



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

**EDSON CAVALCANTI NETO**

**3D AUTOCUT: MÉTODO DE SEGMENTAÇÃO 3D APLICADO A IMAGENS DE  
TOMOGRAFIA COMPUTADORIZADA DO TÓRAX**

**FORTALEZA**

**2018**

EDSON CAVALCANTI NETO

3D AUTOCUT: MÉTODO DE SEGMENTAÇÃO 3D APLICADO A IMAGENS DE  
TOMOGRAFIA COMPUTADORIZADA DO TÓRAX

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 - Engenharia IV

Orientador: Prof. Dr. Paulo César Cortez

FORTALEZA

2018

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)

---

- C3653 Cavalcanti Neto, Edson.  
3D AUTOCUT: Método de Segmentação 3D Aplicado a Imagens de Tomografia Computadorizada do Tórax / Edson Cavalcanti Neto. – 2018.  
97 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2018.  
Orientação: Prof. Dr. Paulo César Cortez.
1. Processamento Digital de Imagens. 2. Tomografia Computadorizada. 3. Autômatos. I. Título.  
CDD 621.38
-

EDSON CAVALCANTI NETO

3D AUTOCUT: MÉTODO DE SEGMENTAÇÃO 3D APLICADO A IMAGENS DE  
TOMOGRAFIA COMPUTADORIZADA DO TÓRAX

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 - Engenharia IV

Aprovada em: 30 de julho de 2018

BANCA EXAMINADORA

---

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

---

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

---

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

---

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

---

Prof. Dr. Pedro Pedrosa Rebouças Filho  
Instituto Federal do Ceará (IFCE)

## **AGRADECIMENTOS**

A toda minha família pelo apoio e incentivo, pela dedicação, pela paciência, pela persistência, pelo amor que dedicaram a mim durante toda essa jornada, em especial aos meus pais Raimundo Enéas Cavalcanti Neto e Regina Coeli Figueiredo Cavalcanti

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

Ao professor Dr. Marcelo Alcântara de Holanda e a Dra. Ingrid Correia Nogueira que tornaram possível a realização deste, graças à disponibilidade, dedicação e apoio.

A todos os companheiros e amigos da UFC e do IFCE pela amizade, paciência e pelos conselhos e ensinamentos que me foram passados durante essa jornada, em especial agradeço aos amigos Tarique da Silveira Cavalcante, Alyson Bezerra Nogueira Ribeiro, Rafael Alves, Pedro Batista Neto, Romulo Frutuoso, Jonas Rodrigues, Italo Sampaio, Francisco José Marques Anselmo, Valberto Enoc Rodrigues da Silva Filho e Thomaz Maia de Almeida, o qual peço desculpas por ter esquecido de adicionar seu nome em um dos artigos submetidos.

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

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

Não se preocupe com as pedras no caminho sejam elas grandes ou pequenas. As grandes a gente pula e as pequenas a gente chuta.

(Wesley Safadão)

## RESUMO

Entre todos os tipos de câncer, o de pulmão (CP) é um dos mais comuns de todos os tumores malignos, apresentando aumento de 2% por ano na sua incidência mundial. No Brasil, para o ano de 2018 são estimados 31.270 casos novos de CP, sendo destes 18.740, em homens e 12.530 em mulheres. Neste contexto, é de fundamental importância para saúde pública se ter um diagnóstico precoce e preciso para detectar os estágios reais das doenças pulmonares, bem como para aumentar as chances de cura. Em tais doenças, o exame de Tomografia Computadorizada (TC) do Tórax contém muitas informações para seu diagnóstico precoce para tanto, a segmentação 3D dos pulmões, é fundamental. Muitos métodos foram desenvolvidos para a segmentação 3D dos pulmões, entretanto, em sua maioria apresentam problemas quando há presença de doenças, tais como CP ou mesmo outras estruturas presentes no interior dos pulmões. Na direção de resolver este problema, nesta tese é proposto um novo algoritmo baseado em autômatos 3D que utiliza uma composição de forças no espaço RGB e em seguida é realiza a inicialização dos rótulos e sementes que evoluem de forma interativa até se estabilizarem. Além disso, um método de inicialização automática 3D para segmentação de pulmões em imagens de TC também é proposto. Os testes são realizados para a segmentação 3D em imagens sintéticas (cilindro, duplocone, cubo e esfera) e imagens exames de TC do tórax. Nos testes das imagens sintéticas são introduzidos ruídos para avaliar, com base no ajuste de posição e no coeficiente de similaridade Dice, a capacidade e robustez de segmentação 3D do método proposto, comparado a outros métodos encontrados na literatura pesquisada. Neste tipo de imagens, os resultados obtidos comprovaram que o algoritmo 3D Autocut os melhores resultados para imagens tanto para baixo nível de ruído, quanto com alto nível de ruído, com medidas de ajuste de posição e coeficiente Dice acima de 0.95. Os testes para imagens de TC do tórax, baseados nas métricas coeficiente de similaridade Dice, ajuste de posição, ajustes de forma e de tamanho, são utilizados 15 exames, nas posições ápice, hilo e base, de pacientes voluntários saudáveis e com patologia. Os resultados da segmentação 3D, baseado no método 3D Autocut, bem como a utilização da inicialização proposta, também produz resultados superiores, em relação aos demais métodos avaliados, em 93,3% dos exames, quando comparando a forma final da segmentação e a similaridade Dice. As principais contribuições são os algoritmos 3D Autocut e o de inicialização automática das sementes.

