake* se movimenta buscando minimizar energia e. Nesse caso, o ponto de menor energia deve ser sempre no extremo da janela de busca que é onde o vetor unitário é o maior possível (vide exemplo de janela de busca  $5 \times 5$  na Figura 7).

Tanto a Força de Continuidade quanto a Força de Curvatura e a Força Balão foram propostas para serem utilizadas em MCAs de modo genérico e sem aplicação específica. Com o tempo surgiram novos elementos utilizados como forças internas em função da característica de cada aplicação. Radeva *et al.* (1995), por exemplo, adicionam um termo relativo aos olhos do ser humano, visando a segmentação das estruturas da face. Já Pardo *et al.* (1997), tratam o *snake* em função de um conjunto de imagens médicas de TC e propõem uma força interna cuja formulação é dependente de informações adquiridas em fatias anteriores para inicializar a curva

mais próxima ao objeto. Luo *et al.* (2000) reformulam a energia interna para servir de termo de suavização sem que a curva precise necessariamente se contrair e, eventualmente, entrar em colapso. A literatura trás uma série de outros trabalhos com novas forças internas e diferentes aplicações (JACOB *et al.*, 2004), inclusive trabalhos que já melhoram as novas forças criadas como, por exemplo, a Força Balão (REBOUÇAS FILHO *et al.*, 2014).

### 2.2.1.2 Energia Externa

Além da energia interna, a Equação geral de energias do MCA, Equação 2.3, contém um segundo termo, referente à energia externa  $E_{ext}[c(s)]$ . Este termo permite ao método uma adaptação sobre os objetos da imagem uma vez que não depende mais da geometria do contorno e sim de informações proveniente da própria imagem. É justamente a energia externa que não permite que o *snake* entre em colapso ao se contrair sobre si mesmo ou que este se distancie para além dos limites da imagem.

De acordo com Kass *et al.* (1987), a energia externa  $E_{ext}[c(s)]$  pode ser expressa por uma combinação ponderada de três outros termos conforme

$$E_{ext}[c(s)] = w_{line}(s)E_{line}(s) + w_{edge}(s)E_{edge}(s) + w_{term}(s)E_{term}(s), \quad (2.6)$$

em que  $w_{line}(s)$ ,  $w_{edge}(s)$  e  $w_{term}(s)$  são os coeficientes de ponderação das energias provenientes das linhas, das bordas e das terminações, respectivamente. Já  $E_{line}(s)$ ,  $E_{edge}(s)$  e  $E_{term}(s)$  são as próprias energias dos mesmos termos.

Segundo Nixon e Aguado (2002), a energia proveniente das linhas, ou simplesmente o operador gradiente da imagem, já extrai informações das linhas, das bordas e das terminações dos objetos. Dessa forma, uma maneira simplificada de calcular a energia externa é dada por

$$E_{ext}[c(s)] = -|\nabla G_{\sigma} * I[c(s)]|^2, \quad (2.7)$$

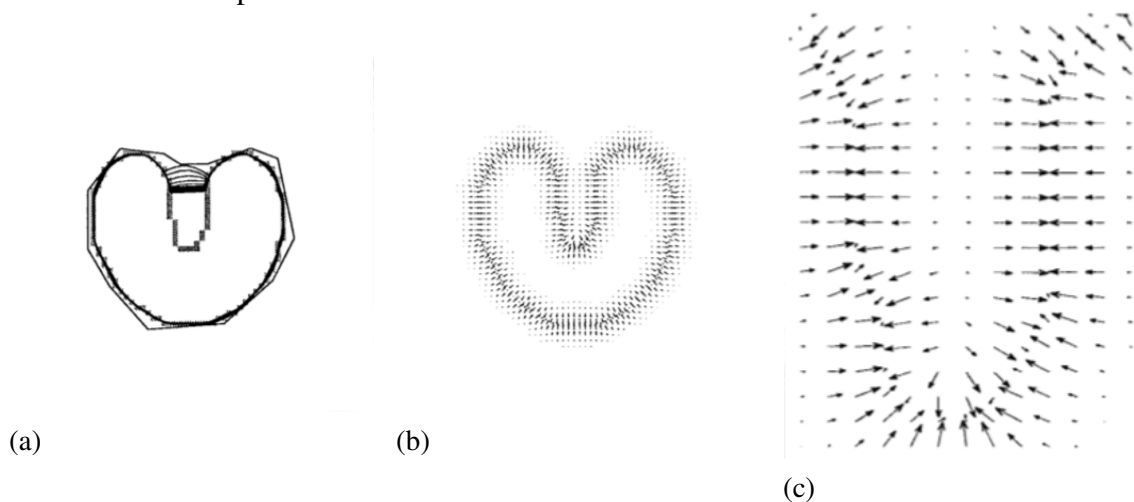
em que  $\nabla$  é o operador gradiente e  $G_{\sigma}$  é uma função gaussiana centrada no ponto  $c(s)$  de variância  $\sigma^2$  (XU; PRINCE, 1998b). Quanto maior o valor utilizado em  $\sigma^2$ , maior o borramento na imagem, especialmente nas bordas. Entretanto, esse fato pode ser útil uma vez que permite ao MCA detectar as bordas mais facilmente através do espalhamento formado pelo borramento e pela redução de ruído na imagem (ALEXANDRIA *et al.*, 2011; FÉLIX, ).

Ao combinar as informações do contorno e as informações da imagem, é possível movimentar o *snake* de maneira que se ajuste às bordas do objeto, que é onde estão as informações de menor energia, definido pelas forças da energia interna para que a curva não estacione em ruídos locais e continue suave e constante.

Da mesma forma como a energia interna, vários autores vem propondo diversas formulações para novas energias externas. Contudo, como essa energia é totalmente proveniente de informações da imagem e, existindo inúmeras modalidades e tipos de imagens, o percentual de novas técnicas é muito maior para energias externas do que para energias internas.

Uma das abordagens que mais tem se destacado ao longo dos anos é a técnica desenvolvida por Xu e Prince (1998b), chamada de Fluxo do Vetor Gradiente (*Gradient Vector Flow - GVF*)<sup>3</sup>. Essa técnica se tornou importante em decorrência da limitação intrínseca do MCA, utilizando o operador gradiente em não segmentar corretamente estruturas côncavas. Esta limitação se deve ao fato da não existência de fluxo do gradiente em regiões uniformes, como pode ser visto na Figura 10. Na Figura 10a) é ilustrada a dinâmica de um MCA ao tentar segmentar um objeto côncavo. Percebe-se que a curva não consegue penetrar a região da concavidade porque o fluxo do gradiente das bordas se anulam, impossibilitando a segmentação destas regiões. Este fluxo é ilustrado pela Figura 10b) e amplificado pela Figura 10c).

Figura 10 – a) convergência de um MCA usando b) energia externa tradicional, e c) recorte com detalhe para a borda da concavidade.



Fonte: Xu e Prince (1998b).

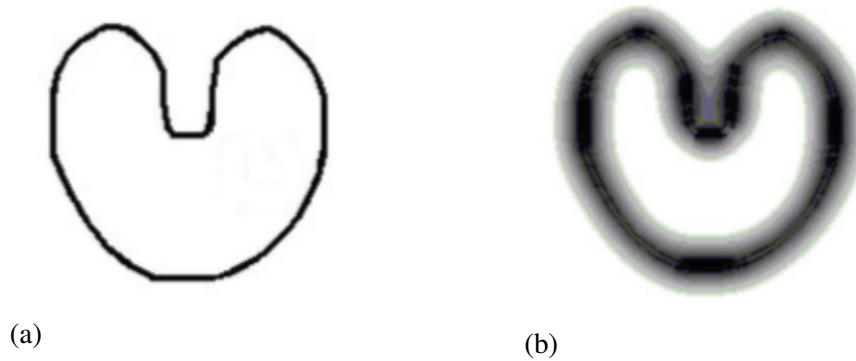
Xu e Prince (1998b) desenvolveram a técnica de GVF visando a intensificação das

<sup>3</sup> Em Abril de 2018, o trabalho de Xu e Prince (1998b) recebeu mais de 5100 citações listadas no *Google Scholar* e está classificado como a 10<sup>a</sup> publicação entre mais de 17.000 publicações citando o artigo original de Kass *et al.* (1987).



bordas e a distribuição suave do gradiente em regiões homogêneas, conforme ilustrado na Figura 11. Nesse método, é construído um campo de vetores que direciona o gradiente para as bordas do objeto e, por sua vez, conduz o *snake* para as mesmas bordas. Além disso, com essa nova energia externa é reduzida a sensibilidade do posicionamento do contorno inicial, uma vez que o *snake* consegue perceber o fluxo do vetor do gradiente espalhado por uma área maior do que apenas imediatamente em volta do objeto, conforme ilustrado na Figura 11b).

Figura 11 – aplicação do GVF, a) imagem original e a) suaviação de bordas.



Fonte: Cavalcante ().

A energia externa GVF,  $E_{GVF}$ , é definida por um campo de vetores,  $V_{GVF}$ , que é calculado através da difusão de gradientes derivados do operador gradiente (XU; PRINCE, 1998b)

$$V_{GVF} = [u_{GVF}(x,y), v_{GVF}(x,y)], \quad (2.8)$$

em que o campo de vetores  $V_{GVF}$  é definido de modo a minimizar a função de energia

$$E_{GVF} = \int \int [\mu(u_{GVFx}^2 + u_{GVFy}^2 + v_{GVFx}^2 + v_{GVFy}^2) + |\nabla f_{GVF}|^2 |V_{GVF} - \nabla f_{GVF}|^2] dx dy, \quad (2.9)$$

em que  $\nabla f_{GVF}$  é o mapa de bordas da imagem,  $u_{GVFx}$ ,  $u_{GVFy}$ ,  $v_{GVFx}$  e  $v_{GVFy}$  são as primeiras derivadas parciais de  $u_{GVF}$  e  $v_{GVF}$  em relação a  $x$  e a  $y$ , respectivamente e  $\mu$  é um parâmetro de regularização que controla relação entre o primeiro e o segundo termo da integral (XU; PRINCE, 1998b; CAVALCANTE, ).

Apesar de ser uma técnica amplamente utilizada, esta possui um alto custo computacional oriundo dos cálculos dos campos de difusão do fluxo dos vetores do gradiente (WEI *et al.*, 2004; CHENG; FOO, 2006), além de apresentar restrições para segmentar regiões com concavidades estreitas e profundas (FÉLIX, ).

A partir do GVF de Xu e Prince (1998b), trabalhos como o Fluxo do Vetor Gradiente Generalizado (*Generalized GVF* - GGVF) (XU; PRINCE, 1998a), Fluxo do Vetor Gradiente Direcional Dinâmico (*Dynamic Directional GVF* - DDGVF) (CHENG; FOO, 2006), Fluxo do Vetor Gradiente Normal (*Normal GVF* - NGVF) (JIFENG *et al.*, 2007), Convolução de Campo de Vetores (*Vector Field Convolution* - VFC) (LI; ACTON, 2007) e Fluxo do Vetor Gradiente Normal Enviesado (*Normally Biased GVF* - NBGVF) (WANG *et al.*, 2010), foram criados seguindo o mesmo princípio de um mapa de vetores de gradiente. Essas técnicas têm sido adaptadas, aperfeiçoadas e expandidas para outras dimensões (3D) ao longo do tempo.

### 2.2.2 Tridimensional (3D)

A generalização da curva que define o MCA 2D pode ser obtida no espaço 3D como uma superfície que é deformada, através de cálculos de forças e energias, e expandida ou contraída para se moldar à forma de um volume de interesse. A movimentação dessa superfície pode ser obtida através de sucessivas iterações em que cada ponto da superfície pode se locomover nos três eixos buscando a minimização de sua energia (MCINERNEY; TERZOPOULOS, 1996; SLABAUGH; UNAL, 2005; COOK *et al.*, 2015). Por esse motivo, essa técnica é chamada de Método de Superfícies Ativas (MSA) ou, dependendo do autor, também é denominada Modelos Deformáveis 3D, Método das Malhas Ativas, *snakes* 3D ou, simplesmente, MCA 3D (CAVALCANTE, ).

Semelhante à Equação 2.2 de parametrização do MCA, um MSA é tipicamente definido por uma superfície geométrica  $v(s,r)$  da forma (COHEN; COHEN, 1993)

$$\begin{cases} [0, 1] \times [0, 1] \rightarrow \mathbb{R}^3 \\ v(s, r) = [x(s, r), y(s, r), z(s, r)], \end{cases} \quad (2.10)$$

em que cada ponto  $v(s,r)$  corresponde a um *voxel* localizado nas coordenadas  $[x(s, r), y(s, r), z(s, r)]$ . Já a energia associada  $E$  é definida por

$$E = \int_0^1 E_s[v(s, r)] ds = \int_0^1 \{E_{int}[v(s, r)] + E_{ext}[v(s, r)]\} ds, \quad (2.11)$$

no qual a energia total de cada ponto da superfície é representada pelo termo  $E_s$  e  $E_{int}$  e  $E_{ext}$  são termos que denotam a energia interna e a energia externa naquele ponto, respectivamente.

Em 3D, a energia externa  $E_{ext}$ , advinda de informações presentes na imagem, é calculada da mesma maneira que no caso de 2D. Já o cálculo da energia interna  $E_{int}$  é modificado para a forma (para  $v \rightarrow v(s,r)$ ) (COHEN; COHEN, 1993; AHLBERG, 1996)

$$E_{int}[v] = \alpha_1(s) \left| \frac{\partial}{\partial s} v \right|^2 + \alpha_2(s) \left| \frac{\partial}{\partial r} v \right|^2 + \beta_1(s) \left| \frac{\partial^2}{\partial s^2} v \right|^2 + \beta_2(s) \left| \frac{\partial^2}{\partial r^2} v \right|^2 \quad (2.12)$$

em que  $\alpha_1(s)$  e  $\alpha_2(s)$  são os parâmetros que quantificam a importância da força de continuidade na superfície e os parâmetros  $\beta_1(s)$  e  $\beta_2(s)$  definem a relevância da força de curvatura.

Na metodologia do MCA, isto é, em duas dimensões, o contorno é definido por um vetor de pontos interligados, no qual cada ponto tem dois vizinhos. Logo, para o MSA, em três dimensões, os pontos são representados por matriz ou, como é comumente chamado na literatura, como uma malha (AHLBERG, 1996).

De forma semelhante à adotada na dinâmica do MCA, o MSA se move através de seguidas iterações em que pontos são adicionados e/ou removidos ao longo do processamento para que a malha se molde ao volume a ser segmentado. Contudo, como é de se esperar, esse processamento em 3D é computacionalmente mais lento, pois, funções como adição e remoção de pontos, por exemplo, elevam o custo computacional dos cálculos, uma vez que um ponto pode ter mais de dois vizinhos e isso pode acarretar em uma completa reestruturação da malha (MISHRA *et al.*, 2010).


Apesar da maioria das metodologias de MSA envolverem malhas, existem alguns poucos trabalhos que realizam segmentação 3D com contornos ativos sem malhas. Nesses casos, existem as técnicas chamadas de  $2\frac{1}{2}D$  (nomenclatura usada por Cohen e Cohen (1993)), na qual não existe uma superfície 3D real e sim vários *snakes* 2D em que cada um é aplicado em um nível diferente da terceira dimensão. Nesses casos, é clara a inexistência de relação entre os contornos e, com isso, não é possível que um influencie no outro, o que acarreta muitas vezes em uma segmentação não confiável e incompleta.

De acordo com Cavalcante (), o tipo de malha mais utilizada nos MSAs verdadeiramente 3D é a malha estruturada regular. Esta malha tem uma divisão clara para todos os seus pontos, também chamado de *nós*, que possuem a mesma quantidade de elementos adjacentes. Esse tipo de malha é fácil de se gerar e manipular, além de permitir uso de uma estrutura de dados simples, facilitando a implementação computacional (KALLEMEYN *et al.*, 2012).

Um exemplo de três diferentes tipos de malhas é ilustrado na Figura 12. A Figura 12a) ilustra uma malha estruturada, onde cada elemento é um quadrilátero e cada nó possui 4

outros nós como vizinhos exceto pelos polos, que formam triângulos com seus  $N$  vizinhos. Já a Figura 12b) mostra uma malha estruturada contendo elementos triangulares em que cada nó que possui 5 nós vizinhos. Por último, na Figura 12c), é mostrada uma malha não estruturada, com triângulos de formas variadas onde cada nó pode se conectar a uma quantidade qualquer de outros nós conforme a topologia da malha.

Figura 12 – exemplos de malhas a) estruturada retangular, b) estruturada triangular e c) não estruturada.



Fonte: Autor.

Dada a dinâmica do MSA para que a superfície ativa possa se moldar ao objeto após um determinado número de iterações, a quantidade de nós que a compõe pode variar muito durante o processo de segmentação. Enquanto em uma curva (2D), cada ponto do MCA possui dois únicos vizinhos, conforme representado na Figura 6, e a menor região de busca se limitava a 9 elementos (vizinhança  $3 \times 3$ ). Já em 3D, cada ponto do MSA pode ter uma quantidade ilimitada de vizinhos e a região de busca possui pelo menos 27 elementos (vizinhança  $3 \times 3 \times 3$ ). Portanto, o tipo de malha adotado está diretamente ligado ao custo computacional do algoritmo, já que um determinado ponto pode ter uma quantidade limitada de vizinhos (em malhas estruturadas) ou ilimitada (em malhas não estruturadas). Somado a isso, o fato desses nós poderem ser removidos e também adicionados posteriormente faz com que suas ligações possam ser desfeitas e refeitas e a topologia da superfície modificada. Logo, mais cálculos são necessários para otimizar a ligação entre esses pontos.

## 2.3 Contornos Ativos Radiais


O sucesso dos MCAs é tamanho que surgiram inúmeras variações da técnica em diversas aplicações e não se limitam ao plano 2D. A partir dos MCAs foram criados os MSAs que expandiram o conceito para terceira dimensão. Em 3D, é possível uma segmentação mais completa devido ao aumento de informações a ser processada. Buscando obter informações do volume 3D sem perder performance computacional, uma nova categoria derivada do MCA é criada e chamada de MCA Radial (MCAR), ou *snakes* radiais.

De um modo geral, o MCAR possui um fundamento comum ao MCA tradicional, que é o de minimizar a função de energia de um contorno através da atuação de forças. Contudo, a principal característica que diferencia estas técnicas é que os *snakes* radiais utilizam coordenadas polares ao invés de coordenadas cartesianas na busca por seus pontos de controle. Assim, ao invés de se localizar por pontos  $(x,y)$ , cada ponto do *snake* radial é dado em função de  $(r,\phi)$  (ALEXANDRIA *et al.*, 2011). Esse conceito é derivado da uma técnica chamada Raios Ativos (*Active Rays*) (DENZLER; NIEMANN, 1999), que é detalhado em seguida.

### 2.3.1 Raios Ativos (*Active Rays*)

Os Raios Ativos, introduzidos por Denzler e Niemann (1996) e também chamado de Método dos Contornos Ativos Polares (MCAP) (VERSARI *et al.*, 2017), possuem a mesma base fundamental dos MCAs, como dito anteriormente. A ideia da técnica é definir um ponto central interno ao objeto que se deseja segmentar e, a partir deste, encontrar os pontos que formam o contorno do objeto efetuando uma busca ao longo de raios (ou feixes) que divergem do ponto central  $m$ , conforme ilustrado na Figura 13.

Figura 13 – representação dos Raios Ativos.



Fonte: Adaptado de Denzler e Niemann (1996).

Levando em conta os parâmetros da Figura 13 e de maneira semelhante à definição do MCA pela Equação 2.2, os Raios Ativos podem ser definidos como (DENZLER; NIEMANN, 1996)

$$\begin{cases} [0, 1] \rightarrow R^2 \\ c(s) = c_m[\phi(s), \lambda(s)], \end{cases} \quad (2.13)$$

em que cada ponto  $c_m$  está localizado nas coordenadas polares  $[\phi(s), \lambda(s)]$ , sendo  $\phi$  o ângulo do raio  $\rho$  que diverge do ponto central  $m$  ( $[x_m, y_m]^T$ ) e  $\lambda$  seu comprimento. Dessa maneira, cada raio é definido por (DENZLER; NIEMANN, 1996)

$$\rho(\phi, \lambda) = f[x_m + \lambda \cos(\phi), y_m + \lambda \sin(\phi)], \quad (2.14)$$

no qual  $f$  é uma imagem em tons de cinza e  $0 \leq \lambda \leq n_\phi$ , de modo que  $n_\phi$  é dado pelo comprimento do feixe que se inicia no ponto central  $m$  até a extremidade da imagem. Logo, a distância do ponto de controle na angulação  $\phi$  a partir do ponto  $m$  pode ser descrita por (DENZLER; NIEMANN, 1999)


$$\lambda(\phi) = \underset{\lambda}{\operatorname{argmin}} \left( - \left| \frac{\partial}{\partial \lambda} \rho(\phi, \lambda) \right|^2 \right). \quad (2.15)$$

Verifica-se, através dessas equações, que a estrutura dos Raios Ativos se baseia em dois parâmetros fundamentais: comprimento do raio ( $\lambda$ ) e angulação do raio ( $\phi$ ). Pode-se dizer que o objetivo da técnica se resume a minimizar uma função de energia, buscando ao longo de um raio de comprimento  $\lambda$  e quanto maior o ângulo  $\phi$ , menos raios deve haver. Assim, a busca se resume a uma busca 1D limitada à quantidade de raios que divergem do centro do objeto. Por esse motivo, a técnica de Denzler e Niemann (1996) é ideal para rastreamento de objetos em tempo real ou segmentações rápidas.

Contudo, é de se esperar que poucos raios não sejam suficientes para descrever o contorno do objeto por completo. Quanto mais complexo e irregular o contorno a ser segmentado, mais feixes são necessários para discretizá-lo com qualidade. Da mesma maneira, se um objeto possui, por exemplo, uma forma regular, a segmentação tende a ser completa com poucos feixes. Esses dois casos estão ilustrados na Figura 14 na qual a Figura 14a) é um objeto com contorno complexo e irregular e na Figura 14d) é um simples quadrado. Nas Figuras 14b) e 14e) são

exemplos da aplicação dos Raios Ativos e, por fim, nas Figuras 14c) e 14f) estão os resultados das duas segmentações com apenas 8 feixes.

Figura 14 – exemplo de segmentação de objeto por Raios Ativos em que a) e d) são objetos de referência; b) e e) são os resultados da aplicação da técnica e c) e f) são os resultados das segmentações.



Fonte: Autor.

Por se tratar de um feixe unidimensional, a equação de energia dessa técnica também é e pode ser definida de maneira semelhante à Equação 2.3 do MCA por (DENZLER; NIEMANN, 1996)

$$E = \int_0^{2\pi} \{E_{int}[\lambda(\phi)] + E_{ext}[\lambda(\phi)]\} d\phi, \quad (2.16)$$


em que os termos  $E_{int}$  e  $E_{ext}$  representam as energias internas e externa, respectivamente, ao longo do feixe  $\lambda$ , a partir de um ângulo  $\phi$ . Portanto, a janela de busca local para essa metodologia se resume à busca da menor energia em um sinal 1D, pois, os pontos de controle só podem variar ao longo do raio e não mais em duas dimensões sobre o plano como está mostrado na Figura 7. Contudo, ainda assim, podem existir mínimos locais que possam gerar falsos positivos e, por esse motivo, trabalhos como o de Chen *et al.* (2001) buscam uma forma de otimizar a busca recursiva através técnicas de programação dinâmica, por exemplo.

De maneira similar à adotada para os MCAs na Equação 2.4, a energia interna dos raios ativos controla a maneira como o contorno pode se deformar para se adaptar ao objeto. Para isso, a energia interna  $E_{int}[c_m(\phi)]$  em um ponto de controle  $c_m(\phi)$  é decomposta nas duas forças citadas na seção 2.2.1.1, Força de Continuidade ( $F_{cont}$ ) e Força de Curvatura ( $F_{curv}$ ), e pode ser definida por (DENZLER; NIEMANN, 1996)

$$E_{int}[c_m(\phi)] = \alpha(\phi) \left| \frac{\partial}{\partial \phi} \lambda(\phi) \right|^2 + \beta(\phi) \left| \frac{\partial^2}{\partial \phi^2} \lambda(\phi) \right|^2, \quad (2.17)$$

no qual o primeiro termo representa a Força de Continuidade, que está ligada à capacidade elástica do contorno, e o segundo termo representa a Força de Curvatura, que é responsável pela suavização do contorno. Os parâmetros  $\alpha(\phi)$  e  $\beta(\phi)$  são parâmetros de configuração de importância de cada força  $F_{cont}$  e  $F_{curv}$ , respectivamente. Essas forças agem de maneira semelhante à situação mostrada nas Figuras 8 e 9, nas quais tendem a manter o contorno igualmente espaçado, evitando ângulos agudos. Todavia, o ponto de controle não pode se movimentar livremente sobre o plano. Este, por sua vez, só pode se mover ao longo de cada feixe, como é exemplificado na Figura 15.

Figura 15 – ilustração do efeito das Forças de Continuidade e Curvatura sobre um contorno formado por 8 pontos de controle em que a) ilustra um contorno irregular com pontos mal espaçados e cantos pontiagudos enquanto a ilustra o mesmo contorno após a regularização através de  $F_{cont}$  e  $F_{curv}$ .



Fonte: Autor.

Além da energia interna, a Equação 2.16 possui seu último termo que trata da energia externa  $E_{ext}[\lambda(\phi)]$ . Esta energia é proveniente unicamente da imagem e esse termo contém as informações da imagem somente ao longo do feixe. Com isso, o espaço de busca que era o plano da imagem, passa a ser a quantidade de raios  $\rho$  vezes o tamanho  $\lambda$  de cada raio. Isso, por si só, já reduz abruptamente as buscas dos mínimos globais da imagem, pois, enquanto uma imagem




de tamanho  $100 \times 100$  *pixels* há 10.000 possíveis *pixels* para serem analisados por um MCA tradicional, a mesma imagem ao ser analisada pelos 72 Raios Ativos (para  $\phi = \frac{\pi}{36} = 5^\circ$ ) de tamanho  $\lambda = 50$  *pixels* reduz o campo de busca para apenas 3.600 *pixels* (uma redução de 64%). Essa energia externa pode ser calculada em função do gradiente 1D sobre o raio  $\rho$  da imagem na forma da seguinte derivada (DENZLER; NIEMANN, 1996)

$$E_{ext}[c_m(\phi)] = -|\nabla f[c_m(\phi)]|^2 = -\left|\frac{d}{d\lambda}\rho(\phi, \lambda)\right|^2. \quad (2.18)$$

Apesar dos Raios Ativos existirem como técnica há algum tempo, esta não é tão estudada como os *snakes* tradicionais. Todavia, é uma abordagem que continua sendo aplicada ao longo dos anos e é considerada promissora no campos de sistemas de Visão Computacional por ter introduzido os *snakes* radiais (WEIHERER, ). Ao comparar com os *snakes* tradicionais, os radiais possuem a clara vantagem do baixo custo computacional que lhe dá suporte a aplicações em tempo real e/ou sistemas de VC embarcadas (GEMIGNANI *et al.*, 2004; GEMIGNANI *et al.*, 2007). Isso se deve a diversos fatores já citados como, por exemplo, a janela de busca ser 1D. Além disso, não há necessidade de funções de adição ou remoção de pontos de controle, uma vez que, cada ponto só pode se mover ao longo de um raio e quantidade de raios é previamente definida junto com seu comprimento em função de sua angulação. Dessa forma, os pontos não precisam ser desconectados e reconectados a cada iteração. Como cada ponto só se move sobre cada raio, outra vantagem dessa técnica se dá pela impossibilidade de interseção entre os pontos, que acontece com certa frequência nos MCAs. O fato da energia externa ser calculada em 1D também produz vantagens no tocante à utilização de diversos filtros 1D para o seu cálculo (ALMEIDA *et al.*, 2012). Outra vantagem adicional dessa técnica é sua fácil implementação, dada a baixa complexidade das equações 2.14, 2.16, 2.17, 2.18 e à semelhança com as equações do MCA tradicional, já amplamente estudadas. Breier *et al.* (2011) ressalta, ainda, que *snakes* radiais não sofrem com o problema de agrupamento (clusterização) desnecessário de pontos, como está mostrado na Figura 16.

Assim como é feito na tradicional técnica 2D, cada parte que compõe o MCA Radial é uma área a ser explorada como, por exemplo, utilizar funções 1D como base de cálculo da energia externa, como acontece com a utilização da transformada de Hilbert por Alexandria *et al.* (2010). Trabalhos recentes trazem, inclusive, análises comparativas do desempenho de contornos ativos radiais na segmentação de imagens com e sem ruído (BESSA *et al.*, 2015). Já outros trabalhos modificam a estrutura do contorno para que possam se adequar a aplicações

Figura 16 – Problema de clusterização dos a) contornos ativos tradicionais e dos b) contornos ativos radiais.



Fonte: Breier *et al.* (2011).

específicas como é o caso da técnica chamada *pSnakes*, criada para atuar diretamente no feixe ultrassônico (ALEXANDRIA *et al.*, 2011; ALEXANDRIA *et al.*, 2014).

### 2.3.2 *pSnakes*

O método de contorno ativo radial *pSnakes* foi concebido inicialmente para aplicações específicas, envolvendo equipamentos de ultrassom, mas que pode ser embarcado no próprio equipamento. Isto se dá devido à característica da técnica em utilizar coordenadas polares  $(r, \theta)$  para os raios, tendo o ponto de origem dos raios coincidente com o ponto de divergência dos feixes ultrassônicos.

Essa técnica possui uma definição semelhante à apresentada na equação 2.13 com a principal diferença de que a curva possui dois pontos por vez para cada ângulo  $\theta$ , ao invés de apenas um, tal como definido (ALEXANDRIA *et al.*, 2011)

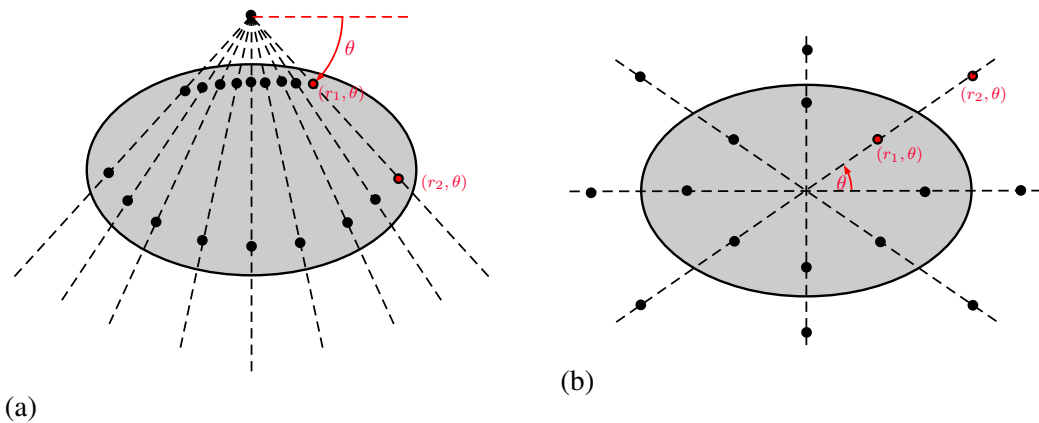
$$\begin{cases} [0, 1] \rightarrow \mathbb{R}^2 \\ c(s) = \{[r_1(s), \theta(s)]; [r_2(s), \theta(s)]\}, \end{cases} \quad (2.19)$$

em que  $(r_1)$  e  $(r_2)$  são os comprimentos dos raios partindo da origem em uma determinada angulação  $\theta$ . Cada ponto  $(r_1, \theta)$  e  $(r_2, \theta)$  é chamado de nó e faz parte dos pontos de controle da curva  $c$ . Cada par de ponto é denominado nó gêmeo.

O aspecto geométrico da técnica com 9 raios e 18 pontos de controle partindo de um local externo no topo do objeto de interesse é ilustrado na Figura 17a). Nessa configuração,

existe uma angulação mínima ( $\theta_{min}$ ) a máxima ( $\theta_{max}$ ) em que os raios são distribuídos. Nesse caso, os nós gêmeos tendem a se distanciar um do outro em direções opostas, de modo que um nó encontre a borda superior do objeto e o outro a borda inferior. Portanto, Alexandria *et al.* (2011) extrapolam a aplicação de feixes ultrassônicos para o caso em que  $\theta_{min} = 0$  e  $\theta_{max} = 2\pi$  e, assim, a técnica possa ser aplicada também em imagens em coordenadas cartesianas. A esta configuração foi dada o nome de *snakes radial dual* (Figura 17b)), na qual cada par de nós gêmeos tende a se aproximar um do outro contendo o contorno do objeto de interesse entre estes.

Figura 17 – exemplo de configuração de a) pSnakes e b) *snakes radial dual*.



Fonte: Adaptado de (BESSA *et al.*, 2015).

Outro diferencial desta técnica é que a quantidade de nós não é previamente definida. Isto é, existem critérios para adição e remoção de pontos à medida que a curva evolui. Em relação às energias, *pSnakes* é semelhante às outras técnicas radiais, contendo uma energia total composta de outras duas energias. A energia interna é dividida em duas forças e calculada de maneira semelhante à equação 2.17. Já a energia externa é calculada mediante Transformada de Hilbert (TH). Alexandria *et al.* (2011) perceberam que a TH possui características que a torna bastante eficiente quando utilizada como energia externa de contornos ativos radiais. A ideia é aplicar a TH 1D ao longo dos feixes radiais de modo que a energia externa é dada por (ALEXANDRIA *et al.*, 2010)

$$E_{ext}(r, \theta) = |\hat{f}(r)|. \quad (2.20)$$

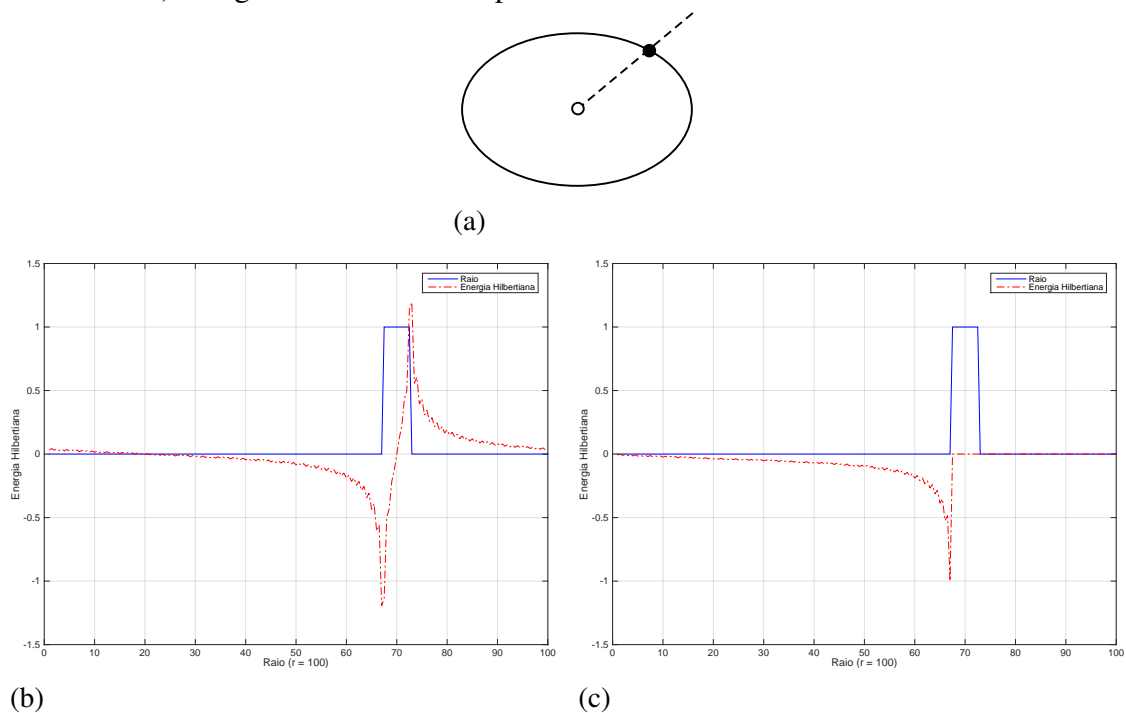
Como a TH pode obter valores positivos e negativos, dependendo se o ponto de divergência dos raios está interno ou externo ao objeto, as regiões de fora do contorno são

desprezadas e a energia externa é recalculada já normalizada por (ALEXANDRIA *et al.*, 2010)

$$E_{ext}(r, \theta) = \begin{cases} 1 - \frac{|\hat{f}(r)|}{\max(|\hat{f}(r)|)}, & \text{se } \hat{f}(r) < 0 \\ 0, & \text{caso contrário.} \end{cases} \quad (2.21)$$

Desta forma, a energia externa é definida simplesmente pelo valor absoluto da TH normalizada ao longo de um raio. A idéia dessa energia é criar um direcionamento dos nós para a borda do objeto como está ilustrado no gráfico da Figura 18b). Este gráfico representa a situação mostrada na Figura 18a) em que existe um raio de 100 *pixels* partindo de um ponto interno a um objeto sólido com uma borda de aproximadamente 5 *pixels*. Percebe-se que a TH cria uma suavização (em vermelho) que possibilita que o ponto de controle caminhe até o ponto de mínima energia que coincide com a borda de subida da TH e a borda do objeto. Ao normalizar a energia e descartar parte dela, tem-se a situação da Figura 18c) que é a energia hilbertiana definitiva.

Figura 18 – transformada de Hilbert ao longo de um a) feixe partindo de uma origem e ultrapassando a borda de um objeto; b) transformada de Hilbert sobreposta ao sinal do feixe e c) energia hilbertiana sobreposta ao sinal do feixe.




Fonte: Autor.

### 2.3.3 MCA Radiais 3D

O MCA Radial 3D, ou simplesmente *snake* Radial 3D, é uma nova técnica de segmentação de estruturas em três dimensões que amplia os conceitos apresentados nos Raios Ativos e é o objetivo principal desta tese. Essa abordagem, recentemente introduzida na literatura (ALMEIDA *et al.*, 2017), trata da segmentação de volumes (3D), a partir de da análise de informações 1D presentes nos raios que divergem de um ponto no centro do volume a ser segmentado, conforme ilustrado na Figura 19.

Figura 19 – representação dos Contornos Ativos Radiais 3D.



Fonte: Almeida *et al.* (2017).

A partir dessa Figura, observa-se que um raio  $\rho(\phi, \theta, \lambda)$  possui três parâmetros ao invés de dois (como ilustrado nos Raios Ativos da Figura 13). Esse terceiro parâmetro se trata de uma nova angulação que generaliza a técnica de Denzler e Niemann (1996), sendo  $\lambda$  o comprimento do raio,  $\phi$  o ângulo que varia em torno do eixo  $y$  (plano  $x - z$ ) e  $\theta$  o ângulo que varia sobre o plano  $x - y$  (em torno do eixo  $z$ ). Os ângulos  $\phi$  e  $\theta$  são análogos aos parâmetros de azimute e elevação em um sistema de coordenadas horizontal.

Formalmente, um raio 3D  $\rho(\phi, \theta, \lambda)$  pode ser definido em função de uma imagem em tons de cinza  $f$  como um feixe que parte de uma origem  $m$  até a extremidade da imagem, da forma

$$\rho(\phi, \theta, \lambda) = f[x_m + \lambda \text{sen}(\phi) \cos(\theta), y_m + \lambda \text{sen}(\phi) \text{sen}(\theta), z_m + \lambda \cos(\phi)]. \quad (2.22)$$

A maioria das técnicas envolvendo MCA 2D possuem uma dinâmica que pode ser resumida em quatro passos: 1) demarcação de contorno inicial próximo ao objeto; 2) cálculo de energias; 3) minimização de energia; e 4) atualização da posição dos pontos de controle da

curva. Grande parte das técnicas 3D também agem da mesma forma, mas ao invés de iniciarem a partir da definição de um contorno, estas iniciam com a delimitação de uma superfície em torno do objeto que é geralmente uma malha com pontos interligados entre si (JAOUEN *et al.*, 2013; REBOUCAS *et al.*, 2015).

Como dito anteriormente na seção 2.2.2, o tipo de malha adotado é fundamental para o correto funcionamento da técnica de segmentação, uma vez que a forma como os pontos estão conectados está intimamente ligada à forma como as energias são calculadas. Uma das grandes vantagens do MCA Radial 3D é reduzir a complexidade computacional e, por esse motivo, utiliza uma malha estruturada regular semelhante à malha da Figura 12a).

Diferente de outras metodologias radiais (ALEXANDRIA *et al.*, 2014; BESSA *et al.*, 2015), os *snakes* Radiais 3D não necessitam de funções de adição ou remoção de pontos durante a segmentação. Assim, a quantidade de pontos de controle é igual à quantidade de raios que é igual à quantidade de pontos na malha, pois só existe um ponto de controle por raio. Dessa maneira, a quantidade de raios é determinante para o refinamento da malha, nas quais as malhas com muitos pontos conseguem um maior detalhe na segmentação mas demandam um maior custo computacional. Contudo, isso é inerente a qualquer MCA 3D em que muitos pontos demandam muitos cálculos.

O conceito de energia é a principal característica dos MCAs 2D ou 3D e é o único aspecto comum a todas as técnicas e variações (ALMEIDA *et al.*, 2017). A energia dos *snakes* Radiais 3D atua em todos os pontos de controle da superfície, definidos sobre o raio  $\rho$ , de modo que a distância desse ponto a partir de uma origem  $m$  na angulação  $(\phi, \theta)$  pode ser descrita por

$$\rho(\phi, \theta) = \underset{\lambda}{\operatorname{argmin}} \left( - \left| \frac{\partial}{\partial \lambda} \rho(\phi, \theta, \lambda) \right|^2 \right). \quad (2.23)$$

A energia total da técnica é obtida a partir da generalização da equação 2.16, que é calculada em uma dimensão para cada raio na posição  $\rho(\phi, \theta, \lambda)$  de modo que

$$E = \int \int_0^{2\pi} \{E_{int}[\lambda(\phi, \theta)] + E_{ext}[\lambda(\phi, \theta)]\} d\phi d\theta, \quad (2.24)$$

em que os termos  $E_{int}$  e  $E_{ext}$  representam a energia interna e externa respectivamente.

A energia interna, responsável pela geometria da superfície, tende a eliminar pontos de inflexão tendendo a deixar a superfície contínua e suave. Essa energia é composta pelas

primeiras e segundas derivadas parciais chamadas de força de continuidade e de força de curvatura, respectivamente, sendo calculada, para  $\lambda = \lambda(\rho, \theta)$ , por

$$E_{int}(\lambda) = \int \int \left( \alpha_\phi \left| \frac{\partial \lambda}{\partial \phi} \right|^2 + \alpha_\theta \left| \frac{\partial \lambda}{\partial \theta} \right|^2 + \beta_\phi \left| \frac{\partial^2 \lambda}{\partial \phi^2} \right|^2 + \beta_\theta \left| \frac{\partial^2 \lambda}{\partial \theta^2} \right|^2 + \beta_{\phi\theta} \left| \frac{\partial^2 \lambda}{\partial \phi \partial \theta} \right|^2 \right) d\phi d\theta, \quad (2.25)$$

em que  $\alpha$  é o coeficiente de relevância associado à força de continuidade (derivada de primeira ordem) e  $\beta$  é o parâmetro de importância referente à força de curvatura (derivada de segunda ordem).

Já a energia externa permite que a superfície dos *snakes* Radiais 3D se adapte à vizinhança do objeto a ser segmentado. Esta energia é influenciada unicamente pelas informações contidas na imagem como na teoria dos MCAs. Por não possuir nenhuma informação da geometria da superfície, essa energia tende a estacionar em pontos mínimos locais, que podem ser bordas ou regiões ruidosas. O MCA Radial 3D proposto por Almeida *et al.* (2017) contém o operador gradiente como energia externa tradicional. Logo, para  $\lambda = \lambda(\rho, \theta)$ , essa energia é dada por

$$E_{ext}(\lambda) = -\gamma |\nabla f(\lambda)|^2, \quad (2.26)$$

em que  $\gamma$  representa o quão relevante devem ser as informações presentes na imagem, em detrimento das forças que envolvem a geometria da curva (compensadas pelos parâmetros  $\alpha$  e  $\beta$  descritos anteriormente).

## 2.4 Avaliação do Método

Existem basicamente duas grandes abordagens para se avaliar o resultado de uma segmentação. A primeira delas depende de uma avaliação qualitativa através de uma verificação visual por um especialista, capaz de identificar informações presentes ou ausentes na imagem, com base na sua experiência com aquele tipo de imagem e/ou estrutura segmentada. Esse tipo de avaliação é muito comum no âmbito médico, em que há uma constante análise visual de resultado de exames por médicos especialistas. Esta primeira maneira está sujeita a limitações inerentes à subjetividade e à variabilidade intra e interobservadores (REBOUÇAS FILHO, ).

Uma segunda maneira de se avaliar resultados de segmentações acontece por meio de uma análise quantitativa. Dependendo do que se deseja, esta não necessita de um profissional especializado para obtê-la e muitas vezes é realizada através de cálculos por computadores para quantificar diferenças e semelhanças entre a segmentação final e um padrão ouro, previamente definido. Essas diferenças e semelhanças são observadas mediante informações tais como medidas de intensidade de regiões, cálculo de momentos estatísticos, área, perímetro, dentre outras.

### 2.4.1 Medidas de Ajuste

As medidas de ajuste, chamadas de *Fit*, baseiam-se na relação de semelhança entre as regiões  $r_1, r_2, \dots, r_r$  de uma imagem de referência  $R$  e as regiões  $r_1, r_2, \dots, r_s$  da imagem segmentada  $S$ . Neste trabalho são empregadas três medidas de ajuste distintas, comumente utilizadas na literatura, quais sejam “Ajuste de Posição”, “Ajuste de Tamanho” e “Ajuste de Forma” (DELVES *et al.*, 1992; FÉLIX, ; REBOUÇAS FILHO, ; CAVALCANTE, ).

- **Ajuste de Posição** - o ajuste de posição para volumes 3D, chamado de  $Fit_{XYZ}$ , mede a exatidão do ajuste entre as imagens  $R$  e  $S$  através da diferença entre o centro geométrico de cada região e as médias dos eixos  $x$ ,  $y$  e  $z$  dos volumes, definida por

$$Fit_{XYZ} = 1 - \frac{x_d + y_d + z_d}{3}, \quad (2.27)$$

em que  $x_d, y_d$  e  $z_d$  são definidos por

$$x_d = \frac{|\bar{x}_R - \bar{x}_S|}{m}; \quad y_d = \frac{|\bar{y}_R - \bar{y}_S|}{n}; \quad z_d = \frac{|\bar{z}_R - \bar{z}_S|}{o}, \quad (2.28)$$

em que o trio ordenado  $(\bar{x}_R, \bar{y}_R, \bar{z}_R)$  denota a coordenada média, nos eixos  $x$ ,  $y$  e  $z$ , das regiões da imagem  $R$  e, de maneira análoga,  $(\bar{x}_S, \bar{y}_S, \bar{z}_S)$  indica a coordenada média das regiões da imagem  $S$ ; por fim,  $m, n$  e  $o$  representam as dimensões da imagem nos eixos  $x$ ,  $y$  e  $z$ , respectivamente.