**Palavras-chave:** Segmentação 3D, TC do tórax, Autômatos.

## ABSTRACT

Among all types of cancer, lung cancer (LC) is one of the most common of all malignancies, presenting a growth of 2% in its worldwide expansion. In Brazil, for the year 2018, 31,270 new LC cases are estimated, of which 18,740 are in men and 12,530 in women. This is important to prevent the diagnosis and increase the chances of cure. In such diseases, the Computed Tomography (CT) scan of the Thorax contains information from the 3D segmentation of the lungs helping its early diagnosis. Different methods have been developed for the 3D lung segmentation, however, they mostly present problems when there are diseases such as LC or other structures present inside the lungs. In this thesis, a new 3D algorithm is proposed, which uses a force composition in the RGB space and then initializes the labels and seeds that evolve interactively until they stabilize. In addition, a new 3D automatic initialization method for lung segmentation in CT images is also proposed. The tests were performed for 3D segmentation in synthetic images (cylinder, doublecone, cube and sphere) and images CT scans of the thorax. In the tests of the synthetic images are introduced noises to evaluate, based on the position adjustment and the Dice similarity coefficient, the 3D segmentation capacity and robustness of the method, compared to other methods found in the researched literature. In this type of images, the results obtained showed that the 3D Autocut algorithm has the best results for both low noise and high noise images with position adjustment measures and Dice coefficient above 0.95. The tests for thoracic CT images, based on the metrics Dice similarity coefficient, position adjustment, shape and size adjustments, use 15 exams in the apex, hilo and base positions of healthy and pathological patients. The 3D segmentation result, based on the 3D Autocut method, as well as the use of the proposed initialization, also produces superior results in 93.3% of the exams when comparing the final form of segmentation and Dice Similarity. The main contributions are the Autocut 3D algorithms and the automatic seed initialization algorithm.

**Keywords:** 3D Segmentation, Thorax CT, Automata.

## LISTA DE FIGURAS

Figura 1 – imagens do corpo humano nas secções transversal, coronal e sagittal. . . . .	24
Figura 2 – a) imagem original de TC, b) representação do exame de TC pelas faixas de densidade. . . . .	25
Figura 3 – Sistema de visão computacional típico. . . . .	26
Figura 4 – Histograma de imagem com baixo contraste. . . . .	28
Figura 5 – Histograma de imagem com o histograma equalizado. . . . .	29
Figura 6 – exemplos de vizinhanças circulares (8,1), (16,2) e (8,2) (AHONEN <i>et al.</i> , 2006). . . . .	31
Figura 7 – operador básico LBP com vizinhança (8,1) (AHONEN <i>et al.</i> , 2006). . . . .	31
Figura 8 – aplicação da limiarização , a) imagem original, e b) imagem limiarizada. . .	34
Figura 9 – exemplo de aplicação do operador Sobel, a) imagem em RGB, b) imagem em tom de cinza, c) resultado do operador Sobel para identificação das linhas horizontais, e d) resultado do operador Sobel para identificação das linhas verticais. . . . .	35
Figura 10 – a) As células vermelhas são referentes à vizinhança Von Neumann para a célula azul; b) As células são a vizinhança Moore para a célula azul. . . . .	36
Figura 11 – O ataque de uma célula de defesa, em vermelho, pela sua vizinhança, em cinza.	37
Figura 12 – Segmentação de imagem colorida, a) imagem original, b) sementes definidas pelo usuário, c) resultado da segmentação. . . . .	38
Figura 13 – Passos da evolução da segmentação. . . . .	39
Figura 14 – ilustração da aplicação do <i>Region Growing</i> 3D, a) localização da semente, b) primeira iteração do RG 3D, e c) resultado final da segmentação. . . . .	43
Figura 15 – Fluxograma do método proposto . . . . .	48
Figura 16 – Modelos dos volumes sintéticos . . . . .	49
Figura 17 – Imagens originais de TC do pulmão, tórax, cérebro e fígado. . . . .	49
Figura 18 – Imagens resultantes da filtragem gaussiana . . . . .	50
Figura 19 – Imagens resultantes da equalização do histograma . . . . .	50
Figura 20 – Imagens resultantes do filtro LBP . . . . .	50
Figura 21 – Configuração da montagem no espaço RGB . . . . .	51
Figura 22 – Imagens resultantes no espaço RGB obtidas a partir de suas componentes da Figura 21. . . . .	51