- **Ajuste de Tamanho** - o ajuste de tamanho 3D, chamado de  $Fit_T$ , é definido como a razão da diferença entre os volumes de  $R$  e  $S$  e a soma das mesmas, dada por

$$Fit_T = 1 - \frac{|R - S|}{R + S}. \quad (2.29)$$



A partir dessa equação, observa-se que este valor varia entre 0 e 1 de modo que quanto mais próximo do valor 1, mais semelhantes são os volumes e quanto mais próximo do valor 0, maior a diferença entre as formas.

- **Ajuste de Forma** - o ajuste de forma 3D, chamado de  $Fit_F$ , é definido como a razão da interseção e união dos volumes de  $R$  e  $S$ , dada por

$$Fit_F = \frac{R \cap S}{R \cup S}, \quad (2.30)$$

que varia de 0 a 1, tendendo para o valor mais baixo quando da ausência de sobreposição entre as regiões  $R$  e  $S$  e para o valor 1 quando a sobreposição entre essas regiões é concordante.

#### 2.4.2 Coeficiente Dice

O Coeficiente de Similaridade *Dice*, conhecido como DSC - *Dice Similarity Coefficient*, é um índice de sobreposição espacial semelhante à Medida de Ajuste de Forma que é dado por (DICE, 1945)

$$DSC = \frac{2|R \cap S|}{|R| + |S|}, \quad (2.31)$$

em que os termos  $|R|$  e  $|S|$  representam a cardinalidade dos volumes  $R$  e  $S$ . Sendo assim, o coeficiente *Dice* duplica a importância da interseção das regiões, mas mantém seu valor entre 0 e 1. Sendo mais próximo de 0 à medida que as formas não coincidem e mais próximo do valor 1 quando há uma maior sobreposição das regiões em relação à quantidade de elementos nessas regiões.

#### 2.4.3 Desempenho computacional

A última medida de avaliação adotada nesta tese trata do cálculo do custo computacional da técnica proposta, em comparação a outras três técnicas conhecidas na literatura: Crescimento de Regiões 3D, MCA 3D e MCA Morfológico. Sendo a primeira delas uma técnica simples e largamente utilizada na literatura nas mais variadas aplicações. A segunda e a terceira são técnicas mais complexas de origem coincidente com a técnica proposta com a diferença da última se tratar de uma outra vertente de MCAs com a premissa de ser mais veloz.

O tempo de processamento é um aspecto importante desta tese, uma vez que sua principal contribuição é a redução do custo computacional quando comparada a outras técnicas que podem consumir até horas para processar um volume completo em três dimensões.

Neste Capítulo foi realizada uma breve revisão da literatura sobre segmentação de imagens e suas técnicas em duas e em três dimensões de forma ampla. Em seguida aprofundou-se em um assunto que está em constante ascensão na área que são os MCAs. Da mesma maneira foram detalhados os aspectos dos MCAs 2D e 3D. Após isso, foi apresentado um nicho relativamente novo dentro dos MCAs que são os MCAs radiais. Dentre as metodologias envolvendo MCAs radiais, foram detalhados Raios Ativos, a técnica *pSnakes* e MCA Radial 3D que é a técnica formalizada nesta tese e terá sua implementação detalhada no Capítulo seguinte. Por fim, foram detalhadas algumas formas utilizadas para quantificar e comparar o desempenho das técnicas utilizadas nesta tese.

### 3 METODOLOGIA

Neste Capítulo é descrita a metodologia necessária para implementar o Método de Contornos Ativos Radiais 3D baseada nos conceitos abordados no Capítulo 2. São detalhados os passos a serem seguidos e as funções necessárias para que a técnica possa ser reproduzida e adaptada para segmentar aplicações específicas. Ainda nesse Capítulo é descrita a metodologia de testes, bem como as métricas e os parâmetros utilizados na avaliação da técnica proposta. Vale ressaltar que todo o desenvolvimento da metodologia descrita nesta tese é implementado em C/C++ com o auxílio das bibliotecas Imebra, OpenGL e OpenCV para fins de visualização gráfica.


#### 3.1 MCA Radiais 3D

Conforme explicado no início da seção 2.3.3, o MCA Radial 3D é uma técnica proposta para segmentar volumes 3D, a partir dos conceitos dos Raios Ativos em que se analisam informações de maneira unidimensional ao longo de feixes ou raios. Estes feixes, por sua vez, partem do interior do objeto de interesse e se interligam de modo a formar uma superfície que tende a se moldar ao objeto de acordo com as informações obtidas ao longo do feixe.

##### 3.1.1 Inicialização

As cinco primeiras etapas para se inicializar o *snake* Radial 3D é mostrado na Figura 20. A primeira etapa acontece com a leitura do volume de entrada. Este volume é normalmente composto por diversas fatias de iguais dimensões que, quando combinadas, formam uma imagem 3D independente do tipo da imagem.

Figura 20 – etapas de inicialização da técnica MCAR3D.



Fonte: Autor.

Na segunda etapa são realizadas as configurações dos parâmetros necessários para


executar a técnica. Parâmetros como  $\phi$ ,  $\theta$  e  $\lambda$ , por exemplo, necessários para implementar a equação 2.22 que definem o comprimento e a angulação dos feixes ou, ainda, a quantidade de feixes partindo de um determinado ponto de origem também definida nesta etapa. Outros parâmetros como  $\alpha$ ,  $\beta$  e  $\gamma$  são definidos para controlar a influência de cada termo de energia interna ou externa conforme as equações 2.25 e 2.26. Os valores de cada um desses parâmetros são ajustados e adaptados de acordo com a aplicação específica e a complexidade da segmentação, uma vez que a quantidade de feixes, por exemplo, tende a definir o refinamento da malha e, por sua vez, a precisão da segmentação resultante. Por fim, são definidos os parâmetros gerais como o tipo de malha escolhido e o tipo de energia externa a ser utilizado.

As três últimas etapas, ilustradas na Figura 20, envolvem a criação da estrutura de dados da superfície ativa. A terceira etapa é responsável pela geração da malha de acordo com o tipo da malha e o refinamento definidos na etapa anterior. O tipo da malha está diretamente ligado à forma com que os pontos da superfície (chamados de *nós*) são conectados uns aos outros e a quantidade de vizinhos que cada nó deva ter. Nesta tese, são apresentadas dois tipos de malhas estruturadas: retangulares e triangulares.

As malhas retangulares são compostas por nós dispostos de forma semelhante a um globo terrestre onde há um ponto em cada polo e os demais distribuídos ao longo das interseções entre latitudes e longitudes. Nesta configuração, cada nó está ligado a outros quatro nós vizinhos com exceção dos nós dispostos nos polos. Os pontos são gerados conforme equação 2.22, no qual o ponto no polo superior (norte) é dado por  $\theta = 0$  e  $\phi = 0$  e o ponto no polo inferior (sul) é dado por  $\theta = \pi$  e  $\phi = \pi$ . Já os demais nós são gerados da seguinte maneira: para cada  $M$  linhas de latitude (horizontal) requerida, geram-se  $N$  nós de modo que  $N$  é a quantidade de linhas longitudinais (verticais). Logo, uma configuração com duas linhas horizontais (latitude  $M = 2$ ) e três linhas verticais (latitude  $N = 3$ ) produz uma malha com 6 pontos centrais e 2 polos, conforme ilustrado na Figura 21a). A Figura 21 ilustra outros exemplos de refinamento para malhas com 12, 32 e 112 nós.


Já a malha regular triangular apresentada nesta tese provém de um icosaedro que é um poliedro convexo de 20 faces triangulares e 12 vértices, no qual cada vértice está conectado a outros cinco vértices de modo equidistante. Essa malha é gerada a partir dos cantos de três planos ortogonais conforme mostra a Figura 22. Estes planos são chamados de retângulos de ouro devido à sua proporção áurea em que o lado menor mede 1 e o lado maior é dado por  $t = \frac{1+\sqrt{5}}{2}$  (SCHNEIDER; EBERLY, 2002).

Figura 21 – refinamento de malha estruturada retangular com a) 8 nós, b) 12 nós, c) 32 nós e d) 112 nós.



Fonte: Autor.

Figura 22 – icosaedro formado pelos vértices de três planos ortogonais.



Fonte: Wikipedia contributors (2018).


Logo, para se gerar um icosaedro é necessário que todos os pontos partindo do centro a qualquer vértice obedeam os valores citados de modo que os 12 vértices iniciais sejam  $v_0 = (t, 1, 0)$ ;  $v_1 = (-t, 1, 0)$ ;  $v_2 = (t, 1, 0)$ ;  $v_3 = (-t, -1, 0)$ ;  $v_4 = (1, 0, t)$ ;  $v_5 = (1, 0, -t)$ ;  $v_6 = (-1, 0, t)$ ;  $v_7 = (-1, 0, -t)$ ;  $v_8 = (0, t, 1)$ ;  $v_9 = (0, -t, 1)$ ;  $v_{10} = (0, t, -1)$  e  $v_{11} = (0, -t, -1)$ .

A partir desse poliedro inicial, pode-se refinar a malha ao subdividir os triângulos das faces adicionando novos pontos. Para isto, um novo nó é adicionado no ponto médio de cada aresta de cada face e cada face é subdividida em 3 novas faces, conforme ilustrado na Figura 23.

Nesse tipo de malha, a quantidade de pontos não é tão configurável quanto na malha retangular uma vez que a quantidade de pontos é fixa a cada subdivisão partindo de, no mínimo, 12 pontos e aumentando consideravelmente a quantidade dos nós adicionados a cada ciclo de refinamento. Uma subdivisão aumenta a quantidade de pontos de 12 para 42. Já com dois ciclos o número de pontos aumenta para 162. Após três ciclos já se tem 642 nós. Esses refinamentos, por adição de nós, são ilustrados na Figura 24 e influenciam diretamente na qualidade da segmentação e no tempo de processamento da técnica.


Ainda em relação ao diagrama da Figura 20, tem-se nas duas últimas etapas: a etapa

Figura 23 – subdivisão de faces para refinamento de malha.



Fonte: Autor.

Figura 24 – refinamento de malha estruturada triangular com a) 12 nós, b) 42 nós, c) 162 nós e d) 642 nós.




Fonte: Autor.

do disparo dos feixes e da conexão entre os mesmos. Cada feixe é uma estrutura de dados 1D capaz de armazenar os valores dos *voxels* em uma determinada posição, de modo que cada elemento dessa estrutura está conectado aos seus vizinhos. Para isso, é adaptado para 3D o algoritmo de Bresenham (1965). Este algoritmo já é amplamente conhecido e utilizado na literatura para desenhar linhas em dispositivos matriciais, a partir de coordenadas de origem e coordenadas de destino. Desta maneira, são criados os feixes partindo de uma origem definida pelo usuário na etapa #2 (Figura 20) em direção aos vértices da malha gerada anteriormente. Finalmente, os feixes são interconectados para se criar uma nova estrutura de superfície ativa que é, de fato, a que se molda de acordo com a segmentação. Essa estrutura contém apenas um nó por feixe e esses nós são interligados entre si no formato da malha triangular ou retangular. Contudo, a superfície ativa pode ser inicializada no exterior ou no interior do objeto de interesse de acordo com o tipo de energia adotado.

O MCAR3D proposto nesta tese, chamado de MCAR3D “tradicional”, possui a superfície ativa exterior ao objeto de interesse, pois, este deve contrair em direção ao objeto. Nesse caso, os pontos escolhidos em cada feixe estão mais próximos do final do feixe. Caso o MCAR3D seja adaptado para inflar ao invés de contrair, os pontos dos feixes devem estar

mais próximos do início do feixe. Nesse caso, propõe-se uma variação da técnica, chamada de MCAR3D “balão” em alusão à força balão introduzida na seção 2.2.1.1 que é detalhada posteriormente. Esses dois casos estão ilustrados na Figura 25 sendo a Figura 25a) a inicialização tradicional e a Figura 25b) a inicialização balão.

Figura 25 – inicialização das superfícies ativas do MCAR3D a) tradicional e b) balão.



Fonte: Autor.

### 3.1.2 Dinâmica do MCAR3D

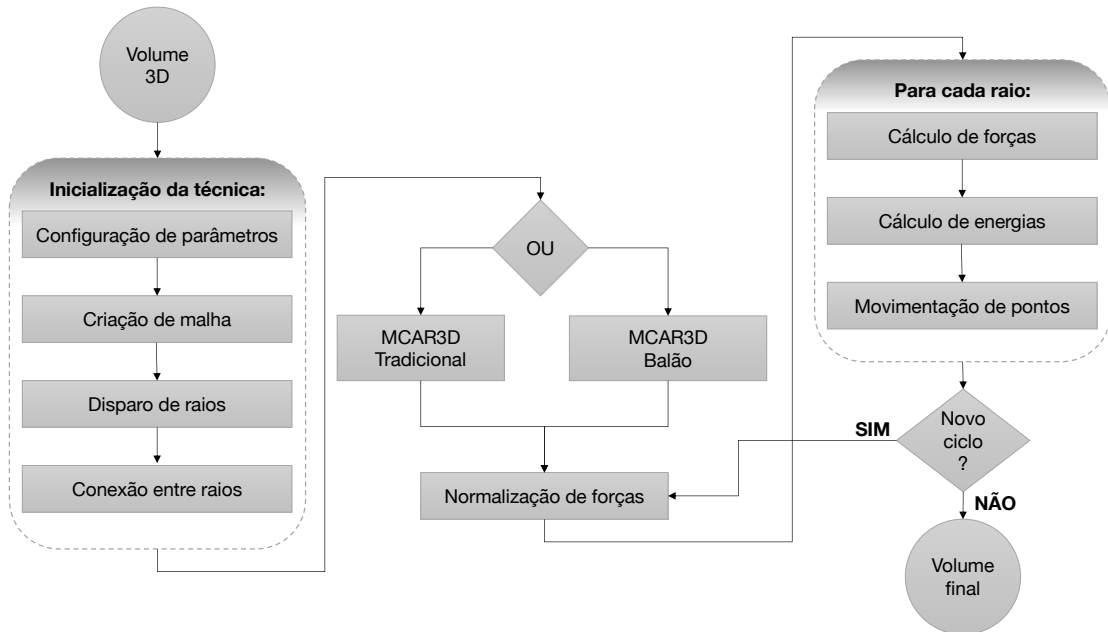
A dinâmica do MCAR3D pode ser resumida em duas grandes etapas após a leitura do volume 3D, sendo a primeira delas a etapa de configuração e a segunda a etapa de iteração. A primeira etapa é responsável pela definição dos parâmetros necessários à criação da malha e as estruturas envolvidas descritas anteriormente (raios, nós, etc.). Já a segunda etapa é um contínuo e repetitivo fluxo de minimização de energia que se inicia com a inicialização do método (interno ou externo ao objeto) descrito anteriormente.

Uma vez inicializado, o MCAR3D movimenta-se automaticamente após sucessivas iterações, buscando a menor energia em cada ponto ao fim de cada iteração. Esse processo é realizado em todos os raios e repetido até que um critério de parada seja atingido que pode ser estabelecido simplesmente por uma quantidade de iterações previamente determinada ou uma função de congelamento que identifica se um ponto está estável em uma determinada posição e não se move mais. Na Figura 26 é possível ver o fluxograma do processo de segmentação da técnica proposta.

### 3.1.3 Janela de busca

Uma das maiores contribuições da técnica proposta está relacionado à maneira como são escolhidos os possíveis *voxels* como pontos de controle da superfície ativa. Conforme

Figura 26 – fluxograma do processo de segmentação pelo MCAR3D.



Fonte: Autor.

explicado no Capítulo anterior, a dinâmica das técnicas baseadas em Contornos Ativos se dá pela minimização de uma função de energia dentro de uma janela de busca.

Grandes janelas de busca trazem uma maior quantidade de possíveis novas posições para os nós dos *snakes*. Assim, são feitos todos os cálculos necessários em todas as posições possíveis dentro da janela de busca. De maneira oposta, uma janela muito pequena não permite a superfície se movimentar, pois, não há para onde os nós se movimentarem. Essa etapa é computacionalmente custosa e, por muitas vezes, não produz uma mudança significativa na posição dos pontos de controle.

Em relação ao tamanho da janela de busca, tem-se as tradicionais técnicas 2D com um plano como janela de busca, conforme ilustrado na Figura 7, de tamanho  $n \times n$  pixels e  $n^2$  possíveis locais para movimentar o ponto de controle. Nas técnicas 3D tem-se um cubo ao invés de um plano com tamanho  $n \times n \times n$  voxels e  $n^3$  possíveis posições para os pontos em análise. Já as técnicas baseadas nos contornos ativos radiais possuem apenas um vetor como janela de busca, uma vez que um nó do *snake* só pode se movimentar sobre um raio (1D).

Dessa forma, a janela de busca proposta nessa tese se resume a procurar a menor energia nos *voxels* vizinhos a um nó de superfície de modo que uma janela de tamanho  $n$  permite analisar  $2n + 1$  posições. Uma janela de busca de tamanho igual a 6 elementos, por exemplo, é ilustrada na Figura 1b), mostrada no Capítulo 1. Dessa maneira, são analisados um total de 13



pontos sendo 12 vizinhos aos ponto central (6 para cada lado) e o próprio nó central.

### 3.1.4 Energia Interna

Conforme descrito na seção 2.3.3, o MCAR3D proposto nesta tese tende a minimizar uma função de energia dada pelo somatório de outras duas funções de energia: a energia interna e a energia externa. A energia interna desta técnica é responsável pela geometria da superfície, evitando que pontos isolados tendam a se distanciar muito ou se aproximar muito dos outros pontos se aproximando de um formato contínuo e suave.

A energia interna é composta por duas forças que dependem exclusivamente da geometria da superfície, uma vez que esta está diretamente ligada ao tipo de malha adotada. Essas forças ditam a movimentação de cada nó sobre os raios e sofrem influência direta dos nós nos raios vizinhos. A seguir é detalhada uma abordagem genérica para implementação dessas forças.

#### 3.1.4.1 Força de Continuidade

De acordo com o descrito na seção 2.2.1.1, a Força de Continuidade é responsável por controlar a capacidade elástica da superfície. Como a superfície nada mais é do que pontos interligados, a Força de Continuidade pode ser resumida como aquele termo que define se um ponto vai se aproximar ou se afastar dos demais de modo a mantê-los uniformemente espaçado.

Nos modelos tradicionais de MCA 3D, um ponto da superfície pode ocupar qualquer lugar no espaço, ao passo que no *snake* Radial 3D este ponto só pode se mover ao longo de um feixe 1D e isso é uma propriedade inerente da técnica proposta (ALMEIDA *et al.*, 2017).


Sendo assim, partindo-se da descrição de um nó no espaço 3D, em coordenadas polares  $[\phi(s), \theta(s), \lambda(s)]$  ou em coordenadas cartesianas  $[x(s, r), y(s, r), z(s, r)]$ , define-se a nova Força de Continuidade 3D ( $F_{\lambda(\phi, \theta)}^{cont}$ ) em função da distância  $d_i$  entre um nó da superfície e seu  $i$ -ésimo vizinho localizado no  $i$ -ésimo raio como

$$F_{\lambda(\phi, \theta)}^{cont} = \frac{1}{N} \sum_{i=1}^N (d_i - d_{\mu})^2, \quad (3.1)$$

em que  $d_{\mu}$  é a distância média entre um nó e seus  $N$  pontos vizinhos. Assim, a Força de Continuidade é definida como a variância das distâncias entre um ponto da superfície e seus vizinhos. Quanto maior o valor da variância, maior a Força de Continuidade que deve ser

minimizada. A influência desta força está ilustrada na Figura 27, onde se observa um recorte de uma superfície formada por oito pontos de controle. Na Figura 27a) existem nós cujas distâncias para seus vizinhos divergem da distância média entre todos os vizinhos. Estes nós tendem a se afastarem ou a se aproximarem ao longo de seus raios (linha tracejada) de modo a equilibrar a distância de seus vizinhos e, por sua vez, manter a superfície contínua e igualmente espaçada (Figura 27b)).

Figura 27 – influência da Força de Continuidade, a) antes da força atual e b) depois da atuação da força.



Fonte: Autor.

### 3.1.4.2 Força de Curvatura

A Força de Curvatura, definida pela de segunda ordem da equação 2.25, está associada aos pontos de inflexão da superfície, gerados dos pontos de controle que desviam do plano. Tradicionalmente, essa força se baseia nos ângulos internos desses pontos de modo a maximizá-los, buscando suavizar a superfície o máximo possível.

Durante a etapa de cálculos para minimização da energia interna, o *snake* tende a perder curvatura, minimizando a área de sua superfície. Essa Força de Curvatura ( $F_{\lambda(\phi, \theta)}^{curv}$ ) é proposta em função da média das coordenadas de seus vizinhos como a norma de um raio  $\rho(\phi, \theta, \lambda)$ , definida por


$$F_{\lambda(\phi, \theta)}^{curv} = \|\rho\| = \sqrt{(x - x_{\mu})^2 + (y - y_{\mu})^2 + (z - z_{\mu})^2}, \quad (3.2)$$

em que  $(x, y, z)$  são as coordenadas cartesianas de um nó 3D e  $(x_{\mu}, y_{\mu}, z_{\mu})$  é a coordenada cartesiana do ponto médio calculado pela média das coordenadas dos nós vizinhos. Sugere-se

o uso das coordenadas cartesianas, visando a simplificação dos cálculos, uma vez que calcular  $x = \lambda \text{sen}(\phi) \cos(\theta)$ ,  $y = \lambda \text{sen}(\phi) \text{sen}(\theta)$  e  $z = \lambda \cos(\phi)$  é mais complexo.

Com isso, o ponto médio gerado pelas coordenadas dos pontos vizinhos forma uma projeção do nó em questão no plano médio determinado pelos vizinhos. Um exemplo da aplicação dessa força está ilustrado na Figura 28, onde na Figura 28a) observa-se um nó mais afastado do que os demais. À medida que a técnica evolui, o nó mais afastado tende a ir de encontro ao plano definido pelos seus nós vizinhos, como está ilustrado na Figura 28b), mas sempre se movendo em uma dimensão ao longo do feixe  $\rho$ . Desta maneira, evita-se que a superfície estacione em mínimos locais tais como pontos ruidosos.

Figura 28 – influência da Força de Curvatura, a) antes da força atual e b) depois da atuação da força.



Fonte: Autor.

### 3.1.4.3 Força Balão

São propostas duas metodologias de inicialização para a técnica MCAR3D, conforme indicado na Figura 25, sendo uma delas externa ao objeto de interesse e a outra interna. O tipo de inicialização define o tipo de *snake* que pode ser o MCAR3D Tradicional (externa) ou o MCAR3D Balão (interna).

O MCAR3D Tradicional é composto pelas duas forças detalhadas anteriormente, de modo que o *snake* tende a se fechar em torno do objeto de interesse. Esse comportamento acontece devido ao efeito da Força de Curvatura, que tende a maximizar os ângulos internos à superfície e faz com que os pontos se movam para o centro dos raios.

Já o MCAR3D Balão não considera a Força de Curvatura, uma vez que este é inicializado interno ao objeto de interesse e deve expandir para as bordas, ao invés de contrair.


Para tal, é proposta uma força que funciona como uma pressão interna à superfície que a empurra para fora. Essa força, denominada de Força Balão, é dada em função do raio de cada nó da superfície do *snake* e o tamanho da janela de busca.

Sabe-se que uma janela de busca de tamanho  $n$  permite uma análise de  $2n + 1$  *voxels*. A nova Força Balão atua no intervalo da janela de busca, de forma que o valor da força diminua à medida que os pontos se distanciem do início do raio. Uma maneira de implementar sua formulação normalizada entre 0 e 1 é dado por

$$F_i^{bal} = 1 - \frac{i}{2n}, \quad (3.3)$$

em que  $n$  é o tamanho da região de busca e  $i$  é o índice do ponto dentro da região de busca. Em uma região com  $n = 4$ , por exemplo, o índice  $i$  dos nós varia de 0 a 8 e possui os valores calculados conforme está ilustrado na Figura 29. Verifica-se que essa força sempre tende a conduzir os pontos para o fim do raio ( $F_i^{bal} = 0$ ), independente de nós vizinhos ou de informações na imagem. O que evita o ponto de sempre se mover para o último nó, a cada iteração, é a ponderação dessa força somada à força de continuidade com os cálculos provenientes da energia externa descrita a seguir. Por esse motivo, é de fundamental importância que todas as forças e energias estejam normalizadas no mesmo intervalo para que nenhuma se sobreponha à outra.

Figura 29 – exemplo de aplicação da Força Balão sobre um raio.



Fonte: Autor.

### 3.1.5 Energia Externa

Conforme descrito na seção 2.2.1.2, a energia externa é aquela que independe da geometria da superfície, pois, é influenciada exclusivamente por informações presentes na imagem através dos níveis dos tons dos *voxels*. Essa energia é responsável por fazer com que o *snake* não entre em colapso ao se contrair sobre si mesmo ou que expanda e extrapole os limites da imagem.

É a energia externa que guia o *snake* para as bordas do objeto de interesse através de cálculos e transformações sobre as posições dos *voxels* das imagens. Esses cálculos tendem a ser custosos computacionalmente, a depender do tamanho da janela de busca e do tipo de energia externa adotada.

Os *snakes* radiais foram criados visando diminuir a complexidade computacional dos Métodos dos Contornos Ativos convencionais e suas energias envolvidas. No tocante à energia externa, essas técnicas possuem a vantagem de realizar os cálculos e transformações de imagens em uma única dimensão.

Neste sentido, a presente tese sugere de metodologias para serem utilizadas como energia externa dos MCAR3D que podem ser modificadas ou adaptadas, dependendo do tipo da aplicação e das características da estrutura que se deseja segmentar.

#### 3.1.5.1 Força Gradiente

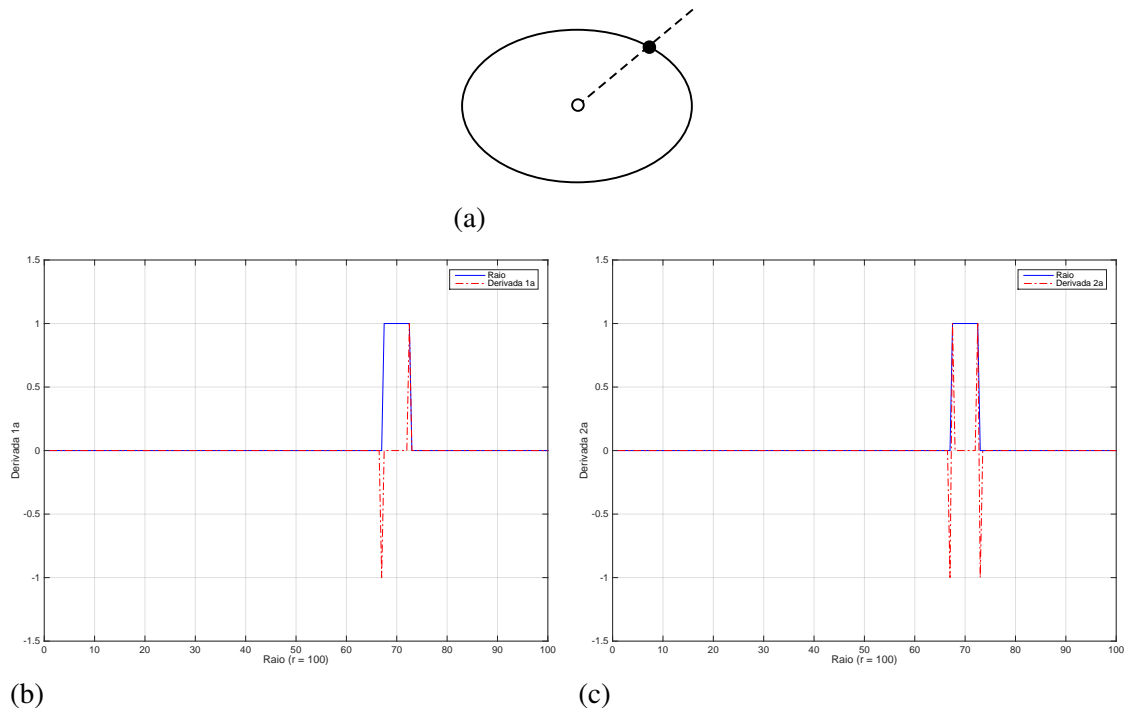
Os operadores derivativos funcionam como simples detectores de bordas que podem direcionar os pontos da superfície do *snake* para o local de menor energia, em função dos tons da imagem. Isto ocorre através das funções unidimensionais derivativas de primeira ou segunda ordem discretizadas por

$$\frac{\partial f}{\partial x} = f(x+1) - f(x). \quad (3.4)$$

$$\frac{\partial^2 f}{\partial x^2} = f(x+1) - f(x-1) - 2f(x). \quad (3.5)$$

Dessa maneira, o valor da derivada é sempre zero em áreas de intensidade constante e não-zero em regiões de mudanças abruptas, que caracterizam regiões de bordas. Na Figura 30 é representado o comportamento das equações anteriores ao longo de feixe de 100 *pixels*, partindo de um ponto interno a um objeto sólido (intensidade constante) e uma borda de aproximadamente 5 *pixels*. Constata-se que ambas as derivadas detectam as regiões de borda do objeto, analisando apenas informações ao longo do feixe. Porém, essa metodologia se mostra ineficiente, uma vez que a derivada de primeira ordem detecta a borda positiva com um vale e a borda negativa com um pico, enquanto a derivada de segunda ordem produz vales e picos para ambas as bordas. Assim, é impossível generalizar a busca pela minimização de energia em ambos os casos.

Figura 30 – derivada ao longo de um a) feixe partindo de uma origem e ultrapassando a borda de um objeto; b) derivada de primeira ordem; e c) derivada de segunda ordem.



Fonte: Autor.

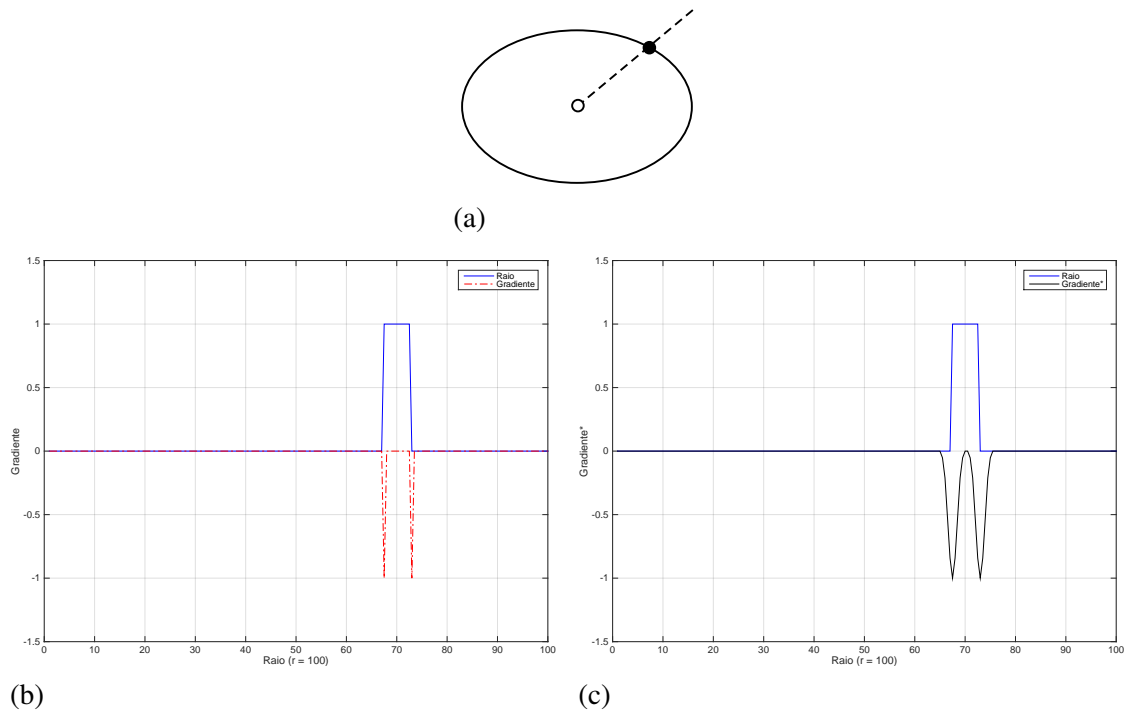
Visando superar a limitação mencionada anteriormente, é comum a utilização de operadores de gradiente tais como o operador Sobel como detector de bordas. Para tal, este é implementado mediante equação (GONZALEZ; WOODS, 2008)

$$\nabla f = 2f(x-1) + 2f(x+1). \quad (3.6)$$

Dessa forma, eliminam-se os picos do sinal após transformação, restando apenas um valor não-zero nas regiões de borda, conforme ilustrado na Figura 31, pois, este é considerado um filtro passa-altas. Logo, os pontos de controle do MCAR3D conseguem estacionar no ponto de menor energia que ocorre justamente sobre a borda do objeto de interesse.

A partir desse modelo de energia externa, é possível incrementá-la para facilitar a convergência para o ponto de menor energia através da adição de novas funções ou substituição, conforme outras sugestões de energia externa. A adição de um filtro passa-baixas normalizado, por exemplo, suaviza a reta de impulso do gradiente até o mínimo global do sinal, conforme ilustrado na Figura 31c). Neste caso, há uma redução gradual no valor da energia naturalmente e isto, por si só, direciona os nós do MCAR3D para o local de menor energia.

Figura 31 – operador Gradiente ao longo de um a) feixe partindo de uma origem e ultrapassando a borda de um objeto; b) operador Sobel e c) operador Sobel superposto ao filtro passa-baixas.



Fonte: Autor.

### 3.2 Avaliação do Método

Visando testar a capacidade da técnica proposta como uma nova metodologia para segmentar volumes, são aplicados testes com a técnica implementada em C/C++ com o auxílio das bibliotecas IMEBRA, OpenCV e OpenGL. Para tanto, são implementadas funções de processamento e visualização 3D para leitura de volumes e apresentação do resultado da segmentação.

Para isso, são criadas 5 formas geométricas sintéticas 3D distintas para servir como objeto de interesse para a segmentação. Posteriormente, a técnica proposta é aplicada em imagens de TC visando a segmentação dos pulmões como prova de conceito da sua utilização. Ao final, implementam-se, ainda, técnicas conhecidas na literatura para se ter um parâmetro real entre resultado esperado e custo computacional quanto às medidas de ajuste explicadas no Capítulo anterior e desempenho computacional.

A metodologia de testes se divide em duas partes. A primeira parte se dá pela aplicação da técnica proposta em duas configurações (malha retangular e malha triangular) comparado com a técnica de MCA 3D nos volumes sintéticos. Essas três abordagens são comparadas juntas, pois, fazem parte dos MCAs explícitos, nos quais se pode variar a quantidade

de pontos igualmente. Dessa maneira, cada técnica é executada 100 vezes em cada um dos cinco volumes sintéticos com uma quantidade específica de pontos que são 12, 36, 156, 625 e 2500 pontos para o tipo de malha retangular e 12, 42, 162, 642 e 2565 pontos para o tipo de malha triangular.

A segunda parte dos testes de desempenho decorre da aplicação da técnica proposta também em duas configurações (malha retangular e malha triangular) com aproximadamente 2500 pontos (definidos empiricamente) aplicadas nos exames reais visando a segmentação dos pulmões. O MCAR 3D é comparado com a técnica de Crescimento de Regiões 3D e a técnica MCA Morfológico 3D. Cada segmentação é realizada 100 vezes para o cálculo do tempo médio por exame.




## 4 RESULTADOS

Neste Capítulo são apresentados os resultados da segmentação em volumes sintéticos e volumes reais. A técnica proposta é avaliada com duas configurações de malhas (retangular e triangular) em conjunto a outras técnicas descritas nos capítulos anteriores que são o MCA 3D, MCA Morfológico e a técnica de Crescimento de Regiões 3D (CR 3D).

As técnicas são comparadas quanto às medidas de ajuste, coeficiente *dice* e, por fim, desempenho computacional. Os testes realizados em volumes sintéticos buscam verificar o comportamento das forças internas em diferentes tipos de formatos e detalhes. Já os testes em exames reais de TC são utilizados como prova de conceito da técnica, visando a comparação de desempenho com outras técnicas generalistas, que também não possuem o objetivo específico de segmentar pulmões.

Um dos objetivos específicos deste trabalho é desenvolver um visualizador da dinâmica da segmentação 3D em tempo real para se verificar o comportamento da mesma. Na Figura 33 são ilustradas as malhas iniciais (em azul) geradas com 12, 36, 156, 625 e 2500 raios (em cinza).


Figura 32 – malha inicial (em azul) do MCAR3D com 12 (a), 36 (b), 156 (c), 625 (d) e 2500 (e) raios (em cinza).



Fonte: Autor.

O visualizador implementado possui algumas opções de configuração que ajudam a visualizar detalhes da segmentação. Além de poder rotacionar, aumentar e diminuir o objeto enquanto se está segmentando, é possível isolar apenas a malha final (Figura 33a)), a malha em conjunto com os raios (Figura 33b)) que facilita para se ter uma ideia do tamanho do objeto, apenas os pontos de controle (Figura 33c)) ou, ainda, a malha e os pontos sem os raios (Figura 33d)).

Figura 33 – possíveis configurações de visualização da segmentação final sendo a) a malha final, b) a malha e os raios, c) os pontos de controle e os raios e d) a malha e os pontos de controle.



Fonte: Autor.

#### 4.1 Testes em Volumes Sintéticos


Conforme explicado em capítulos anteriores, a energia externa é influenciada exclusivamente por informações presentes nas imagens. Dentre as energias, esta é, sem dúvida, a mais importante, pois, define o local de parada do *snake*. Sem esta energia, a superfície se movimenta unicamente mediante forças internas de modo a expandir ou se contrair. Visando isolar a influência de forças externas para analisar o comportamento das forças internas, em estruturas com diferentes formatos, são realizados testes em volumes sintéticos.

Para isso, são criadas cinco formas geométricas 3D com formatos diversificados visando englobar características como cantos pontiagudos, cantos arredondados, regiões curvas, regiões planas. As cinco formas geométricas estão ilustradas na Figura 34 em que 34a é um cilindro com raio de base igual a 50 *voxels* e altura igual a 160 *voxels*, 34b é um forma cônica com raio de base e altura iguais a 100 *voxels*, 34c é um cubo de lado igual a 100 *voxels*, 34d tem um formato piramidal com base quadrada 200 × 200 *voxels* e altura igual a 100 *voxels* e, por fim, 34e é uma esfera de raio 50 *voxels*.

Cada forma geométrica é gerada em um espaço 3D cúbico com dimensões iguais a 300 × 300 × 300 *voxels*, definidas arbitrariamente. Antes de gerar cada volume, este espaço é configurado com valor 1 para todos os *voxels* e em seguida a forma é preenchida nesse espaço com valor 0, criando assim uma forma sólida imersa em um espaço 3D cúbico.

A ideia de se utilizar essas formas geométricas é analisar a convergência dos pontos de acordo com as malhas da técnica proposta nas suas duas metodologias MCAR3D Tradicional e MCAR3D Balão. Na primeira delas a superfície é inicializada no exterior da forma geométrica e na segunda é inicializada no interior da mesma. Como o volume 3D é uma imagem 3D binária,

Figura 34 – exemplo de formas geométricas 3D utilizadas nos testes sintéticos, a) cilindro; b) cone; c) cubo; d) pirâmide; e e) esfera.



Fonte: Autor.

a influência de forças externas é mínima. Sendo assim, pode-se avaliar o comportamento do *snake* mediante atuação unicamente das forças internas na mais variadas formas.

As técnicas comparadas entre si são a MCAR 3D, proposta nesta tese, em duas configurações e a técnica MCA 3D tradicional, gerando três metodologias diferentes. Essas duas técnicas são comparadas quanto à evolução da quantidade de pontos de cada superfície ativa, porque esses MCAs fazem parte de um conjunto maior de MCA paramétrico composto de curvas explícitas formadas por pontos de controle. Já a técnica MCA Morfológico não é comparada em volumes sintéticos, pois, este é um MCA geométrico composto por curvas explícitas, conforme explicado nos capítulos anteriores, e, por isso, não possui pontos de controle. Já a técnica de CR 3D não é avaliada nos volumes sintéticos, pois, esta não considera a geometria da forma e sim a intensidade dos *voxels*.

#### 4.1.1 Medidas de Ajuste

Em cada volume sintético são comparados os três métodos com cinco diferentes quantidades de pontos de controle: 2, 36, 156, 625 e 2500 pontos para o tipo de malha retangular e 12, 42, 162, 642 e 2565 pontos para o tipo de malha triangular. Visando facilitar o entendimento, a quantidade de pontos considerada é de 12, 36, 156, 625 e 2500 pontos aproximadamente.

As três abordagens são inicializadas internas aos objetos de modo que sejam utilizadas apenas as forças de Continuidade e força Balão como energia interna. Ao final, é gerado um total de 5 resultados para cada técnica em cada volume sintético, totalizando 75 novos volumes apresentados no Apêndice A para melhor visualização. Esses resultados são agrupados nas quatro métricas avaliativas totalizando 300 resultados dispostos numericamente em detalhes no Apêndice B.

O valor da medida de ajuste de posição  $Fit_{XYZ}$  é muito próximo a 100% entre as técnicas, verificando-se que nenhuma delas foge do centro geométrico do objeto de segmentação. Esse comportamento é observado em todas as formas geométricas independente da quantidade de pontos. Os gráficos referentes aos resultados divididos por forma geométrica estão ilustrados no Apêndice C.

#### 4.1.1.1 Cilindro

O formato cilíndrico possui como características duas regiões planas e circulares nas bases. A primeira segmentação resultante possui apenas 12 pontos de controle. Os resultados estão mostrados na Figura 46 em que há um gráfico resumindo os resultados das medidas comparativas entre as técnicas MCAR 3D (RET/TRI) e MCA 3D, respectivamente nas cores vermelha, verde e azul na Figura 46a). As medidas obedecem o mesmo padrão com 12 pontos: o MCA 3D é o que possui o tamanho e forma mais próxima do volume original com resultados de DSC em torno de 80%, seguido da malha triangular com 78% e a malha retangular com 67%. Ao analisar o resultado visual da segmentação através da Figura 41, percebe-se que o porquê desse comportamento, uma vez que o MCA 3D pode se distribuir por qualquer ponto do espaço, enquanto o MCAR 3D se limita a estar sobre os raios e tende a ter regiões pontiagudas na sua segmentação.

Com um aumento de 12 para 36 pontos, a malha triangular é a que tem maior destaque quanto à forma e tamanho com resultados acima de 90%. Visualmente, observa-se o início de uma convergência entre as formas do MCAR 3D para a forma cilíndrica. Já com 156 pontos, o MCA 3D produz os piores valores para segmentação, tendo a malha retangular um melhor resultado quanto ao tamanho e a malha triangular quanto à forma.

O comportamento do resultado com 625 pontos reflete a melhora da segmentação pela malha retangular seguida da malha triangular e, por fim, o MCA 3D. Vê-se que, a partir desse número de pontos, o resultado do MCAR 3D tem pouca variação entre as malhas e isso é

comprovado visualmente pela segmentação na Figura 41.

Finalmente, com 2500 pontos de controle, vê-se todos os resultados acima de 92% correspondentes com o volume padrão. De acordo com o gráfico da Figura 46e), o MCA 3D possui as piores taxas, exceto pelo ajuste de tamanho. Logo, esta técnica produz um resultado melhor com mais pontos, mas apesar do tamanho semelhante ao original, a sua forma não se sobrepõe tão fielmente ao volume de referência.

#### 4.1.1.2 *Cone*

O formato cônico possui uma base circular semelhante ao formato cilíndrico em um dos lados, mas possui um canto pontiagudo no outro. Com apenas 12 pontos ainda não se vê nenhum resultado semelhante a um cone, conforme visto na Figura 42. Nesta configuração de poucos pontos, o MCA 3D traz novamente os melhores resultados quanto a forma, tamanho e sobreposição.

Com 36 pontos o MCAR 3D possui uma melhora significativa com sobreposições acima de 80%, conforme mostra Figura 47b), enquanto o MCA 3D ainda possui um melhor resultado com valores acima de 90%. Aparentemente há uma convergência mais rápida para o canto pontiagudo do cone no MCA 3D, devido à sua capacidade de se locomover por todo o espaço e este melhor resultado é demonstrado visualmente na Figura 42i).

Com o aumento de pontos para 156, há uma melhora na técnica MCAR 3D que pode ser verificada visualmente, onde os resultados mostrados na Figura 42 se assemelham muito a um cone. Já a técnica MCA 3D não apresenta melhora significativa com o aumento dos pontos de controle para esse tipo de formato.

Após o acréscimo de mais pontos de controle, verifica-se uma tendência onde as três técnicas possuem praticamente os mesmos valores para as quatro medidas avaliadas, ainda que se possa constatar visualmente que com 2500 pontos produzem-se formatos mais próximos do formato cônico de referência. Visualmente observa-se também que a malha retangular da técnica MCAR 3D é a que melhor consegue discretizar a região circular do cone.

#### 4.1.1.3 *Cubo*

O cubo é uma das formas mais simples entre os volumes sintéticos, já que possui apenas regiões planas quadradas e cantos pontiagudos simetricamente distribuídos. Como já é de se esperar, o MCA 3D produz os melhores resultados com menos pontos de controle.

Resultados com 99% de correspondência, em relação ao tamanho da segmentação com o MCA 3D, contra aproximadamente apenas 70% da técnica MCAR 3D são demonstrados visualmente com as formas da Figura 43. Esse mesmo comportamento se repete com 36 pontos (Figura 48e)), provando que são necessários mais pontos para que a técnica MCAR 3D alcance os cantos pontiagudos do cubo.

Com aproximadamente 156 pontos, já se percebe uma convergência no resultado da segmentação das três técnicas (vide Figura 43). Nestes resultados, vê-se que as regiões planas representadas pelos lados do cubo são visíveis e perfeitamente segmentadas enquanto os vértices do cubo ainda precisam de um maior refinamento das malhas do MCAR 3D.

Ao aumentar a quantidade de pontos para aproximadamente 625, há uma inversão na técnica de destaque. Apesar de resultarem em uma segmentação visualmente muito semelhante (Figuras 43d, 43i e 43n), o MCAR 3D tem uma vantagem quanto ao ajuste de forma e DSC. Já os resultados apresentados com 2500 pontos não produzem muitas diferenças em relação aos resultados com 625 pontos. Vê-se, com a comparação dos gráficos das Figuras 48d e 48e, que estes são bem semelhantes com diferenças da ordem de 1% em relação à técnica MCAR 3D, que continua evoluindo enquanto não há nenhuma variação da técnica MCA 3D estagnada nos mesmos resultados com 625 pontos.