Figura 23 – Imagem 3D obtida pelo método proposto . . . . .	52
Figura 24 – fluxograma do método proposto de inicialização para imagens de TC do Tórax. . . . .	53
Figura 25 – imagens de pulmão, a) imagem 2D original do pulmão, e b) imagem 2D limiarizada. . . . .	53
Figura 26 – volume 3D resultante do processamento de limiarização. . . . .	54
Figura 27 – volume 3D do pulmão separado ao meio. . . . .	55
Figura 28 – volume 3D do pulmão esquerdo e direito separado em três partes. . . . .	55
Figura 29 – inicialização dos raios no volume 3D do pulmão esquerdo e direito. . . . .	57
Figura 30 – intensidade dos <i>voxels</i> no percurso do raio gerado. . . . .	57
Figura 31 – raios gerados a partir do centro de massa. . . . .	58
Figura 32 – Imagens sintéticas 3D utilizadas para os testes, a) cilindro, b) esfera, c) cubo e d) duplocone. . . . .	60
Figura 33 – Imagens sintéticas 3D utilizadas para os testes, a) cilindro, b) esfera, c) cubo e d) duplocone. . . . .	62
Figura 34 – imagens resultantes após a aplicação dos métodos para segmentação do cilindro. . . . .	68
Figura 35 – imagens resultantes após a aplicação dos métodos para segmentação do cubo. . . . .	68
Figura 36 – imagens resultantes após a aplicação dos métodos para segmentação do duplo cone. . . . .	68
Figura 37 – imagens resultantes após a aplicação dos métodos para segmentação da esfera. . . . .	69
Figura 38 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume do cilindro. . . . .	70
Figura 39 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume do cubo. . . . .	70
Figura 40 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume do duplo cone. . . . .	71
Figura 41 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume da esfera. . . . .	71
Figura 45 – Ajuste de posição baseado na variância do ruído para o volume da esfera. . . . .	71
Figura 42 – Ajuste de posição baseado na variância do ruído para o volume do cilindro. . . . .	72
Figura 43 – Ajuste de posição baseado na variância do ruído para o volume do cubo. . . . .	72
Figura 46 – Síntese dos resultados do Método proposto. . . . .	79
Figura 47 – Resultados obtidos para os métodos baseado no coeficiente Dice. . . . .	80

Figura 48 – Resultados obtidos para os métodos baseado no ajuste de tamanho. . . . .	81
Figura 49 – Resultados obtidos para os métodos baseado no ajuste de posição. . . . .	81
Figura 50 – Resultados obtidos para os métodos baseado no ajuste de forma. . . . .	82

## LISTA DE TABELAS

Tabela 1 – Relação sinal-ruído nas imagens sintéticas . . . . .	61
Tabela 2 – Tipos de exames utilizados. . . . .	63
Tabela 3 – resultados obtidos para o cilindro para os coeficiente de similaridade Dice e ajuste de posição. . . . .	67
Tabela 4 – resultados obtidos para o cubo para os coeficiente de similaridade Dice e ajuste de posição. . . . .	67
Tabela 5 – resultados obtidos para o duplocone para os coeficiente de similaridade Dice e ajuste de posição. . . . .	67
Tabela 6 – resultados obtidos para a esfera para os coeficiente de similaridade Dice e ajuste de posição. . . . .	67
Tabela 7 – Variações do comprimento e quantidade de raios. . . . .	73
Tabela 8 – Coeficiente Dice de similaridade em relação à quantidade de raios e comprimento dos raios. . . . .	74
Tabela 9 – Ajuste de Tamanho em relação à quantidade de raios e comprimento dos raios.	75
Tabela 10 – Ajuste de Posição em relação à quantidade de raios e comprimento dos raios.	75
Tabela 11 – Ajuste de Forma em relação à quantidade de raios e comprimento dos raios.	75
Tabela 12 – Variações das dimensões de janelas. . . . .	76
Tabela 13 – Coeficiente Dice de similaridade em relação à dimensão da janela. . . . .	77
Tabela 14 – Ajuste de Tamanho em relação às dimensões das janelas. . . . .	77
Tabela 15 – Ajuste de Posição em relação às dimensões das janelas. . . . .	78
Tabela 16 – Ajuste de Forma em relação às dimensões das janelas. . . . .	79

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Objetivos</b>	<b>18</b>
<i>1.1.1</i>	<i>Objetivos Específicos</i>	<i>18</i>
<b>1.2</b>	<b>Contribuições</b>	<b>18</b>
<b>1.3</b>	<b>Produção Científica</b>	<b>19</b>
<b>1.4</b>	<b>Organização do Trabalho</b>	<b>20</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>22</b>
<b>2.1</b>	<b>Imagens Médicas</b>	<b>22</b>
<b>2.2</b>	<b>Sistema de Visão Computacional</b>	<b>25</b>
<i>2.2.1</i>	<i>Realce de imagens</i>	<i>27</i>
<i>2.2.2</i>	<i>Local Binary Patterns - LBP</i>	<i>30</i>
<i>2.2.3</i>	<i>Segmentação de Imagens</i>	<i>33</i>
<i>2.2.4</i>	<i>Métodos de segmentação</i>	<i>34</i>
<i>2.2.4.1</i>	<i>GrowCut Original</i>	<i>35</i>
<i>2.2.4.2</i>	<i>Three-dimensional radial active contour model (RAC3D)</i>	<i>38</i>
<i>2.2.4.3</i>	<i>Morphological Active Contours Without Edges (MACWE3D)</i>	<i>40</i>
<i>2.2.4.4</i>	<i>Region Growing 3D</i>	<i>41</i>
<i>2.2.4.5</i>	<i>Fast level set based image segmentation using coherent propagation</i>	<i>42</i>
<b>2.3</b>	<b>Estado da Arte</b>	<b>44</b>
<b>3</b>	<b>METODOLOGIA</b>	<b>47</b>
<b>3.1</b>	<b>Descrição do método proposto</b>	<b>47</b>
<i>3.1.1</i>	<i>Definição das sementes iniciais para o TC do Tórax</i>	<i>52</i>
<i>3.1.2</i>	<i>Regra de evolução do algoritmo</i>	<i>58</i>
<b>3.2</b>	<b>Avaliação do Método</b>	<b>59</b>
<i>3.2.1</i>	<i>Testes em Imagens Sintéticas</i>	<i>59</i>
<i>3.2.2</i>	<i>Testes em Imagens Médicas</i>	<i>62</i>
<i>3.2.3</i>	<i>Métricas de Avaliação</i>	<i>63</i>
<b>4</b>	<b>RESULTADOS</b>	<b>66</b>
<b>4.1</b>	<b>Resultados obtidos para Imagens sintéticas</b>	<b>66</b>
<b>4.2</b>	<b>Resultados obtidos para exames de TC do Tórax</b>	<b>73</b>