#### 4.1.1.4 *Esfera*

Diferentemente dos formatos anteriores, a esfera não possui lados, nem cantos e nem regiões planas. Enquanto o MCA 3D obtém os melhores resultados com uma menor quantidade de pontos nos testes anteriores, nesta forma o MCAR 3D gera os melhores resultados, independente da quantidade de pontos conforme vistos nos gráficos da Figura 49. A evolução da segmentação do MCAR 3D é visível na Figura 44 com a convergência para o formato perfeitamente esférico, enquanto os resultados do MCA 3D avançam para uma formato esférico mas longe do ideal com resultados em torno de 88%, em relação à forma. Isso é explicado pelo fato do MCA 3D naturalmente convergir para os cantos dos volumes (inexistentes no formato esférico).

#### 4.1.1.5 *Pirâmide*

O formato piramidal é semelhante ao formato cônico com excessão da base quadrada. Conforme visto nos resultados anteriores, o MCA 3D tende a ser mais eficiente em formatos

simples com cantos bem definidos, que é o caso de uma pirâmide. Esse comportamento se repete, pois, apenas com 12 pontos o MCA 3D já atinge 97% de correspondência com a forma do objeto de referência contra 56% do MCAR 3D (TRI) e apenas 42% do MCAR (RET).

Um aumento para 36 pontos não influencia nos resultados do MCA 3D, mas aumenta para cerca de 90% os resultados da técnica MCAR 3D. Observa-se, na Figura 50, que os gráficos relacionados ao MCA 3D possuem um comportamento semelhante, independente da quantidade de pontos. Isto é verificado ao se observar os resultados da segmentação na Figura 45. Como a pirâmide em questão só possui 5 vértices, isto facilita a convergência no MCA 3D com poucos pontos. Entretanto, não há como possuir um ganho significativo do resultado ao aumentar a quantidade de pontos.

#### 4.1.2 *Custo Computacional*

As técnicas são desenvolvidas e executadas em um mesmo ambiente descrito por um Macbook Pro (Mid 2012) composto por um processador Intel Core I5 2,5 GHz, com 8 GB de memória RAM. A linguagem de programação empregada na implementação das técnicas foi C/C++ adicionado das bibliotecas Imebra, OpenCV e OpenGL para carregamento e visualização de imagens.

Cada configuração de técnica e quantidade de pontos é comparada no aspecto do custo computacional para os volumes sintéticos. Para isso, cada técnica é executada repetidas vezes em cada volume com uma determinada quantidade de pontos, para se gerar o tempo médio de segmentação por volume. Estes testes produzem um total de 75 resultados referente a tempo médio. Como os volumes possuem dimensões semelhantes e obtêm tempos de segmentação semelhantes, é utilizada a média dos tempos médios dos volumes. Dessa forma, está sumarizado na Tabela 2 o tempo médio (após 100 execuções) entre todos os volumes sintéticos com 12, 36, 156, 625 e 2500 pontos de controle nas técnicas MCAR 3D (RET/TRI) e MCA 3D.

Tabela 2 – tempo de processamento para as técnicas MCAR 3D (malha retangular e triangular) e MCA 3D variando a quantidade de pontos entre 12 e 2500 pontos.

Método	Tempo médio de processamento (s)				
	12 pts	36 pts	156 pts	625 pts	2500 pts
MCAR 3D (malha RET)	1,27	1,29	1,37	1,66	4,03
MCAR 3D (malha TRI)	1,38	1,39	1,45	1,91	4,76
MCA 3D	1,04	1,35	2,46	6,36	22,48


Fonte: Autor.

O gráfico da Figura 35 ilustra os dados da Tabela 2 para facilitar o entendimento de como o aumento da quantidade de pontos afeta o tempo necessário para realizar uma segmentação. É possível ver que, com 12 pontos, as três técnicas segmentam os volumes em pouco mais de 1 segundo, tendo o MCA 3D como o mais rápido com 1,04s seguido pelo MCAR 3D (RET) com 1,27 s. Ao aumentar para 36 pontos, o tempo do MCAR 3D (RET) aumenta 0,02 s enquanto o MCAR 3D (TRI) aumenta 0,01 s e o MCA 3D aumenta 0,31 s.

Analisando o resultado após testes com 625 pontos, vê-se uma curva crescente em relação ao custo computacional do MCA 3D. Enquanto o MCAR 3D consome menos de 2 s para segmentar os volumes, o MCA 3D gasta mais de 6s para executá-lo. Na última configuração, já com 2500 pontos, o MCAR 3D (RET) gasta cerca de 4 s para segmentar os volumes, enquanto o MCA 3D consome mais de cinco vezes esse tempo para fazê-lo.

Ao confrontar esse resultado com a qualidade da segmentação através das medidas de avaliação expostas anteriormente, verifica-se que o MCA 3D não produz os melhores resultados quanto à forma, ao tamanho e ao DSC e apresenta um maior custo computacional para ser executado.

Figura 35 – variação do tempo médio de processamento (s) através do aumento da quantidade de pontos dos métodos MCAR 3D e MCA 3D.



Fonte: Autor.

## 4.2 Testes em Volume Reais

A segunda etapa dos testes trata da aplicação da técnica proposta em imagens de estruturas reais advindas de exames de Tomografia Computadorizada (TC) do tórax obtidos da base de dados *Lung Image Database Consortium Image Collection* (LIDC-IDRI) (ARMATO *et*




al., 2011). Esta base consiste de um grande arquivo contendo vários exames de TC de tórax com diagnóstico de câncer de pulmão muito utilizado na literatura para validar algoritmos e técnicas de segmentação de nódulos pulmonares.

O objetivo final dos testes nos volumes reais não é segmentar as estruturas pulmonares, uma vez que a técnica proposta não possui um direcionamento para esta finalidade e há, na literatura, uma quantidade enorme de técnicas para tal. O objetivo é verificar se o MCAR3D consegue segmentar estruturas sem padrão definido como, por exemplo, os pulmões de modo que a técnica possa ser utilizada em diversas aplicações diferentes. Entretanto, nada impede que haja um estudo sobre novas energias externas direcionadas para segmentar esse tipo de volume através da técnica proposta.

São selecionados aleatoriamente 5 exames da base de dados LIDC-IDRI em formato DICOM<sup>1</sup>. A visualização dessas imagens é possível através da utilização da biblioteca Imebra<sup>2</sup>, que é uma biblioteca *Open Source* multiplataforma para desenvolvimento de aplicações DICOM em C++. Cada exame é formado por uma quantidade variada de imagens, representando fatias no plano axial do tórax em que cada fatia é uma imagem bidimensional de  $512 \times 512$  pixels. Na Figura 36 é ilustrada uma fatia de um exame da base de dados citada.

Figura 36 – imagem de TC do tórax da base de dados LIDC-IDRI.



Fonte: Autor.


Para que as informações presentes na parte interna do pulmão não interfiram na evolução da técnica, o banco de imagens utilizado tem sua resolução redimensionada para  $51 \times 51$  pixels e depois para  $512 \times 512$  pixels novamente através de uma interpolação linear. O efeito desse procedimento é visto na Figura 37, onde percebe-se a redução do contraste dos vasos e

<sup>1</sup> *Digital Imaging and Communications in Medicine* - extensão padrão para imagens médicas.

<sup>2</sup> <<http://www.imebra.com>>

vias aéreas no interior dos pulmões. Este procedimento pode facilitar a separação das bordas dos pulmões através de técnicas como limiarização, por exemplo, conforme visto na Figura 37d).

Figura 37 – imagem de TC, a) original com  $512 \times 512$  pixels; b) redimensionada para  $51 \times 51$  pixels; c) redimensionada para  $512 \times 512$  pixels e d) limiarizada.



Fonte: Autor.


Para realizar a segmentação dessas estruturas, o MCAR3D balão é inicializado no interior de cada pulmão, individualmente, de modo que apenas um pulmão seja segmentado por vez. Sendo assim, é realizado um total de 10 segmentações, sendo dois pulmões por exame. Em cada teste são variados a quantidade de raios, mantendo uma janela de busca de tamanho 7+7.

Além da técnica proposta, as abordagens testadas são o MCA Morfológico e o Crescimento de Regiões 3D (CR 3D). Ambas as técnicas são utilizadas para segmentação de modo geral, sem nenhuma aplicação específica. Isto é, segmentar os pulmões é uma prova de conceito da aplicação da técnica proposta.

O MCAR 3D é configurado para segmentar as estruturas com 2500 raios e uma malha inicial no interior do pulmão de interesse, definida a partir de um ponto manualmente selecionado pelo usuário. A energia externa utilizada é uma combinação de gradiente com limiarização para evitar pequenas estruturas internas ao pulmão. A Figura 38 exemplifica alguns estágios da etapa de segmentação da técnica proposta, tendo a malha inicial na Figura 38a), uma etapa intermediária na Figura 38b) e a segmentação final nas Figuras 38c e 38d).

Já a técnica de CR 3D é inicializada a partir de uma semente interna ao pulmão localizada no mesmo ponto de origem dos raios do MCAR 3D. Por fim, o MCA Morfológico é inicializado como uma matriz de regiões binárias intercaladas, semelhantes a um grande tabuleiro de xadrez (Figura 39a)). Essa inicialização é importante e necessária, pois, o MCA Morfológico atua nas regiões de interesse através de operações de morfologia matemática. Logo, é fundamental ter exemplo de várias regiões na inicialização do MCA. A Figura 39b) exemplifica uma etapa intermediária do processo de segmentação, na qual as regiões ainda não estão totalmente definidas e, por fim, na Figura 39c) há a separação completa de uma fatia do


Figura 38 – evolução da segmentação de um pulmão via MCAR 3D com a) malha inicial; b) segmentação intermediária e c) e d) segmentação final.



Fonte: Autor.

exame de TC em múltiplas regiões de interesse.

Figura 39 – evolução da segmentação de um pulmão via MCA Morfológico com a) leve-set binário inicial; b) segmentação intermediária e c) segmentação final.



Fonte: Autor.

#### 4.2.1 Medidas de Ajuste

Os resultados visuais dos pulmões segmentados estão mostrados no Apêndice D em cinco figuras, separados por exame, nos quais cada figura apresenta os quatro resultados das técnicas MCAR 3D (malha retangular e malha triangular), MCA Morfológico e CR 3D.

A seguir são analisadas as medidas de ajuste individualmente, após a aplicação das técnicas nos cinco exames reais. Os resultados obtidos são apresentados no Apêndice E, nos quais evidenciam-se, em detalhes, a diferença de valores entre os resultados das técnicas.

Os resultados para o ajuste de posição  $Fit_{XYZ}$  são ilustrados na Figura 56 do Apêndice F, enquanto os resultados produzidos para o ajuste de tamanho  $Fit_T$  estão na Figura 57 e os resultados obtidos para o ajuste de forma  $Fit_F$  são mostrados na Figura 58. Por fim, os resultados

para o coeficiente *dice* (DSC) estão na Figura 59.

Em relação à medida de ajuste de posição (Figura 56), percebe-se um comportamento semelhante entre todas as técnicas com valores próximos a 100%. O pior resultado ocorre com o CR 3D no exame 4 e, ainda assim, há uma correspondência de posição igual a 98,4%. Por outro lado, o melhor resultado é produzido com o MCAR 3D (TRI) com 100% de correspondência no exame 3. Assim, todas as técnicas testadas mantêm o centro geométrico próximo ao centro dos exames de referência, sendo que o MCAR 3D é responsável pelos maiores valores para  $Fit_{XYZ}$  nos exames 1, 3 e 4, enquanto MCA Morfológico apresenta os maiores valores para os exames 2 e 5.

Já a medida de ajuste de tamanho, que trata da semelhança volumétrica entre o resultado da segmentação e o volume de referência, apresenta resultados variando de 77,1% com a técnica CR 3D no exame 4 até 99,9% com o MCAR 3D (RET) no exame 1. Em relação a essa medida, a técnica MCAR 3D nas duas versões de malhas, produzem os melhores resultados independentes do exame, seguida pelo MCA Morfológico e, por fim, CR 3D, como pode ser visto na Figura 57.

Esse comportamento é esperado, uma vez que a técnica de CR 3D tende a gerar vazamento em regiões de intensidades semelhantes. Isso é comprovado através da análise visual das figuras do Apêndice D, onde a segmentação da região da traquéia aparece junto à região dos pulmões nas técnicas MCA Morfológico e CR 3D, fazendo com que o volume resultante seja maior do que o volume de referência.

A última medida trata da forma dos volumes e demonstra novamente que a técnica de CR 3D que produz os os piores resultados, conforme está apresentado na Figura 58. Esses resultados variam de 61% a 88%, enquanto o MCAR 3D (RET) varia de 86% a 92%, o MCAR 3D (TRI) varia de 85% a 92% e, por fim, a técnica MCA Morfológico varia entre 85% a 93%. Dessa forma, vê-se que essas três últimas técnicas produzem resultados muito semelhantes, tendo o MCA Morfológico uma taxa um pouco maior, com diferença de aproximadamente 1% para a técnica proposta.

Por fim, o coeficiente *dice* (DSC) corrobora os resultados produzidos para o ajuste de forma, pois, ambas as medidas se baseiam na cardinalidade dos volumes. Os resultados do DSC indicam novamente o CR 3D com taxas entre 76% e 93%, enquanto as demais técnicas produzem taxas com variação praticamente iguais, tendo o MCAR 3D (ambas as malhas) variação de 92% a 96% e o MCA Morfológico variação de 91% a 96%.

A diferença entre essas três últimas técnicas é que, no exame 1, ambas possuem 96% de acerto, enquanto no exame 2 o MCA Morfológico possui 94% versus 92% do MCAR 3D e no exame 3 o MCAR 3D possui 93% e 94% versus 91% do MCA Morfológico. Finalmente, nos exames 4 e 5, o MCA Morfológico produz 96% (aproximadamente 2% melhor do que a técnica proposta) que pode ser revertido com o aumento do número de pontos para o MCAR 3D.

A amplitude dos resultados das técnicas testadas pode ser vista na Tabela 3, na qual é mostrado o melhor e o pior resultado por medida de ajuste. O MCA Morfológico obtém um resultado ligeiramente melhor na maioria dos exames testados em relação às duas últimas medidas testadas. Isso se dá pelo fato de que, tanto o ajuste de forma quanto o DSC atribuírem maior importância às regiões comuns entre os volumes. Por se tratar de um tipo de *snake level-set*, o MCA Morfológico tende a agrupar todas as regiões da imagem e, com isso, consegue segmentar melhor o pulmão, como pode ser visto nas imagens do Apêndice D. Contudo, além do pulmão, outras regiões também são segmentadas, gerando falsos positivos que se assemelha ao vazamento da técnica Crescimento de Regiões 3D.

Tabela 3 – variação entre o melhor e o pior resultado das técnicas testadas nos exames reais.

Método	Fit <sub>XYZ</sub>	Fit <sub>T</sub>	Fit <sub>F</sub>	DSC
MCAR 3D (malha RET)	0,9893 - 0,9997	0,9642 - 0,9996	0,8606 - 0,9246	0,9251 - 0,9608
MCAR 3D (malha TRI)	0,9908 - 1,0000	0,9633 - 0,9992	0,8587 - 0,9285	0,9240 - 0,9629
MCA Morfológico	0,9945 - 0,9989	0,9262 - 0,9785	0,8501 - 0,9376	0,9190 - 0,9678
Crescimento de Região	0,9843 - 0,9980	0,7714 - 0,9412	0,6176 - 0,8828	0,7636 - 0,9373

Fonte: Autor.


#### 4.2.2 Custo Computacional

A última etapa de testes realizada se dá com a análise do custo computacional das técnicas. Para isso, cada técnica é executada 100 vezes e, ao final, é calculado o tempo médio necessário para segmentar os exames de TC.

O resultado do tempo médio após 100 execuções das técnicas testadas pode ser visto na Tabela 4 e ilustrado no gráfico da Figura 40 para melhor visualização e comparação. É possível perceber a discrepante diferença do tempo de processamento da técnica MCA Morfológico em contrates às demais, uma vez que esta possui tempos médio em torno de 260 s (4,3 min), enquanto as demais variam em torno de 15,2 s e 17,4 s (MCAR 3D) e 36 s (CR 3D).

Os resultados de segmentação da malha retangular do MCAR 3D se diferenciam dos resultados da malha triangular por uma variação de 2 a 3 segundos em todos os exames. A

Figura 40 – tempo médio de processamento (s) nos exames reais testados pelo método MCAR 3D, MCA Morfológico e CR 3D.



Fonte: Autor.

utilização da malha retangular produz resultados de 10% a 20% mais rápidos que a utilização da malha triangular. Por fim, o MCAR 3D é, de modo geral, cerca de 30 s mais rápido que o CR 3D ao levar em consideração todos os exames.

Tabela 4 – tempo de processamento para as técnicas MCAR 3D (malha retangular e triangular), e MCA Morfológico e Crescimento de Região aplicadas nos exames de 1 a 5.

Método	Tempo médio de processamento (s)				
	Ex. 1	Ex. 2	Ex. 3	Ex. 4	Ex. 5
MCAR 3D (malha RET)	15,1	14,4	16,6	15,2	15,2
MCAR 3D (malha TRI)	17,8	17,2	17,9	17,4	17,1
MCA Morfológico	268	239	298	260	244
Crescimento de Região	51,1	27,2	30,8	38,5	32

Fonte: Autor.

## 5 CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Na presente tese é proposta uma nova técnica de segmentação de volumes 3D de uso geral direcionada para a redução do custo computacional. A referida técnica é a maior contribuição do trabalho e se baseia nos conceitos dos Métodos de Contornos Ativos e nos Raios Ativos, une características de ambos para criar o então chamado Método de Contornos Ativos Radiais 3D (MCAR 3D).

Para compor o MCAR 3D, são propostas e descritas, nesta tese, equações que regem a energia interna do método. Essas equações são contribuições secundárias e são detalhadas e divididas em forças de continuidade e de curvatura. Além destas, é proposta uma força balão como nova energia interna, de modo que o MCAR 3D possa ser inicializado externamente ao objeto de interesse, de maneira tradicional, ou internamente ao objeto de interesse.

Além das forças internas, é proposta a utilização da força gradiente como energia externa para guiar a superfície às bordas do objeto de interesse. Para isso, são utilizadas malhas que conectam os pontos de controle da técnica. Nesta tese são propostas, ainda, duas malhas para conexão entre pontos: malha retangular e triangular.

Para verificar o desempenho da técnica proposta, são realizados testes de segmentação em volumes sintéticos com diferentes formatos e em volumes reais de exames de TC. São testadas as duas malhas propostas (retangular e triangular) com uma variação na quantidade de pontos, em cada tipo de malha, desde 12 pontos até aproximadamente 2500 pontos, visando verificar o comportamento da técnica nas diferentes regiões dos volumes sintéticos, bem como seu custo computacional. Essas duas topologias de malhas aliada ao MCA proposto são, também, contribuições desta tese.

Para validar os resultados da segmentação, o MCAR 3D é comparado com o MCA 3D tradicional, quando aplicado nos volumes sintéticos e comparado com o MCA Morfológico e CR 3D nos volumes de exames de TC. Para quantificar a qualidade da segmentação são utilizadas as medidas de ajuste de posição  $Fit_{XYZ}$ , de tamanho  $Fit_T$ , de forma  $Fit_F$  e o coeficiente *dice* DSC. A última etapa dos testes se dá pelo cálculo do custo computacional necessário para realizar as diversas segmentações com as configurações de pontos pré-estabelecidas. Para isso, as técnicas são executadas 100 vezes, o tempo médio é calculado.

Os resultados da medida  $Fit_{XYZ}$  se mostraram semelhantes, tanto nos testes sintéticos quanto nos testes reais independente da técnica testada. Isto indica que a segmentação do MCAR 3D, assim como as demais metodologias, não possui variação considerável quanto à posição e

ao centro geométrico dos volumes resultante do volume de referência.

Em relação aos resultados obtidos em decorrência da variação da quantidade de pontos, observa-se que a técnica proposta necessita de uma quantidade adequada de pontos para segmentar regiões específicas, a depender do tipo de estrutura a ser segmentada. Com os testes realizados, conclui-se que estruturas retangulares, com regiões planas e cantos pontiagudos, por exemplo, são facilmente segmentadas pelo MCA 3D tradicional com poucos pontos, uma vez que estes podem se locomover para qualquer local do espaço 3D e tendem a estacionar nos cantos. Contudo, com o aumento da quantidade de pontos, o MCAR 3D consegue realizar a mesma segmentação da técnica tradicional com um tempo de processamento ainda inferior. Ao passo que, em estruturas irregulares sem regiões planas nem regiões pontiagudas, como uma estrutura esférica, por exemplo, o MCA 3D não consegue realizar uma segmentação adequada independente da quantidade de pontos, enquanto a técnica proposta realiza a segmentação até com poucos pontos. Pode-se concluir que é uma das vantagens do MCAR 3D: a possibilidade do aumento da quantidade de pontos visando o refinamento da malha para alcançar a segmentação mais exata sem afetar seu desempenho computacional.

Ao analisar apenas os resultados relacionados ao tempo médio de processamento nos volumes sintéticos, conclui-se que, à medida que se aumenta a quantidade de pontos, o custo computacional do MCA 3D aumenta consideravelmente de 1 s para 22 s, enquanto o MCAR 3D aumenta de 1 s para apenas 4 s. Já os resultados nos exames reais mostram que o MCA Morfológico é aproximadamente 16 vezes mais lento que o MCAR 3D e produzem resultados semelhantes no tocante à segmentação de pulmões com o benefício de não haver vazamento de regiões. Comparado com o CR 3D, o MCAR 3D é aproximadamente duas vezes mais rápido, produzindo um resultado ainda superior. Com relação às malhas testadas, retangular e triangular, observam-se resultados semelhantes e muitas vezes coincidentes, de modo que, a única diferença notável ocorre em relação ao custo computacional, no qual a malha retangular é, em média, 2 s mais rápida do que a malha triangular nos teste em volumes reais, que são mais complexos e custosos computacionalmente.

Diante do exposto, conclui-se a eficiência da nova técnica proposta no processo de segmentação, com um resultado tão eficiente quanto se deseje, com o compromisso da localização e quantidade de pontos, além do baixo custo computacional, no qual diferencia-se de outras técnicas da literatura.

Em resumo, as principais contribuições desta tese são as propostas de:



- método de segmentação radial 3D adaptado à malha retangular;
- método de segmentação radial 3D adaptado à malha triangular;
- forças de continuidade e curvatura como energia interna para MCAR 3D;
- força balão como energia interna para MCAR 3D;
- força gradiente como energia externa para MCAR 3D;
- visualização 3D da dinâmica da técnica MCAR 3D; e
- volumes sintéticos 3D.

Com a criação desta nova técnica, estimula-se o desenvolvimento de pesquisas a serem sugeridas como trabalhos futuros, quais sejam:

- estudo de novas forças externas baseadas no processamento de sinais em uma dimensão como a TH ou GVF, por exemplo, já utilizada em trabalhos na literatura;
- estudo do impacto relacionado ao desempenho computacional através da variação do tamanho da janela de busca ao longo do feixe;
- criação de método de inicialização automática independente da aplicação;
- adição de um critério de parada mediante o congelamento das posições dos pontos de controle ao longo dos ciclos de iteração;
- aplicação da técnica propostas em outras estruturas reais tais como o músculo cardíaco, por exemplo; e
- criação do Método de Contornos Ativos Radiais 3D Duais baseado no trabalho de Alexandria *et al.* (2014).

## REFERÊNCIAS

AHLBERG, J. **Active Contours in Three Dimensions**. 1996.

ALEXANDRIA, A. R. D.; CORTEZ, P. C.; BESSA, J. A.; FÉLIX, J. H. D. 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. D.; CORTEZ, P. C.; FÉLIX, J. H. D. S.; CAVALCANTE, T. D. S.; Rebouças Filho, P. P.; Silva Júnior, J. D. A. C. Hilbertian energy: a method for external energy calculation on radial active contours. In: **IWSSIP 2010 - 17th International Conference on Systems, Signals and Image Processing**. [S.l.: s.n.], 2010. p. 81 – 84.

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

ALMEIDA, T. M. D. **Implementação e teste de método de contornos ativos T-Snakes para a segmentação de imagens**. 2009. 60 p. Monografia (Tecnologia em Mecatrônica Industrial) - Departamento da Indústria, Instituto Federal do Ceará, Fortaleza, 2009.

ALMEIDA, T. M. D.; CORTEZ, P. C.; ALEXANDRIA, A. R. D.; FÉLIX, J. H. D. S. Transformada wavelet como energia externa de contornos ativos radiais. In: **Computer on the Beach 2012**. [S.l.: s.n.], 2012. p. 241 – 250.

ALMEIDA, T. M. D.; CORTEZ, P. C.; CAVALCANTE, T. D. S. Three-dimensional radial active contour model: A 3-d to 1-d image segmentation technique. **IEEE Latin America Transactions**, v. 15, n. 2, p. 365 – 373, Feb 2017.

ARIKIDIS, N.; KARAHALIOU, A.; SKIADOPOULOS, S.; KORFIATIS, P.; LIKAKI, E.; PANAYIOTAKIS, G.; L., C. Size-adapted segmentation of individual mammographic microcalcifications. In: **8th IEEE International Conference on BioInformatics and BioEngineering, BIBE 2008**. [S.l.: s.n.], 2008.

ARIKIDIS, N.; KARAHALIOU, A.; SKIADOPOULOS, S.; KORFIATIS, P.; LIKAKI, E.; PANAYIOTAKIS, G.; COSTARIDOU, L. Size-adapted microcalcification segmentation in mammography utilizing scale-space signatures. **Computerized Medical Imaging and Graphics**, v. 34, n. 6, p. 487 – 493, 2010.

ARIKIDIS, N.; SKIADOPOULOS, S.; KARAHALIOU, A.; LIKAKI, E.; PANAYIOTAKIS, G.; COSTARIDOU, L. B-spline active rays segmentation of microcalcifications in mammography. **Medical Physics**, v. 35, n. 11, p. 5161 – 5171, 2008.

ARIKIDIS, N. S.; KARAHALIOU, A.; SKIADOPOULOS, S.; LIKAKI, E.; PANAYIOTAKIS, G.; COSTARIDOU, L. Integrating multiscale polar active contours and region growing for microcalcifications segmentation in mammography. **Journal of Instrumentation**, v. 4, n. 07, p. P07009, 2009.

ARMATO, S. G.; MCLENNAN, G.; BIDAUT, L.; MCNITT-GRAY, M. F.; MEYER, C. R.; REEVES, A. P.; ZHAO, B.; ABERLE, D. R.; HENSCHKE, C. I.; HOFFMAN, E. A.; KAZEROONI, E. A.; MACMAHON, H.; BEEKE, E. J. R. V.; YANKELEVITZ, D.;

BIANCARDI, A. M.; BLAND, P. H.; BROWN, M. S.; ENGELMANN, R. M.; LADERACH, G. E.; MAX, D.; PAIS, R. C.; QING, D. P. Y.; ROBERTS, R. Y.; SMITH, A. R.; STARKEY, A.; BATRAH, P.; CALIGIURI, P.; FAROOQI, A.; GLADISH, G. W.; JUDE, C. M.; MUNDEN, R. F.; PETKOVSKA, I.; QUINT, L. E.; SCHWARTZ, L. H.; SUNDARAM, B.; DODD, L. E.; FENIMORE, C.; GUR, D.; PETRICK, N.; FREYMAN, J.; KIRBY, J.; HUGHES, B.; CASTEELE, A. V.; GUPTE, S.; SALLAM, M.; HEATH, M. D.; KUHN, M. H.; DHARAIYA, E.; BURNS, R.; FRYD, D. S.; SALGANICOFF, M.; ANAND, V.; SHRETER, U.; VASTAGH, S.; CROFT, B. Y. 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, 2011.

BANERJEE, S.; MITRA, S.; SHANKAR, B. U. Automated 3d segmentation of brain tumor using visual saliency. **Information Sciences**, v. 424, p. 337 – 353, 2018.

BAUST, M.; YEZZI, A.; UNAL, G.; NAVAB, N. A sobolev-type metric for polar active contours. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, p. 1017 – 1024, 2011.

BAUST, M.; YEZZI, A.; UNAL, G.; NAVAB, N. Translation, scale, and deformation weighted polar active contours. **Journal of Mathematical Imaging and Vision**, v. 44, n. 3, p. 354 – 365, 2012.

BESSA, J. A.; CORTEZ, P. C.; FÉLIX, J. H. D. S.; NETO, A. R. D. R.; ALEXANDRIA, A. R. D. Radial snakes: Comparison of segmentation methods in synthetic noisy images. **Expert Systems with Applications**, v. 42, n. 6, p. 3079 – 3088, April 2015.

BREIER, M.; GROSS, S.; BEHRENSM, A.; STEHLE, T.; AACH, T. Active contours for localizing polyps in colonoscopic nbi image data. In: **Progress in Biomedical Optics and Imaging - Proceedings of SPIE**. [S.l.: s.n.], 2011. v. 7963, p. 7963 – 7963 – 10.

BRESENHAM, J. E. Algorithm for computer control of a digital plotter. **IBM Syst. J.**, IBM Corp., Riverton, NJ, USA, v. 4, n. 1, p. 25–30, mar. 1965. ISSN 0018-8670. Disponível em: <<http://dx.doi.org/10.1147/sj.41.0025>>.

CAVALCANTE, T. D. S. **Método de superfícies ativas usando local binary patterns (LBP) aplicado na segmentação de lobos pulmonares em imagens de tomografia computadorizada do tórax**. 2016. 202 p. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2016.

CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266–277, Feb 2001.

CHEN, H.; DOU, Q.; YU, L.; QIN, J.; HENG, P.-A. Voxresnet: Deep voxelwise residual networks for brain segmentation from 3d mr images. **NeuroImage**, v. 170, n. 446 - 455, 2018.

CHEN, J. B.; YUAN, Z. P.; GONG, Z. B. Development of autonomous bucket wheel reclaimer with laser vision. In: **Applied Mechanics and Materials**. [S.l.]: Trans Tech Publications, 2011. v. 44, p. 355–359.

CHEN, Y.; HUANG, T. S.; RUI, Y. Optimal radial contour tracking by dynamic programming. In: **Proceedings 2001 International Conference on Image Processing (Cat. No.01CH37205)**. [S.l.: s.n.], 2001. v. 1, p. 626–629.

- 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.
- CHOI, C.; TREVOR, A. J. B.; CHRISTENSEN, H. I. RGB-D edge detection and edge-based registration. In: **2013 IEEE/RSJ International Conference on Intelligent Robots and Systems**. Tokyo, Japan: [s.n.], 2013. p. 1568–1575.
- COHEN, L. D. On active contour models and balloons. **CVGIP: Image Understanding**, v. 53, n. 2, p. 211 – 218, March 1991.
- COHEN, L. D.; COHEN, I. Finite-element methods for active contour models and balloons for 2-d and 3-d images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 15, n. 11, p. 1131–1147, Nov 1993.
- COOK, D. A.; MUELLER, M. F.; FEDELE, F.; YEZZI, A. J. Adjoint active surfaces for localization and imaging. **IEEE Transactions on Image Processing**, v. 24, n. 1, p. 316–331, Jan 2015.
- 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.
- DENG, X.; RAMU, J.; NARAYANA, P. Spinal cord atrophy in injured rodents: High-resolution mri. **Magnetic Resonance in Medicine**, v. 57, n. 3, p. 620 – 624, 2007.
- DENZLER, J.; NIEMANN, H. Active rays: A new approach to contour tracking. **Journal of computing and information technology**, v. 4, n. 1, p. 9 – 16, 1996.
- DENZLER, J.; NIEMANN, H. Active rays: Polar-transformed active contours for real-time contour tracking. **Real-Time Imaging**, v. 5, n. 3, p. 203 – 213, Jun 1999.
- DICE, L. R. Measures of the amount of ecologic association between species. **Ecology**, v. 26, n. 3, p. 297 – 302, 1945.
- DOU, Q.; YU, L.; CHEN, H.; JIN, Y.; YANG, X.; QIN, J.; HENG, P.-A. 3d deeply supervised network for automated segmentation of volumetric medical images. **Medical Image Analysis**, v. 41, p. 40–54, 2017.
- FÉLIX, J. H. D. S. **Métodos de Contornos Ativos Hilbert 2D Aplicados na Segmentação de Imagem dos Pulmões em Tomografia Computadorizada do Tórax**. 2011. 141 p. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2011.
- FEYRER, S.; ZELL, A. Auf dem weg zum persönlichen assistenten - multisensorielle personendetektion zur realisierung von robustem folgeverhalten für einen mobilen servicero boter. **VDI Berichte**, n. 1552, p. 465–470, 2000.
- FREIXENET, J.; MUÑOZ, X.; RABA, D.; MARTÍ, J.; CUFÍ, X. Yet another survey on image segmentation: Region and boundary information integration. In: A., H.; G., S.; M., N.; P., J. (Ed.). **Computer Vision — ECCV 2002**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2002. p. 408–422.
- FU, K. S.; MUI, J. K. A survey on image segmentation. **Pattern Recognition**, v. 13, n. 1, p. 3–16, 1981.

- GEMIGNANI, V.; FAITA, F.; GHIADONI, L.; POGGIANTI, E.; DEMI, M. A system for real-time measurement of the brachial artery diameter in b-mode ultrasound images. **IEEE Transactions on Medical Imaging**, v. 26, n. 3, p. 393–404, 2007.
- GEMIGNANI, V.; PATERNI, M.; BENASSI, A.; DEMI, M. Real time contour tracking with a new edge detector. **Real-Time Imaging**, v. 10, n. 2, p. 103 – 116, 2004.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 3rd. ed. Upper Saddle River, New Jersey 07458: Pearson, 2008.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 4th. ed. 330 Hudson Street, New York, NY 10013: Pearson, 2018.
- HAFIZ, D. A.; SHETA, W. M.; BAYOUMI, S.; YOUSSEF, B. A. A new approach for 3d range image segmentation using gradient method. **Journal of Computer Science**, v. 7, n. 4, p. 475 – 487, 2011.
- HARALICK, R. M.; SHAPIRO, L. G. Image segmentation techniques. **Computer Vision, Graphics, and Image Processing**, v. 29, n. 1, p. 100–132, 1985.
- JACOB, M.; BLU, T.; UNSER, M. Efficient energies and algorithms for parametric snakes. **IEEE Transactions on Image Processing**, v. 13, n. 9, p. 1231–1244, September 2004.
- JAIN, A. K. **Fundamentals of Digital Image Processing**. Favoritenstrasse 9/4th Floor/1863: Prentice-Hall, 1989. (Prentice-Hall Information and System Sciences Series).
- JAOUEN, V.; GONZÁLEZ, P.; STUTE, S.; GUILLOTEAU, D.; BUVAT, I.; TAUBER, C. Vector-based active surfaces for segmentation of dynamic pet images. In: **2013 IEEE 10th International Symposium on Biomedical Imaging**. [S.l.: s.n.], 2013. p. 61–64.
- JIFENG, N.; CHENGKE, W.; SHIGANG, L.; SHUQIN, Y. NGVF: An improved external force field for active contour model. **Pattern Recognition Letters**, v. 28, n. 1, p. 58 – 63, 2007.
- KAHN, S. Reducing the gap between augmented reality and 3d modeling with real-time depth imaging. **Virtual Reality**, v. 17, n. 2, p. 111–123, Jun 2013.
- KALAFATIC, Z.; RIBARIC, S.; STANISAVLJEVIC, V. A system for tracking laboratory animals based on optical flow and active contours. In: **Proceedings on 11th International Conference on Image Analysis and Processing, ICIAP 2001**. [S.l.: s.n.], 2001. p. 334 – 339.
- 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**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012. p. 75 – 101.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **International Journal of Computer Vision**, v. 1, n. 4, p. 321–331, 1987.
- KERKENI, A.; BENABDALLAH, A.; MANZANERA, A.; BEDOUI, M. H. A coronary artery segmentation method based on multiscale analysis and region growing". **Computerized Medical Imaging and Graphics**, v. 48, p. 49–61, March 2016.

- LASSEN, B.; RIKXOORT, E. M. van; SCHMIDT, 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, n. 2, p. 210–222, Feb 2013.
- LASSEN, B. C.; KUHNIGK, J.-M.; KONRAD, O.; GINNEKEN, B. van; RIKXOORT, E. M. van. Fast interactive segmentation of the pulmonary lobes from thoracic computed tomography data. **Physics in Medicine and Biology**, v. 62, n. 16, p. 6649, Jul 2017.
- LAWIN, F. J.; DANELLJAN, M.; TOSTEBERG, P.; BHAT, G.; KHAN, F. S.; FELSBURG, M. Deep projective 3d semantic segmentation. **CoRR**, abs/1705.03428, 2017.
- LEHMANN, T.; BREDNO, J.; SPITZER, K. On the design of active contours for medical image segmentation: A scheme for classification and construction. In: **Methods of Information in Medicine**. [S.l.: s.n.], 2003. v. 42, n. 1, p. 89 – 98.
- LI, B.; ACTON, S. T. Active contour external force using vector field convolution for image segmentation. **IEEE Transactions on Image Processing**, v. 16, n. 8, p. 2096–2106, August 2007.
- LONG, D.; FAN, S. Research on the extraction of quasi-circular object contours using active contour model in polar coordinate. In: **Proceedings of SPIE - The International Society for Optical Engineering**. [S.l.: s.n.], 2003. p. 251 – 254.
- LUO, H.; LU, Q.; ACHARYA, R. S.; GABORSKI, R. Robust snake model. In: **Proceedings IEEE Conference on Computer Vision and Pattern Recognition. CVPR 2000 (Cat. No.PR00662)**. [S.l.: s.n.], 2000. v. 1, p. 452–457 vol.1.
- MÁRQUEZ-NEILA, P.; BAUMELA, L.; ALVAREZ, L. A morphological approach to curvature-based evolution of curves and surfaces. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 36, n. 1, p. 2 – 17, Jan 2014.
- MARTI, G.; BAUR, C.; ZAMBELLI, P.-Y. Optimal femoral head contour segmentation in ct images using dynamic programming. **Technology and Health Care**, v. 12, n. 4, p. 315 – 322, 2004.
- MCINERNEY, T.; TERZOPOULOS, D. Deformable models in medical image analysis: a survey. **Medical Image Analysis**, v. 1, n. 2, p. 91 – 108, 1996.
- MISHRA, A.; FIEGUTH, P. W.; CLAUSI, D. A. Decoupled active surface for volumetric image segmentation. In: **2010 Canadian Conference on Computer and Robot Vision**. [S.l.: s.n.], 2010. p. 293–300.
- NIXON, M. S.; AGUADO, A. S. **Feature Extraction and Image Processing**. [S.l.]: Newnes, 2002.
- OSHER, S.; SETHIAN, J. Fronts propagating with curvature-dependent speed - algorithms based on hamilton-jacobi formulations. **Journal Of Computational Physics**, v. 79, n. 1, p. 12 – 49, Nov 1988.
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62 – 66, Jan 1979.

- PAL, N. R.; PAL, S. K. A review on image segmentation techniques. **Pattern Recognition**, v. 26, n. 9, p. 1277–1294, 1993.
- PARDO, J. M.; CABELLOA, D.; HERASB, J. A snake for model-based segmentation of biomedical images. **Pattern Recognition Letters**, v. 18, n. 14, p. 1529–1538, Dezembro 1997.
- PRATT, W. K. **Introduction to Digital Image Processing**. [S.l.]: CRC Press, 2013.
- QIU, W.; CHEN, Y.; KISHIMOTO, J.; RIBAUPIERRE, S. D.; CHIU, B.; FENSTER, A.; YUAN, J. Automatic segmentation approach to extracting neonatal cerebral ventricles from 3d ultrasound images. **Medical Image Analysis**, v. 35, p. 181 – 191, Jan 2017.
- RADEVA, P.; SERRAT, J.; MARTI, E. A snake for model-based segmentation. In: **Proceedings of IEEE International Conference on Computer Vision**. [S.l.: s.n.], 1995. p. 816–821.
- REBOUCAS, E. S.; SARMENTO, R. M.; REBOUÇAS FILHO, P. P. 3d adaptive balloon active contour: method of segmentation of structures in three dimensions. **IEEE Latin America Transactions**, v. 13, n. 1, p. 195–203, Jan 2015.
- REBOUÇAS FILHO, P. P. **Métodos de contornos ativos Crisp 2D e 3D aplicados na segmentação dos pulmões em imagens de tomografia computadorizada do tórax**. 2013. 182 p. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2013.
- REBOUÇAS FILHO, P. P.; CORTEZ, P. C.; BARROS, A. C. D. S.; ALBUQUERQUE, V. H. C. Novel adaptive balloon active contour method based on internal force for image segmentation – a systematic evaluation on synthetic and real images. **Expert Systems with Applications**, v. 41, n. 17, p. 7707–7721, Dezembro 2014.
- REBOUÇAS FILHO, P. P.; CORTEZ, P. C.; BARROS, A. C. D. S.; ALBUQUERQUE, V. H. C.; TAVARES, J. M. R. S. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images. **Medical Image Analysis**, v. 35, p. 503 – 516, Jan 2017.
- RIBEIRO, A. B. N. **Segmentação dos vasos sanguíneos pulmonares em imagens de tomografia computadorizada do tórax**. 2013. 79 p. Dissertação (Mestrado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2013.
- SAGE, D.; UNSER, M.; SALMON, P.; DIBNER, C. A software solution for recording circadian oscillator features in time-lapse live cell microscopy. **Cell Division**, v. 5, n. 1, p. 17, Jul 2010.
- SAXENA, A.; CHUNG, S. H.; NG, A. Y. 3-d depth reconstruction from a single still image. **International Journal of Computer Vision**, v. 76, n. 1, p. 53–69, Jan 2008.
- SCHNEIDER, P.; EBERLY, D. H. **Geometric Tools for Computer Graphics**. [S.l.]: Morgan Kaufmann, 2002. (The Morgan Kaufmann Series in Computer Graphics).
- SHADID, W. G.; WILLIS, A. Bone fragment segmentation from 3d CT imagery. **Computerized Medical Imaging and Graphics**, v. 66, p. 14 – 27, 2018.
- SHAPIRO, L. G.; STOCKMAN, G. C. **Computer Vision**. Upper Saddle River, NJ, USA: Prentice Hall PTR, 2001.

SLABAUGH, G.; UNAL, G. Active polyhedron: surface evolution theory applied to deformable meshes. In: **2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)**. [S.l.: s.n.], 2005. v. 2, p. 84–91.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image Processing, Analysis and Machine**. [S.l.]: Thomson, 2008.

SOUZA, A. A. S.; MAIA, R.; GONÇALVES, L. M. G. 3d probabilistic occupancy grid to robotic mapping with stereo vision. In: BHATTI, A. (Ed.). **Current Advancements in Stereo Vision**. Rijeka: InTech, 2002. cap. 09.

SPIRKOVSKA, L. **A summary of image segmentation techniques**. NASA Ames Research Center, Moffett Field, California, 1993.

THAN, J. C. M.; SABA, L.; NOOR, N. M.; RIJAL, O. M.; KASSIM, R. M.; YUNUS, A.; SURI, H. S.; PORCU, M.; SURI, J. S. Lung disease stratification using amalgamation of riesz and gabor transforms in machine learning framework. **Computers in Biology and Medicine**, v. 89, p. 197 – 211, October 2017.

VERSARI, C.; STOMA, S.; BATMANOV, K.; LLAMOSI, A.; MROZ, F.; KACZMAREK, A.; DEYELL, M.; LHOUSSAINE, C.; HERSEN, P.; BATT, G. Long-term tracking of budding yeast cells in brightfield microscopy: Cellstar and the evaluation platform. **Journal of The Royal Society Interface**, v. 14, n. 127, 2017.

WANG, Y.; LIU, L.; ZHANG, H.; CAO, Z.; LU, S. Image segmentation using active contours with normally biased GVF external force. **IEEE Signal Processing Letters**, v. 17, n. 10, p. 875–878, October 2010.

WEI, M.; ZHOU, Y.; WAN, M. A fast snake model based on non-linear diffusion for medical image segmentation. **Computerized medical imaging and graphics : the official journal of the Computerized Medical Imaging Society**, v. 28, n. 3, p. 109–17, 2004.

WEIHERER, T. **Scalable Map-based Environment Representations for Highly Automated Vehicles** . 2015. 220 p. Dissertation (Lehrstuhl für Datenverarbeitung) - Technische Universität München, Fakultät für Elektrotechnik und Informationstechnik, München, 2015.

Wikipedia contributors. **Regular icosahedron — Wikipedia, The Free Encyclopedia**. 2018. [Online; accessed 12-July-2018]. Disponível em: <[https://en.wikipedia.org/w/index.php?title=Regular\\_icosahedron&oldid=847378707](https://en.wikipedia.org/w/index.php?title=Regular_icosahedron&oldid=847378707)>.

WIRJADI, O. **Survey of 3D image segmentation methods**. 67663 Kaiserslautern Germany, 2007. Disponível em: <<http://kluedo.uni-kl.de/volltexte/2008/2213/pdf/bericht123.pdf>>.

WOŹNIAK, T.; STRZELECKI, M.; MAJOS, A.; STEFAŃCZYK, L. 3d vascular tree segmentation using a multiscale vesselness function and a level set approach. **Biocybernetics and Biomedical Engineering**, v. 37, n. 1, p. 66 – 76, 2017.

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

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.



ZENG, Y. zhan; LIAO, S. hui; TANG, P.; ZHAO, Y. qian; LIAO, M.; CHEN, Y.; LIANG, Y. xiong. Automatic liver vessel segmentation using 3d region growing and hybrid active contour model. **Computers in Biology and Medicine**, v. 97, p. 63 – 73, 2018.

ZHANG, Y.-G.; XU, J.-M.; YOU, F.; WEN, H.-Y.; HUANG, S.-B. Steering wheel boundary feature extraction based on contour fusion for long-distance bus. In: **Proceedings of the World Congress on Intelligent Control and Automation (WCICA)**. [S.l.: s.n.], 2011. p. 617 – 620.


ZHENG, G.; CHU, C.; BELAVY, D. L.; IBRAGIMOV, B.; KOREZ, R.; VRTOVEC, T.; HUTT, H.; EVERSON, R.; MEAKIN, J.; ANDRADE, I. L.; GLOCKER, B.; CHEN, H.; DOU, Q.; HENG, P.-A.; WANG, C.; FORSBERG, D.; NEUBERT, A.; FRIPP, J.; URSCHLER, M.; STERN, D.; WIMMER, M.; NOVIKOV, A. A.; CHENG, H.; ARMBRECHT, G.; FELSENBURG, D.; LI, S. Evaluation and comparison of 3d intervertebral disc localization and segmentation methods for 3d {T2} {MR} data: A grand challenge. **Medical Image Analysis**, v. 35, p. 327–344, 2017.

## APÊNDICE A – RESULTADOS VISUAIS - VOLUMES SINTÉTICOS

Neste apêndice são apresentadas as imagens dos volumes sintéticos segmentados pelas técnicas MCAR 3D (malha retangular e malha triangular) e MCA 3D de forma isolada visando a melhor leitura dos resultados do Capítulo 4. Os volumes resultantes estão dispostos da seguinte maneira: as Figuras 41, 42, 43, 44 e 45 trazem os resultados aplicados nos volumes da Figura 34 (Cilindro, Cone, Cubo, Esfera e Pirâmide, respectivamente).