4.2.1	<i>Resultado obtidos para a inicialização automática</i>	73
4.2.2	<i>Resultados obtidos para variação das dimensões da janela</i>	76
4.2.3	<i>Resultados obtidos para os algoritmos avaliados</i>	80
5	<b>CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS</b>	83
	<b>REFERÊNCIAS</b>	86

## 1 INTRODUÇÃO

A Organização Mundial da Saúde (OMS) estimou que, em 2030, espera-se 27 milhões de casos incidentes e 12,6 milhões de mortes por câncer, sendo 2,4 milhões (19,0%) por câncer de traqueia, brônquios e pulmão (WHO, 2018). Na União Européia, o câncer do pulmão é considerado a neoplasia mais frequente e com alta letalidade, constando estatisticamente cerca de 266.000 óbitos por ano, os quais representam 20,8% de todas as mortes por câncer (EUROSTAT, 2017). Apesar das estatísticas evidenciarem uma maior ocorrência do CP nos países desenvolvidos, o número de casos da doença vem aumentando nos países em desenvolvimento.

De acordo com dados do Instituto Nacional de Câncer José Alencar Gomes da Silva (INCA), no fim do século XX, o câncer de pulmão se tornou uma das principais causas de morte evitáveis, já que está muito associado ao tabagismo, com diagnóstico geralmente em estádios avançados. Com isso, permanece sendo uma doença altamente letal, apresentando uma razão mortalidade/incidência de, aproximadamente, 90%. Recente estudo demonstrou esta razão próxima de 0,95 em homens e 0,86 em mulheres (INCA, 2018).

A estimativa mais recente do INCA, para o Brasil em 2018, indica a ocorrência de cerca 31.270 novos casos de CP, sendo 18.740 entre homens e 12.530 entre mulheres. Esses valores correspondem em um aumento estimado de 17,49 casos novos a cada 100 mil homens e 10,54 para cada 100 mil mulheres. Excetuando os casos de câncer de pele não melanoma, o CP é a segunda neoplasia mais frequente em homens (8,1%), e a quarta nas mulheres (5,3%) (INCA, 2018).

Em relação aos novos casos de CP estimados para 2018, dentre as regiões do Brasil, o Sul deve possuir um maior índice da doença, sendo São Paulo o estado que deve apresentar um maior número de novos casos (6.770). Já na região Nordeste, essa neoplasia deve ser a terceira mais frequente em homens (2.690 novos casos) e a quarta em mulheres (2.100 novos casos). Mais especificamente no Ceará, será a quarta neoplasia mais frequente em homens (560 novos casos) e terceira mais frequente nas mulheres (500 novos casos).

De acordo com Herbst *et al.* (2018), o carcinoma do pulmão é um dos cânceres de maior incidência, sendo a principal causa de morte relacionada ao câncer no mundo. Há o registro de mais de 160.000 mortes/ano nos Estados Unidos e, no Brasil, mais de 20.000 mortes/ano. Devido à dificuldade no diagnóstico precoce, a maioria dos pacientes se encontram em estágios avançados no momento do diagnóstico. Somente um terço destes pacientes submete-se à retirada total cirúrgica do tumor e, portanto, a maioria não é candidata a tratamento curativo.

A maioria dos pacientes são diagnosticados no estágio avançado da doença, quando não existe mais a possibilidade de cura, fato este devido aos poucos sintomas observados na fase inicial do câncer (INCA, 2018; WHO, 2014). As manifestações clínicas mais frequentes são a tosse, hemoptise, dor torácica, dispneia e emagrecimento, encontrados em 80% dos casos de CP. Estes sinais e sintomas são considerados o principal motivo pela procura de assistência médica (PEREIRA, 2013).

Após o diagnóstico clínico, a indicação do tratamento, seja clínico ou cirúrgico, e o prognóstico do CP deve ser pautados em três itens essenciais nesta avaliação: tipo histológico, estadiamento clínico por ocasião do diagnóstico e a situação funcional do paciente (RAJ *et al.*, 2011).

O tratamento do câncer de pulmão nos estágios iniciais, quando o tumor ainda se encontra localizado sem disseminação, é cirúrgico. A ressecção pulmonar é o tratamento de escolha para o carcinoma broncogênico em estágio precoce, sendo considerado o tratamento mais eficaz para o CP (PAPAGEORGIOU *et al.*, 2010).

O tratamento inicial do CP é a lobectomia, cirurgia realizada no pulmão na qual é retirado um lobo pulmonar. Desta forma, a partir de informações anatômicas das estruturas pulmonares, é possível realizar o planejamento correto para uma cirurgia de lobectomia. Na anatomia típica do pulmão humano, existem cinco divisões distintas, denominadas de lobos e os limites destes são determinados por fissuras, surgindo a necessidade de identificá-las (KUMAR.; KAVITHA, 2011).

Métodos de auxílio de diagnóstico mostram-se importantes tanto do ponto de vista clínico quanto em pesquisa. Dentre os fatores que contribuem para isto, pode-se citar o aumento da precisão do diagnóstico do médico especialista à medida que aumenta o número de informações sobre o estado do paciente. Deste modo, certas doenças podem ser detectadas precocemente com a possibilidade de cura. Além disto, algumas técnicas desenvolvidas permitem que o quadro clínico evolutivo da doença seja devidamente acompanhado pelo médico especialista (FELIX *et al.*, 2007; LIANG *et al.*, 2008b).

Na Engenharia Biomédica, técnicas de Processamento de Imagens Digitais são aplicadas em imagens médicas, como é o caso do exame de Tomografia Computadorizada (TC), desenvolvida por Hounsfield (KAK; SLANEY, 1999). Estas técnicas foram aplicadas, inicialmente, para medir a densidade radiográfica de forma precisa, e posteriormente, para quantificá-la, auxiliando especialistas no diagnóstico (DRUMMOND, 1998; ARIYÜREK *et al.*,

2001). As principais vantagens dos exames de TC, em relação aos outros tipos de exames, estão relacionadas com o menor tempo dos diagnósticos; detalhar imagens inalcançáveis à percepção natural da visão humana; aumentar a confiabilidade nas análises realizadas e proporcionar, aos cirurgiões, uma maior segurança quanto aos procedimentos (HEIDJEN, 1995; CAVALCANTE, a).

Pesquisas em tecnologias de imagens digitais implicaram em um crescimento de inúmeras formas de adquiri-las nos últimos anos, com a tendência recente de armazenar imagem e utilizar sistemas de comunicação em todos os hospitais. Estes sistemas estão relacionando os domínios especialidades médicas como radiologia, citopatologia, oftalmologia, gastroenterologia, etc, além de existir inúmeros banco de dados de imagens para essas especialidades (SHARMA; SUNGHEETHA, 2017; CHEN *et al.*, 2012).

Para atender estas necessidades, tipos diferentes de imagens médicas são processadas com algoritmos computacionais. Tais imagens médicas são representações visuais do interior de um corpo para análise clínica e apresenta informação de várias partes do corpo. O processamento destas imagens pode criar uma base de dados para anatomias e fisiologias normais, para que se possa identificá-las e que desempenham um papel importante nas áreas de diagnóstico, clínica, pesquisa e ensino relacionados à medicina (SHARMA; SUNGHEETHA, 2017; BESSA *et al.*, 2015).

Os sistemas de Visão Computacional são definidos sendo sistemas computacionais capazes de adquirir, processar e interpretar informações em imagens de cenas reais (CAVALCANTI NETO *et al.*, 2010; CAVALCANTI NETO *et al.*, 2015). A primeira etapa em um sistema de visão é a aquisição da imagem. A segunda etapa consiste no pré-processamento, no qual a imagem passa por uma filtragem de ruído e correção de distorções (MARCHAND-MAILLET; SHARAIHA, 2000; MARSHALL; MARTIN, 1992; MCANDREW, 2004). A terceira etapa é a segmentação da imagem em que passa por um processo de divisão em regiões ou partes homogêneas que podem representar um ou mais objetos de interesse, de acordo com algum critério de uniformidade (NASCIMENTO; CARNEIRO, 2017; BESSA *et al.*, 2015; DESHMUKH *et al.*, 2016). No entanto, esta tarefa ainda é complexa para sistemas computacionais, tendo como foco superar adversidades contidas nas imagens de diversas maneiras, como intensidade (CHABRIER *et al.*, 2004), bordas (RAZALI *et al.*, 2014), contornos (FARHANGI *et al.*, 2017) e textura de nível de cinza (GAO *et al.*, 2016; YUSHKEVICH; GERIG, 2017; MARSOUSI *et al.*, 2017; NI; WU, 2017).

A partir da região de interesse, obtida na etapa de segmentação, extraem-se os atributos que são utilizados na etapa de reconhecimento por algoritmo de classificação. Esta etapa é constituída pelos extratores de características: tom de cinza (HEIDJEN, 1995), posição (HUANG *et al.*, 2004), gradiente (BANON; BARREIRA, 1998), informações de textura (KASHYAP; KHOTANZAD, 1986), dentre outros. Por fim, no caso de análise de imagens, é gerado um relatório com as análises e informações obtidas (NIBLACK, 1986).

Dentre as etapas do sistema de VC, a etapa de segmentação é o foco quando se aborda o processamento de imagens médicas. A finalidade da etapa de segmentação em imagens médicas é destacar estruturas do corpo em uma faixa de Unidade de Hounsfield de interesse. Os resultados produzidos nesta etapa podem ser utilizados na melhor visualização das imagens, bem como no cálculo de medidas quantitativas. Além disso, a segmentação 3D deste tipo de imagens permite a reconstrução e visualização da estrutura segmentada a partir de diferentes ângulos e perspectivas, aproximando-se da real visualização. Alguns métodos de segmentação utilizam algoritmos como limiares, análise de componentes conectados e modelos ativos, dentre outros (CAVALCANTE, b).