Cada figura é composta por 15 imagens dispostas em três linhas com cinco colunas sendo as imagens das primeiras linhas referentes aos resultados da técnica MCAR 3D (malha retangular), os resultados da técnica MCAR 3D (malha triangular) na segunda linha e, por fim, os resultados da técnica MCA 3D na terceira linha. Já as imagens das colunas correspondem à evolução dos resultados com aproximadamente 12, 36, 156, 625 e 2500 pontos para cada coluna da esquerda para direita.

Figura 41 – evolução da segmentação do volume cilíndrico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j, o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente.




Fonte: Autor.

Figura 42 – evolução da segmentação do volume cônico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j, o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente.




Fonte: Autor.

Figura 43 – evolução da segmentação do volume cúbico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j, o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente.




Fonte: Autor.

Figura 44 – evolução da segmentação do volume esférico com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j, o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente.



Fonte: Autor.

Figura 45 – evolução da segmentação do volume piramidal com diferente quantidade de pontos: 12 (a, f, k), 36 (b, g, l), 156 (c, h, m), 625 (d, i, n) e 2500 (e, j, o) para as técnicas MCAR 3D (malha retangular), MCAR 3D (malha triangular) e MCA 3D na primeira, segunda e terceira linha, respectivamente.



Fonte: Autor.

## APÊNDICE B – RESULTADOS NUMÉRICOS - VOLUMES SINTÉTICOS

Neste apêndice são detalhados os valores utilizados para gerar os gráficos mostrados no Apêndice C a fim de possibilitar a reprodução e comparação futura entre outras técnicas e a técnica proposta.

As Tabelas 5, 6, 7, 8 e 9 se referem aos resultados dos testes de ajuste de forma e coeficiente *dice* aplicados nos cinco volumes sintéticos: cilindro, cone, cubo, esfera e pirâmide. Cada volume é testado com três métodos: MCAR 3D (malha Retangular), MCAR 3D (malha Triangular) e MCA 3D. A quantidade de pontos é variada de 12 pontos a aproximadamente 2500 pontos.

Tabela 5 – resultados entre as medidas de ajuste e coeficiente *dice* para o volume sintético cilíndrico.

Volume	Método	Nº Pontos	Fit <sub>XYZ</sub>	Fit <sub>T</sub>	Fit <sub>F</sub>	DSC
Cilindro	Retangular	12	0,9979	0,6637	0,4957	0,6628
		36	0,9973	0,8758	0,7666	0,8679
		156	0,9967	0,9899	0,9233	0,9601
		625	0,9970	0,9970	0,9467	0,9726
		2500	0,9969	0,9709	0,9422	0,9702
	Triangular	12	0,9979	0,7820	0,6389	0,7797
		42	0,9972	0,9562	0,8894	0,9414
		162	0,9967	0,9865	0,9420	0,9701
		642	0,9968	0,9730	0,9399	0,9690
		2565	0,9967	0,9672	0,9347	0,9662
	MCA 3D	12	0,9940	0,8457	0,7167	0,8350
		36	0,9983	0,9113	0,8084	0,8941
		156	0,9979	0,9502	0,8618	0,9258
		625	0,9952	0,9776	0,8969	0,9456
		2500	0,9964	0,9978	0,9298	0,9636

Fonte: Autor.



Tabela 6 – resultados entre as medidas de ajuste e coeficiente *dice* para o volume sintético cônico.

<b>Volume</b>	<b>Método</b>	<b>Nº Pontos</b>	<b>Fit<sub>XYZ</sub></b>	<b>Fit<sub>T</sub></b>	<b>Fit<sub>F</sub></b>	<b>DSC</b>
Cone	Retangular	12	0,9871	0,5110	0,3409	0,5084
		36	0,9927	0,8676	0,7499	0,8571
		156	0,9934	0,9512	0,8324	0,9085
		625	0,9961	0,9814	0,9201	0,9584
		2500	0,9966	0,9626	0,9236	0,9603
	Triangular	12	0,9879	0,6050	0,4310	0,6024
		42	0,9941	0,9064	0,7922	0,8841
		162	0,9955	0,9964	0,9046	0,9499
		642	0,9960	0,9715	0,9149	0,9556
		2565	0,9964	0,9595	0,9172	0,9568
	MCA 3D	12	0,9874	0,8685	0,7356	0,8477
		36	0,9975	0,9952	0,9257	0,9614
		156	0,9974	0,9796	0,9390	0,9686
		625	0,9970	0,9713	0,9381	0,9681
		2500	0,9969	0,9680	0,9355	0,9667

Fonte: Autor.

Tabela 7 – resultados entre as medidas de ajuste e coeficiente *dice* para o volume sintético cúbico.

<b>Volume</b>	<b>Método</b>	<b>Nº Pontos</b>	<b>Fit<sub>XYZ</sub></b>	<b>Fit<sub>T</sub></b>	<b>Fit<sub>F</sub></b>	<b>DSC</b>
Cubo	Retangular	12	0,9976	0,6898	0,5150	0,6799
		36	0,9971	0,8922	0,7685	0,8691
		156	0,9954	0,9918	0,9038	0,9495
		625	0,9972	0,9823	0,9412	0,9697
		2500	0,9967	0,9738	0,9443	0,9713
	Triangular	12	0,9977	0,7116	0,5488	0,7087
		42	0,9971	0,8937	0,7703	0,8702
		162	0,9968	0,9897	0,9320	0,9648
		642	0,9967	0,9778	0,9413	0,9697
		2565	0,9967	0,9729	0,9441	0,9712
	MCA 3D	12	0,9954	0,9909	0,9243	0,9607
		36	0,9954	0,9920	0,9262	0,9617
		156	0,9950	0,9860	0,9176	0,9570
		625	0,9950	0,9855	0,9166	0,9565
		2500	0,9950	0,9855	0,9166	0,9565

Fonte: Autor.

Tabela 8 – resultados entre as medidas de ajuste e coeficiente *dice* para o volume sintético esférico.

<b>Volume</b>	<b>Método</b>	<b>Nº Pontos</b>	<b>Fit<sub>XYZ</sub></b>	<b>Fit<sub>T</sub></b>	<b>Fit<sub>F</sub></b>	<b>DSC</b>
Esfera	Retangular	12	0,9977	0,7425	0,5896	0,7418
		36	0,9971	0,9260	0,8491	0,9184
		156	0,9967	0,9866	0,9431	0,9707
		625	0,9968	0,9650	0,9285	0,9629
		2500	0,9968	0,9567	0,9160	0,9561
	Triangular	12	0,9982	0,7963	0,6610	0,7959
		42	0,9974	0,9675	0,9266	0,9619
		162	0,9970	0,9790	0,9428	0,9705
		642	0,9970	0,9640	0,9274	0,9623
		2565	0,9969	0,9545	0,9128	0,9544
	MCA 3D	12	1,0000	0,6602	0,4918	0,6593
		36	0,9959	0,8539	0,7348	0,8471
		156	0,9970	0,8972	0,7981	0,8877
		625	0,9951	0,9244	0,8338	0,9094
		2500	0,9956	0,9573	0,8806	0,9365

Fonte: Autor.

Tabela 9 – resultados entre as medidas de ajuste e coeficiente *dice* para o volume sintético piramidal.

<b>Volume</b>	<b>Método</b>	<b>Nº Pontos</b>	<b>Fit<sub>XYZ</sub></b>	<b>Fit<sub>T</sub></b>	<b>Fit<sub>F</sub></b>	<b>DSC</b>
Pirâmide	Retangular	12	0,9871	0,4268	0,2701	0,4253
		36	0,9948	0,8952	0,7669	0,8681
		156	0,9925	0,9874	0,8816	0,9371
		625	0,9965	0,9762	0,9235	0,9602
		2500	0,9969	0,9630	0,9246	0,9608
	Triangular	12	0,9875	0,5635	0,3870	0,5580
		42	0,9931	0,8865	0,7483	0,8560
		162	0,9946	0,9727	0,8547	0,9216
		642	0,9960	0,9771	0,9110	0,9534
		2565	0,9968	0,9631	0,9238	0,9604
	MCA 3D	12	0,9969	0,9778	0,9424	0,9703
		36	0,9974	0,9731	0,9472	0,9729
		156	0,9976	0,9786	0,9309	0,9642
		625	0,9976	0,9730	0,9405	0,9693
		2500	0,9976	0,9730	0,9405	0,9693

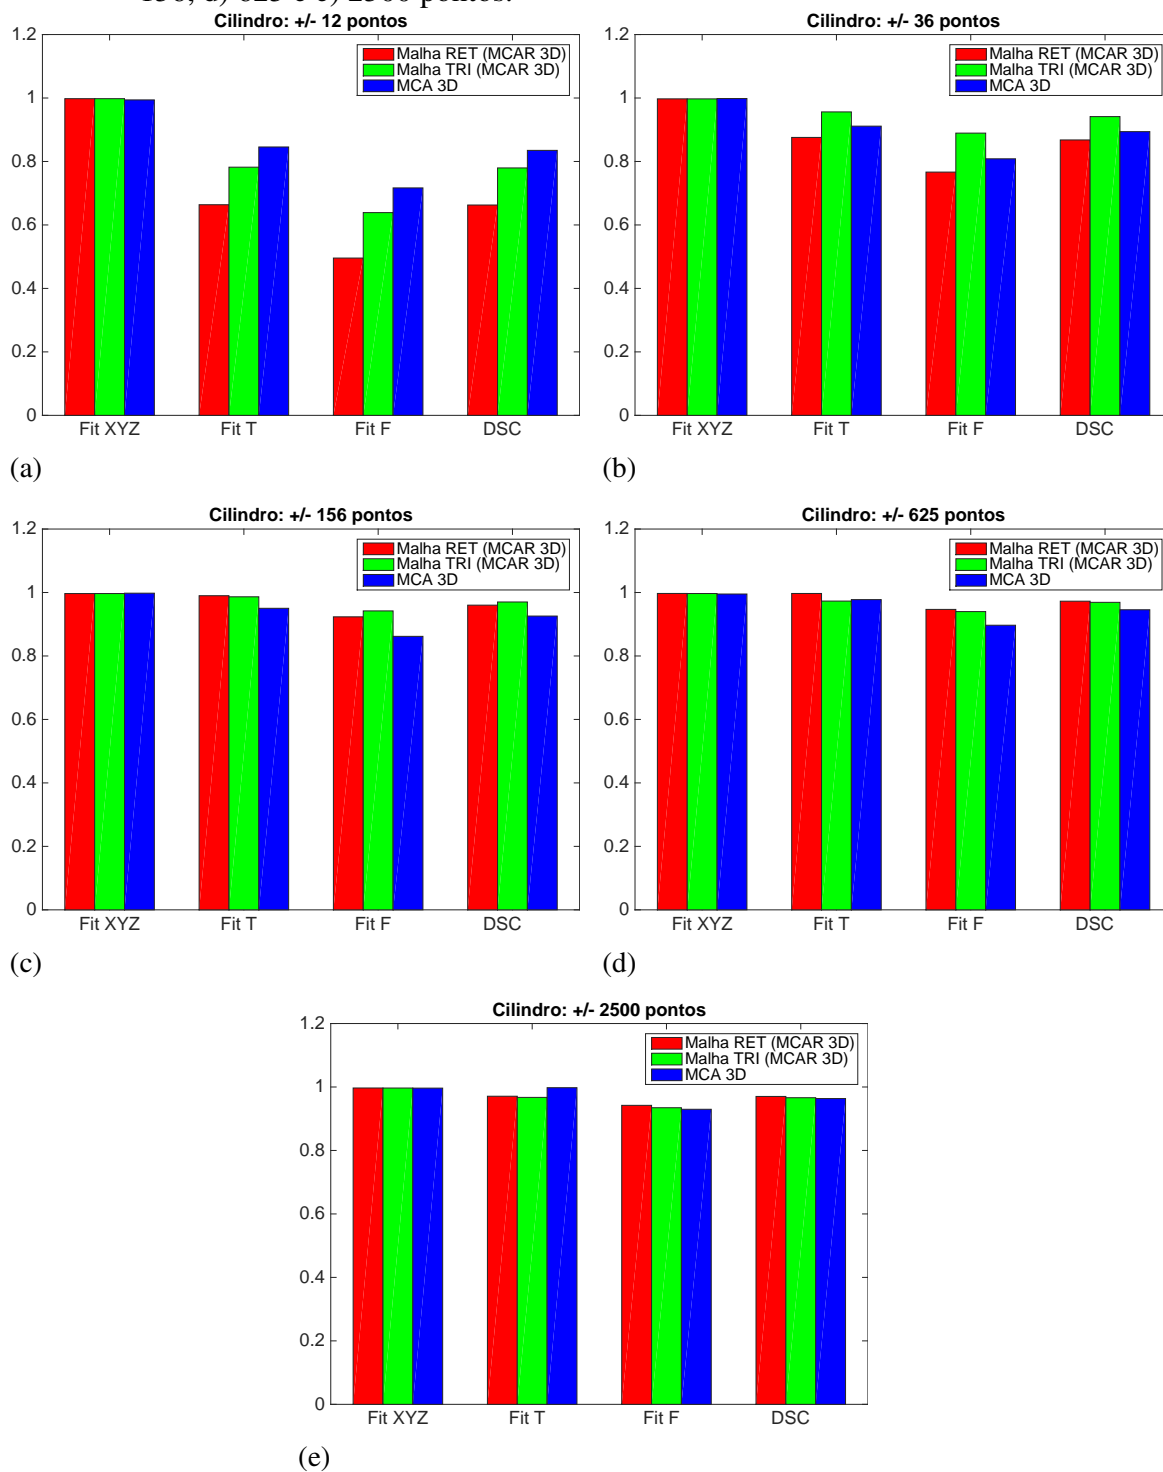
Fonte: Autor.

## APÊNDICE C – RESULTADOS GRÁFICOS - VOLUMES SINTÉTICOS

Neste apêndice são apresentados os gráficos relacionados aos resultados das medidas de ajuste de posição ( $Fit_{XYZ}$ ), ajuste de tamanho ( $Fit_T$ ), ajuste de forma ( $Fit_F$ ) e coeficiente *dice* (DSC) para os volumes sintéticos nas Figuras 46, 47, 48, 49 e 50.

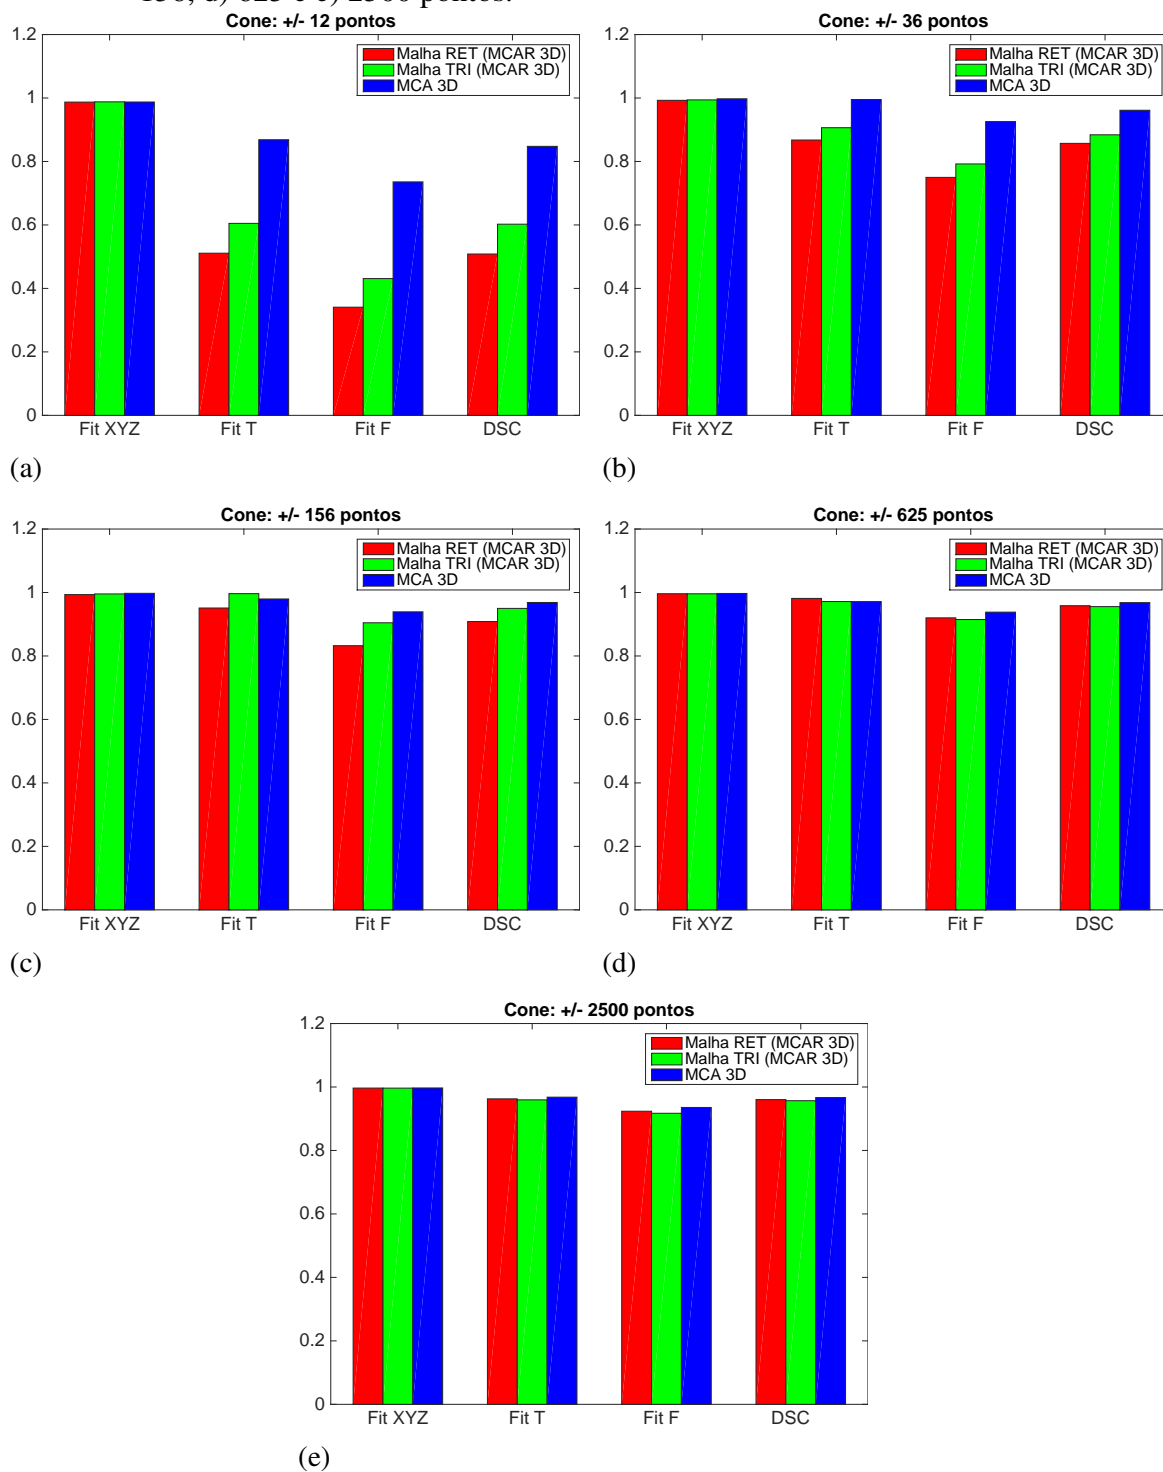
Cada Figura faz referencia a uma forma sintética e traz cinco gráficos referentes ao aumento da quantidade de pontos de 12 pontos até aproximadamente 2500 pontos. O gráfico mostra, em barras, o resultado das quatro medidas separados entre as três técnicas testadas: MCAR 3D (malha retangular e malha triangular) e MCA 3D.

Figura 46 – resultados das medidas de ajuste aplicadas no volume cilíndrico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos.



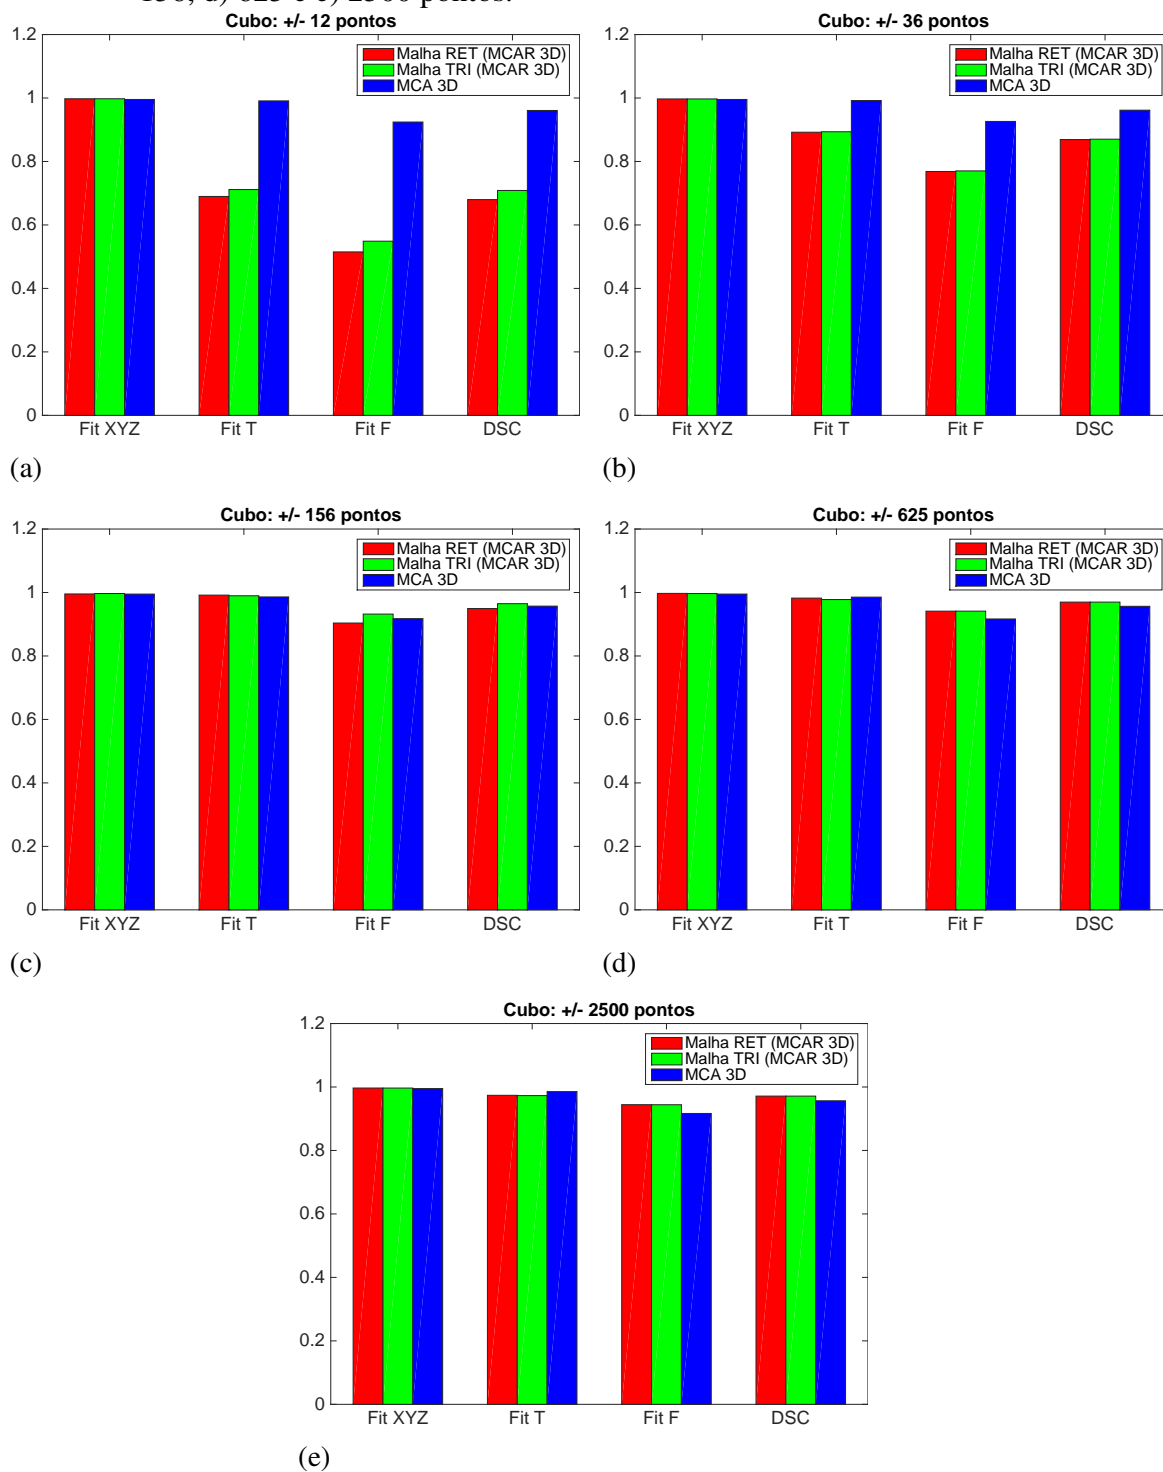
Fonte: Autor.