Diversos trabalhos têm sido desenvolvidos pelo Grupo de Pesquisa em Engenharia Biomédica e Sistemas de Auxílio ao Diagnóstico Médico com sede no LESC/UFC dentre os quais se destacam Félix () apresenta um Método de Contorno Ativo baseado na transformada Hilbert 2D para realizar a segmentação dos pulmões em imagens de tomografia computadorizada (TC) do tórax, e Felix *et al.* (2012) uma inicialização automática para Métodos Contornos Ativos (MCA) aplicados à segmentação dos pulmões. Já REBOUÇAS FILHO (2010), utilizando análise de densidades pulmonares (ADP), também apresentam um MCA para segmentação dos pulmões em imagens de TC; Alexandria (2011) criam o Psnakes, método de contornos ativos para segmentação do ventrículo esquerdo em imagens de ultra-som. Cavalcante (a) utilizam MCA com ADP para realizar segmentação 2D de vias aéreas em imagens de TC, enquanto (REBOUÇAS FILHO *et al.*, 2013) cria o MCA Crisp Adaptativo 2D para segmentar os pulmões ainda em imagens de TC. REBOUÇAS FILHO (2013) apresenta um Método de Contornos Ativos baseados em Redes Neurais Artificiais e nas densidades radiológicas dos pulmões para a segmentação 3D de pulmões em imagens de TC. Cavalcante (b) apresenta um Método de Superfícies Ativas para malhas estruturadas e não estruturadas com o objetivo de segmentação de pulmões e lobos pulmonares.

Em relação aos trabalhos já publicados existem os que são focados na inicialização

de pulmão, outros que são aplicados à segmentação em imagens de ultrassom, segmentação de pulmão 2D e 3D. No entanto, não se encontra na literatura pesquisada, um método de segmentação 3D baseados em autômatos 3D que utiliza uma composição de forças no espaço RGB para realizar a segmentação de estruturas diversas de forma simultânea em imagens, inclusive em imagens de Tomografia Computadorizada.

## 1.1 Objetivos

O objetivo principal desta tese consiste em desenvolver e avaliar um método de segmentação de estruturas em 3D baseado em autômatos, capaz de realizar uma segmentação 3D automática de pulmões em imagens de TC do tórax.

### 1.1.1 *Objetivos Específicos*

Durante o desenvolvimento desta tese outros objetivos devem ser alcançados:

- criar um banco de dados com imagens sintéticas para testar a técnica desenvolvida;
- aplicar e avaliar o desempenho do método 3D com as imagens sintéticas
- propor e avaliar um método de inicialização automática para o método de segmentação 3D proposto;
- aplicar e avaliar o método com a inicialização na segmentação dos pulmões em imagens de TC;
- avaliar os resultados junto aos especialistas.

## 1.2 Contribuições

As principais contribuições desta tese são propostas de:

- método de segmentação baseado em autômatos 3D;
- método de segmentação de mais de uma estrutura 3D em uma imagem de forma simultânea;
- forças para método de segmentação 3D baseado em composição de forças no espaço RGB: filtragem gaussiana, realce e filtragem LBP;
- comparação com métodos da literatura;
- método de inicialização automática para segmentação de pulmões.

### 1.3 Produção Científica

Seguem as produções científicas realizadas na área de segmentação de imagens durante o desenvolvimento desta pesquisa.

- Trabalhos publicados em periódicos:
  - CAVALCANTI NETO, E.; CORTEZ, PAULO ; RODRIGUES, VALBERTO ; CAVALCANTE, TARIQUE; VALENTE, IGOR . 3D AUTOCUT: a 3D segmentation algorithm based on cellular automaton. ELECTRONICS LETTERS (ONLINE), v. 1, p. 1, 2017.
  - CAVALCANTI NETO, E.; CORTEZ, PAULO CÉSAR; CAVALCANTE, T. S.; SILVA FILHO, V.E.R.; HOLANDA, M. A.; Segmentação de Fissura 3D em imagens de TC baseadas em Texturas. Revista IEEE América Latina, v. 14, 2016.
- Trabalhos publicados em eventos científicos:
  - CAVALCANTI NETO, EDSON; CESAR CORTEZ, PAULO ; ENOC RODRIGUES, VALBERTO ; CAVALCANTE, T. S. . Análise Comparativa da janela LBP para segmentação de Fissuras Pulmonares. In: XIII Workshop de Visão Computacional, 2017, Natal. XIII Workshop de Visão Computacional, 2017.
  - SILVA FILHO, V. R. ; CORTEZ, P. C. ; MACIEL, T. F. ; Neto, Edson Cavalcanti ; CAVALCANTE, T. S. . SEGMENTAÇÃO SEMIAUTOMÁTICA DO PULMÃO EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA UTILIZANDO A TÉCNICA GROWCUT. In: XXV Congresso Brasileiro de Engenharia Biomédica, 2016, Foz do Iguaçu. XXV Congresso Brasileiro de Engenharia Biomédica, 2016.
  - REBOUCAS FILHO, P. P.R. ; SILVA FILHO, V. R. ; CORTEZ, P. C. ; Neto, E. Cavalcanti ; REBOUCAS, E. S. . Avaliação de técnicas de Processamento Digital de Imagens na segmentação dos pulmões em imagens de Tomografia Computadorizada do Tórax. In: 7º Simpósio de Instrumentação e Imagens Médicas (SIIM) / 6º Simpósio de Processamento de Sinais da UNICAMP, 2015, Campinas. 7º Simpósio de Instrumentação e Imagens Médicas (SIIM) / 6º Simpósio de Processamento de Sinais da UNICAMP, 2015.
  - VALENTE, I. R. S. ; CORTEZ, P. C. ; CAVALCANTE, T. S. ; ANSELMO, F. J. M. ; Neto, E. Cavalcanti ; RIBEIRO, A. B. N. ; SILVA FILHO, V. R. ; HOLANDA, M. A. . LISA - Lung Image System Analysis. In: 7º Simpósio de Instrumentação e Imagens Médicas (SIIM) / 6º Simpósio de Processamento de Sinais da UNICAMP,

2015, Campinas. 7º Simpósio de Instrumentação e Imagens Médicas (SIIM) / 6º Simpósio de Processamento de Sinais da UNICAMP, 2015.

- Patentes depositadas:
  - Neto, E. Cavalcanti; SILVEIRA CAVALCANTE, TARIQUE ; ENOC RODRIGUES, VALBERTO ; RIBEIRO, A. B. N. ; ALMEIDA, T. M. ; VALENTE, I. R. S. . 3D AUTOCUT - NOVA TÉCNICA DE SEGMENTAÇÃO DE ESTRUTURAS 3D EM IMAGENS DIGITAIS. 2017, Brasil. Patente: Privilégio de Inovação. Número do registro: BR1020170154696, título: "3D AUTOCUT - NOVA TÉCNICA DE SEGMENTAÇÃO DE ESTRUTURAS 3D EM IMAGENS DIGITAIS", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial, Depositante (s): Paulo Cesar Cortez;Universidade Federal do Ceará, Depósito: 19/07/2017
  - Neto, E. Cavalcanti; CAVALCANTE, T. S. ; VALENTE, I. R. S. ; HOLANDA, M. A. ; ALMEIDA, T. M. ; NOGUEIRA, I. C. ; SILVA FILHO, V. R. ; RIBEIRO, A. B. N. . Método de inicialização automática de sementes para o algoritmo de segmentação 3D Growcut. 2017, Brasil. Patente: Privilégio de Inovação. Número do registro: BR1020170274179, título: "Método de inicialização automática de sementes para o algoritmo de segmentação 3D Growcut", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial, Depositante (s): Paulo Cesar Cortez;Universidade Federal do Ceará, Depósito PCT: 19/12/2017
  - CAVALCANTE, T. S. ; FELIX, J. H. S. ; HOLANDA, M. A. ; CAVALCANTI NETO, E. ; SILVA FILHO, V. R. ; RIBEIRO, A. B. N. ; ALMEIDA, T. M. ; NOGUEIRA, I. C. . Inicialização Automática de Modelos Ativos 3D para Segmentação Lobar em Imagens de TC do Tórax. 2015, Brasil. Patente: Privilégio de Inovação. Número do registro: BR1020150297688, título: "Inicialização Automática de Modelos Ativos 3D para Segmentação Lobar em Imagens de TC do Tórax", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial, Depositante (s): Paulo Cesar Cortez;Universidade Federal do Ceará, Depósito: 27/11/2015

#### **1.4 Organização do Trabalho**

Esta tese está organizada em cinco Capítulos. No Capítulo 2, inicialmente são descritas as características das estruturas dos pulmões em imagens TC, bem como são apresentados os conceitos e o estado da arte de algoritmos de segmentação 3D. Além disso, ainda no mesmo

Capítulo, é apresentado o estado da arte de algoritmos de segmentação relevantes à esta tese. No Capítulo 3 é descrita a metodologia proposta para realizar a segmentação automática de estruturas pulmonares em imagens de TC do Tórax, bem como são destacadas e detalhadas as contribuições deste trabalho e os procedimentos para avaliação da metodologia proposta. No Capítulo 4, por sua vez, são apresentados e discutidos os resultados dos testes realizados, em imagens sintéticas e em exames de TC para validar o método proposto. Por fim, no Capítulo 5, são apresentadas as conclusões, contribuições, considerações e trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo, inicialmente são apresentadas características dos pulmões e suas estruturas em imagens médicas de TC. Em seguida, é descrito um estudo contendo conceitos, características, estruturas e composição de métodos de filtragem, realce e segmentação aplicados às imagens digitais. Por fim é apresentado o estado da arte dos algoritmos de segmentação de estruturas 3D.

### 2.1 Imagens Médicas

De um modo geral, imageologia médica refere-se ao processo que envolve instrumentação e técnicas especializadas para criar imagens ou obter informações relevantes sobre as estruturas biológicas internas e funções do corpo. No ambiente clínico, imagens médicas de um órgão ou parte específica do corpo são obtidas por exame de imagens para diagnóstico de uma doença. No entanto, exames de imagens médicas também são realizados para obter informações sobre estudos anatômicos e estruturas funcionais para fins de diagnóstico e pesquisa, comparando assim o estado de um paciente sadio com o paciente em estudo que possui alguma patologia.

De um ponto de vista científico, a obtenção e o estudo de imagens médicas são multidisciplinares e interdisciplinares com uma ampla cobertura nas áreas de física, biologia, engenharia e ciências médicas. A tecnologia na área médica exige o envolvimento direto de conhecimentos em física, química, biologia, matemática, engenharias e medicina, de forma que procedimentos úteis e protocolos para exames de imagem médica com instrumentação adequada possam ser desenvolvidos (DHAWAN *et al.*, 2008).

Essas imagens contêm informações sobre a estrutura anatômica específica (um órgão ou tecido) utilizando uma propriedade característica intrínseca de cada órgão ou tecido contidas na imagem. Por exemplo, na radiografia, mamografia e TC, a densidade do tecido é a propriedade característica que é exibida nas imagens para ilustrar as estruturas anatômicas. A informação sobre a densidade do tecido de estruturas anatômicas é obtida através da medição da atenuação de energia de raios X, quando ela é transmitida através do corpo (DHAWAN *et al.*, 2008; RITTER *et al.*, 2011).