Figura 47 – resultados das medidas de ajuste aplicadas no volume cônico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos.



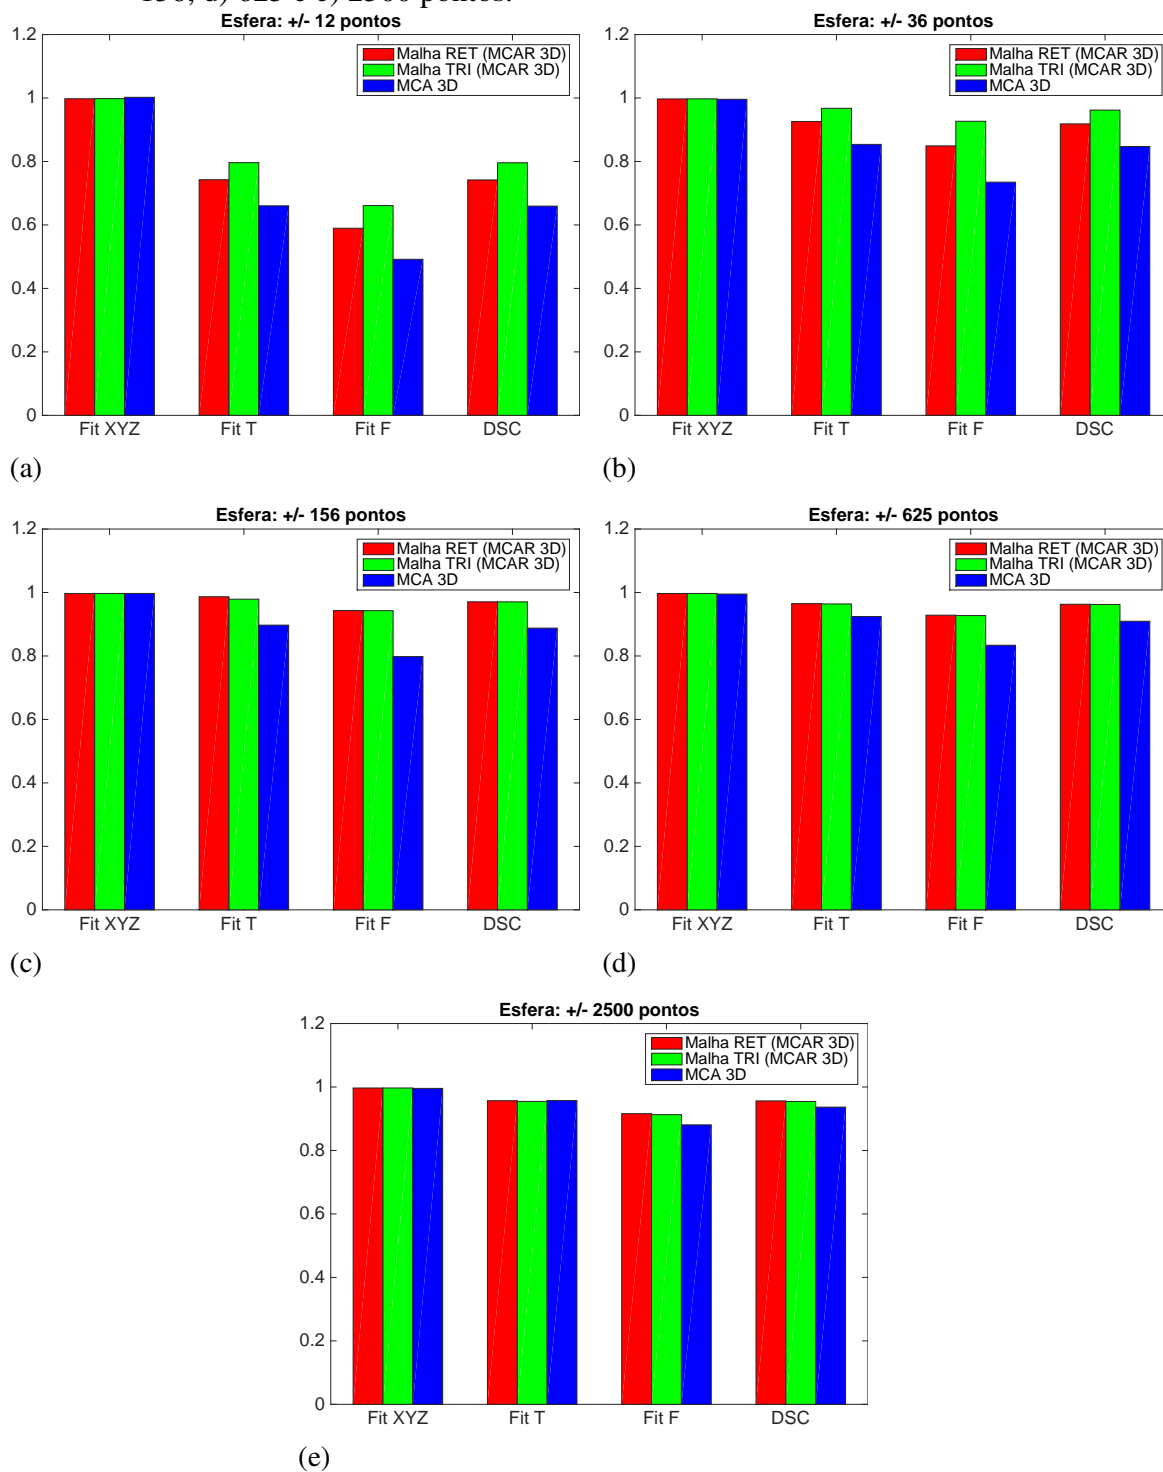
Fonte: Autor.

Figura 48 – resultados das medidas de ajuste aplicadas no volume cúbico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos.



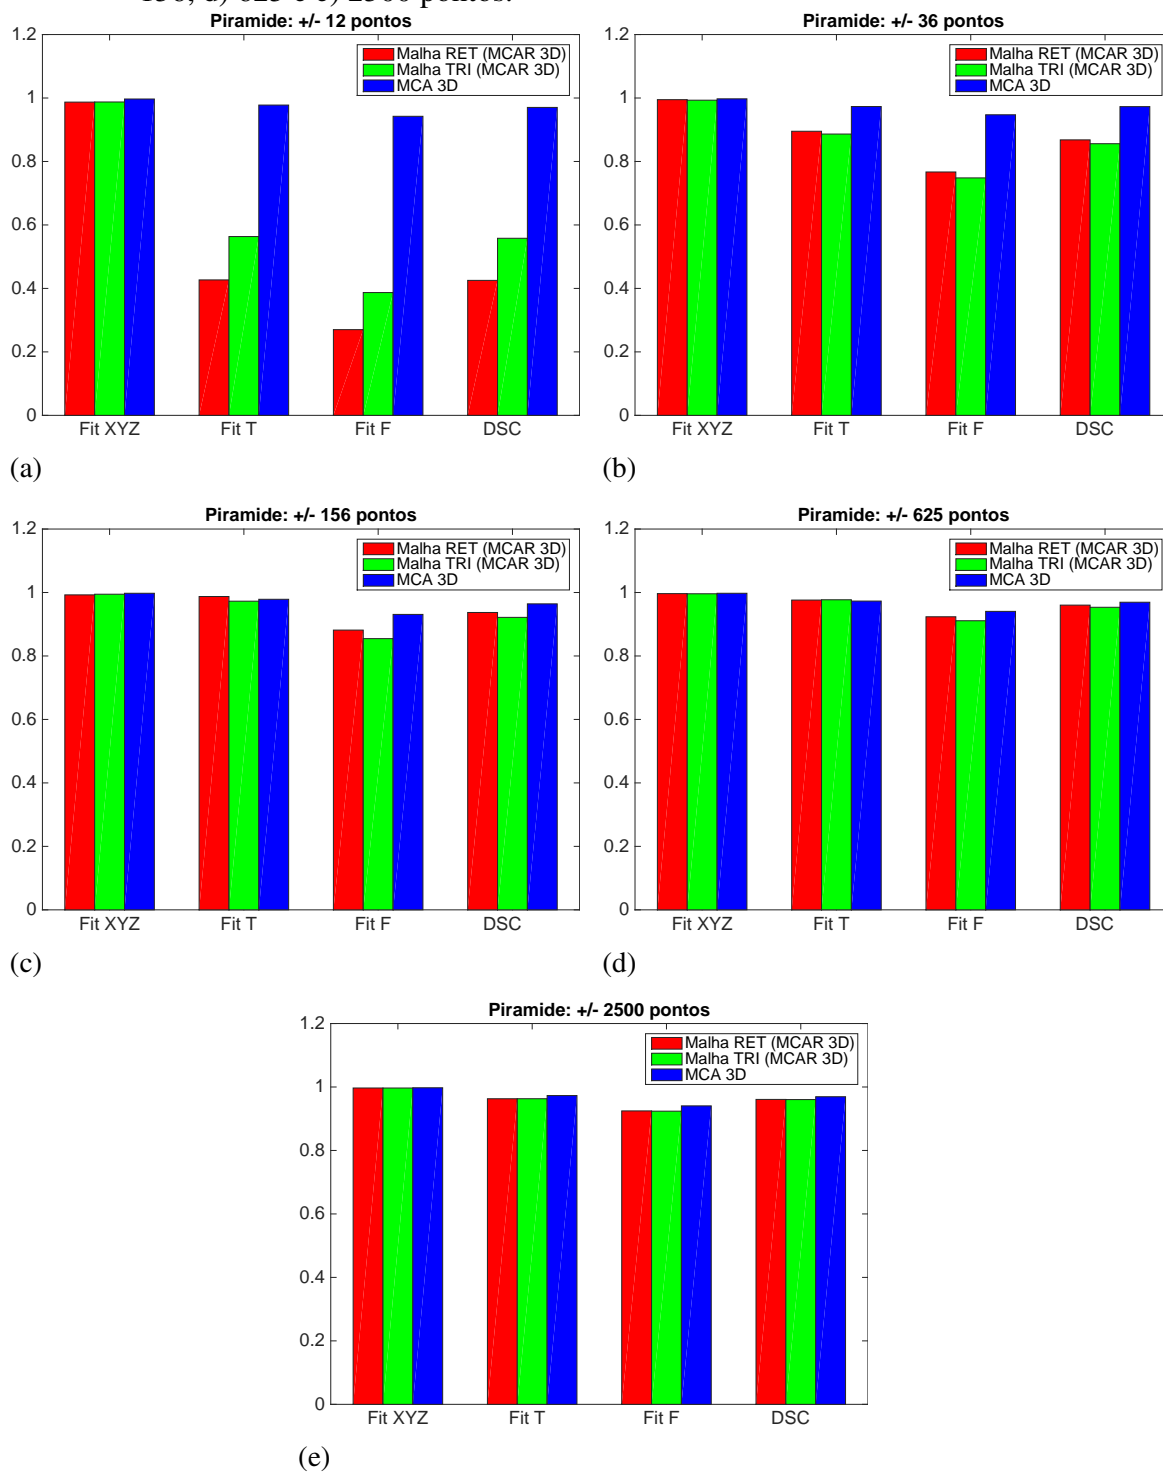
Fonte: Autor.

Figura 49 – resultados das medidas de ajuste aplicadas no volume esférico com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos.



Fonte: Autor.

Figura 50 – resultados das medidas de ajuste aplicadas no volume piramidal com a) 12, b) 36, c) 156, d) 625 e e) 2500 pontos.




Fonte: Autor.



## APÊNDICE D – RESULTADOS VISUAIS - VOLUMES REAIS


Neste apêndice são apresentadas as imagens dos volumes reais segmentados pelas técnicas MCAR 3D (malha retangular e malha triangular), MCA Morfológico e Crescimento de Regiões de forma isolada, visando a melhor leitura dos resultados do Capítulo 4. Cada figura se refere aos resultados em um exame específico onde cada exame produz quadro resultados.

Figura 51 – segmentação do exame 1 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões.




Fonte: Autor.


Figura 52 – segmentação do exame 2 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões.




(a)



(b)




(c)



(d)


Fonte: Autor.

Figura 53 – segmentação do exame 3 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões.




Fonte: Autor.

Figura 54 – segmentação do exame 4 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões.



(a)



(b)



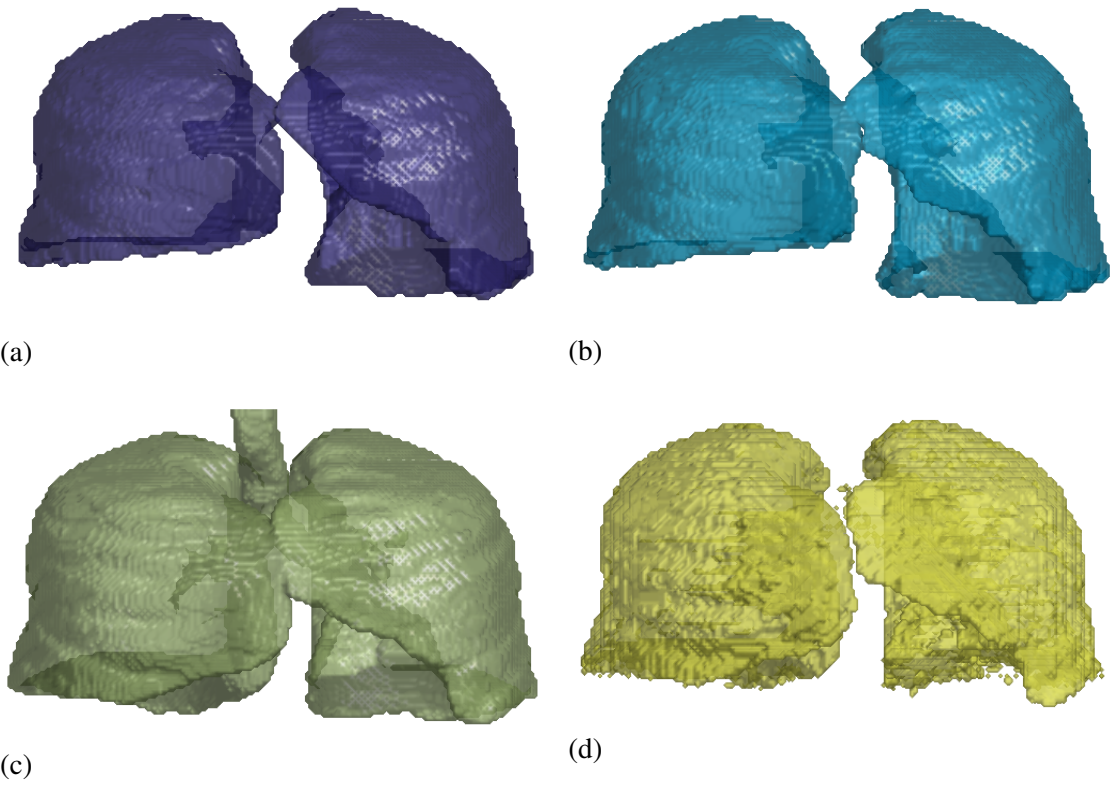
(c)



(d)

Fonte: Autor.

Figura 55 – segmentação do exame 5 a partir das técnicas a) MCAR 3D (RET), b) MCAR 3D (TRI), c) MCA Morfológico e d) Crescimento de Regiões.



Fonte: Autor.

## APÊNDICE E – RESULTADOS NUMÉRICOS - VOLUMES REAIS

Neste apêndice são detalhados os valores utilizados para gerar os gráficos mostrados no Capítulo 4 a fim de possibilitar a reprodução e comparação futura entre outras técnicas e a técnica proposta.

A Tabela 10 traz os resultados de ajuste de forma e coeficiente *dice* aplicado aos cinco exames médicos reais pelas técnicas MCAR 3D (malha Retangular), MCAR 3D (malha Triangular), MCA Morfológico e Crescimento de Região.

Tabela 10 – resultados entre as medidas de ajuste e coeficiente *dice* entre os exames de TC.

<b>Exame</b>	<b>Método</b>	<b>Fit<sub>XYZ</sub></b>	<b>Fit<sub>T</sub></b>	<b>Fit<sub>F</sub></b>	<b>DSC</b>
Exame 1	MCAR 3D (malha RET)	0,9995	0,9996	0,9246	0,9608
	MCAR 3D (malha TRI)	0,9992	0,9992	0,9285	0,9629
	MCA Morfológico	0,9989	0,9757	0,9326	0,9651
	Crescimento de Região	0,9980	0,9412	0,8828	0,9377
Exame 2	MCAR 3D (malha RET)	0,9893	0,9642	0,8606	0,9251
	MCAR 3D (malha TRI)	0,9908	0,9633	0,8587	0,9240
	MCA Morfológico	0,9982	0,9469	0,8898	0,9417
	Crescimento de Região	0,9932	0,8689	0,7679	0,8687
Exame 3	MCAR 3D (malha RET)	0,9997	0,9801	0,8825	0,9376
	MCAR 3D (malha TRI)	1,0000	0,9851	0,8871	0,9402
	MCA Morfológico	0,9945	0,9262	0,8501	0,9190
	Crescimento de Região	0,9919	0,8839	0,7919	0,8838
Exame 4	MCAR 3D (malha RET)	0,9984	0,9936	0,9119	0,9539
	MCAR 3D (malha TRI)	0,9983	0,9878	0,9188	0,9577
	MCA Morfológico	0,9980	0,9762	0,9376	0,9678
	Crescimento de Região	0,9843	0,7714	0,6176	0,7636
Exame 5	MCAR 3D (malha RET)	0,9951	0,9906	0,8850	0,9390
	MCAR 3D (malha TRI)	0,9953	0,9985	0,8885	0,9410
	MCA Morfológico	0,9978	0,9785	0,9347	0,9663
	Crescimento de Região	0,9923	0,9213	0,8531	0,9207


Fonte: Autor.

## APÊNDICE F – RESULTADOS GRÁFICOS - VOLUMES REAIS

Neste apêndice são apresentados os gráficos relacionados aos resultados das medidas de ajuste de posição ( $Fit_{XYZ}$ ), ajuste de tamanho ( $Fit_T$ ), ajuste de forma ( $Fit_F$ ) e coeficiente *dice* (DSC) para os volumes reais nas Figuras 56, 57, 58 e 59.

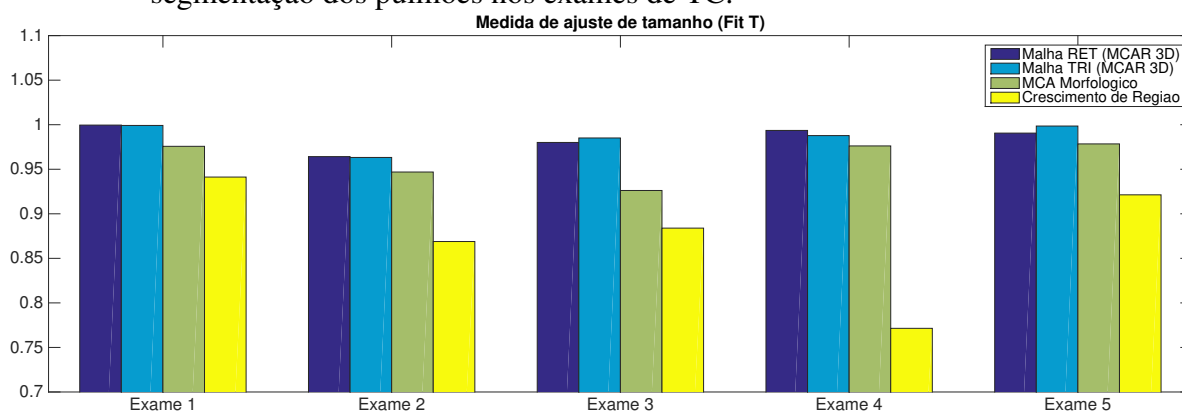
Cada Figura faz referencia a uma medida avaliada trazendo um gráfico que mostra, em barras, o resultado nos cinco exames médicos reais após a aplicação das quatro técnicas: MCAR 3D (malha retangular e triangular), MCA Morfológico e Crescimento de Regiões.

Figura 56 – resultados da medida de ajuste de posição utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC.




Fonte: Autor.

Figura 57 – resultados da medida de ajuste de tamanho utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC.



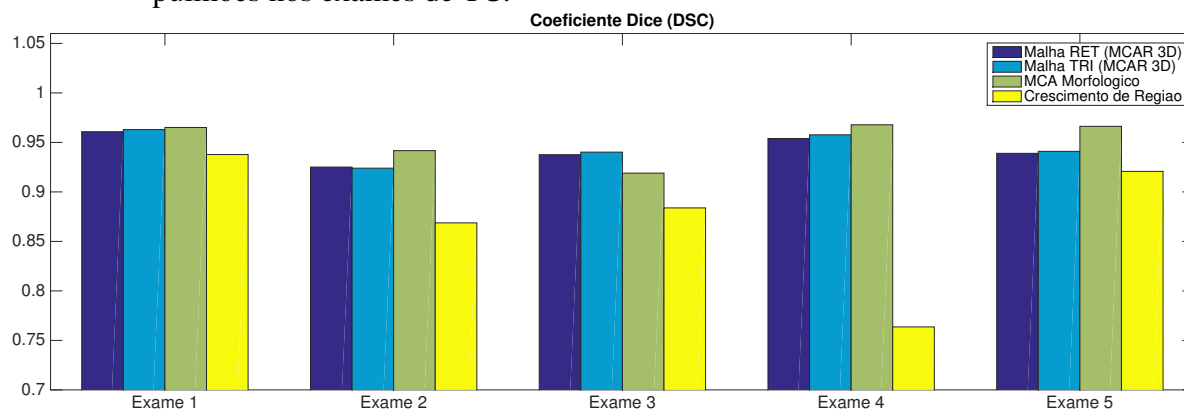
Fonte: Autor.

Figura 58 – resultados da medida de ajuste de forma utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC.



Fonte: Autor.

Figura 59 – resultados de coeficiente *dice* utilizando o MCAR 3D (malha retangular e triangular), MCA 3D Morfológico e Crescimento de Regiões aplicados na segmentação dos pulmões nos exames de TC.



Fonte: Autor.