De acordo com Hendee e Ritenour (2002), seis grandes desenvolvimentos estão convergindo para elevar a influência da área de análise de imagens biomédicas, que são:

- crescente sofisticação das questões biológicas que podem ser abordadas como a expansão do conhecimento em crescente compreensão sobre a complexidade do corpo humano e suas propriedades estáticas e dinâmicas;
- evolução constante das tecnologias relacionadas à imagem e o crescente aperfeiçoamento das questões que essas tecnologias podem atender em níveis cada vez mais fundamentais;
- aceleração dos avanços na tecnologia de computadores e redes de informação que suportam os avanços na área de imagem, como por exemplo a representação de três e quatro dimensões, superposição de imagens de diferentes dispositivos, criação de ambientes de realidade virtual e transporte de imagens para sites remotos em tempo real;
- o crescimento da quantidade de informações sobre os pacientes que podem ser comprimidas e melhor expressas através da utilização de imagens; e
- entrada em pesquisa e clínica médica de jovens que possuem facilidade com tecnologias de informática e aptidão com imagens como o principal caminho para a aquisição e exibição de informações.

O processo básico de formação de uma imagem requer uma fonte de energia para se obter a informação acerca do objeto de interesse presente na imagem. Alguma forma de radiação como a luz, raios X, raios gama, RF ou ondas acústicas, interagem com o objeto tecido ou órgão para fornecer informações sobre a sua propriedade característica. A fonte de energia pode ser externa (radiografia de raios X, mamografia, tomografia computadorizada, ultra-som), interna (medicina nuclear; tomografia de emissão de fóton único-SPECT. A tomografia de emissão de pósitrons (PET), ou uma combinação de ambas internas e externas, tal como em imagiologia de ressonância magnética. padrão *Digital Imaging and Communications in Medicine* (DICOM), criado em 1985 com o nome de ARC-NEMA 300-1985, descreve a formatação de imagens médicas com informações associadas a mesma, dirigidas aos mecanismos de operação da interface utilizadas para transferir dados entre determinado dispositivo de imagens e redes (CAVALCANTE, a; NEMA, 2014; CHO *et al.*, 1993; FELIX, ).

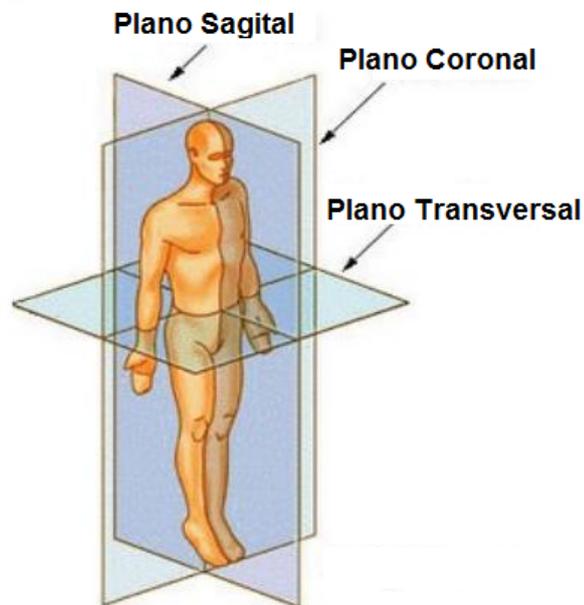
O padrão DICOM, atualizado em 2014, é disponibilizado pelo *American College of Radiology - National Electrical Manufacturers Association* (ACR-NEMA) e engloba informações sobre o aparelho em utilização, descreve com detalhes dados do paciente como nome, idade e sexo, e dados das imagens, como *frames*, modalidades, formatos (de armazenamento, visualização e impressão), dimensões, tipo de compressão, espessura da fatia de corte dentre outros. Este padrão é utilizado por diversos fabricantes de equipamentos médicos inclusive

equipamentos de raios-X, ultrassonografia e Tomografia Computadorizada. (NEMA, 2014).

O exame de TC foi desenvolvido por Hounsfield (1973), com o objetivo de visualizar as estruturas internas dos órgãos do corpo humano, como por exemplo, o pulmão e suas estruturas. Deste modo, o tomógrafo, equipamento utilizado para realizar a TC, é capaz de adquirir imagens destes órgãos para que o médico possa realizar a detecção, bem como o acompanhamento clínico de doenças (STERN; SWENSEN, 2001).

A imagem digital resultante de um exame de TC é composta por *pixels*, na qual o valor de cada *pixel* corresponde à atenuação da intensidade dos raios X, expressa em Unidades Hounsfield (UH). A escala da intensidade de atenuação tem valores específicos para cada tecido ou estrutura do corpo humano. Por exemplo, o tecido ósseo está entre 600 e 2000 UH (WEBB *et al.*, 2001). Além disso, uma imagem de TC do corpo humano pode ser obtida em três planos diferentes denominados de Sagital, Coronal e Transversal. É possível observar a ilustração dos planos do corpo humano na Figura 1.

Figura 1 – imagens do corpo humano nas secções transversal, coronal e sagittal.



Fonte – Dhawan *et al.* (2008).

O coeficiente de atenuação ou absorção quantifica a tendência de um corpo absorver os raios X e é definido por (EPSTEIN, 2003; MAHESH, 2002)

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

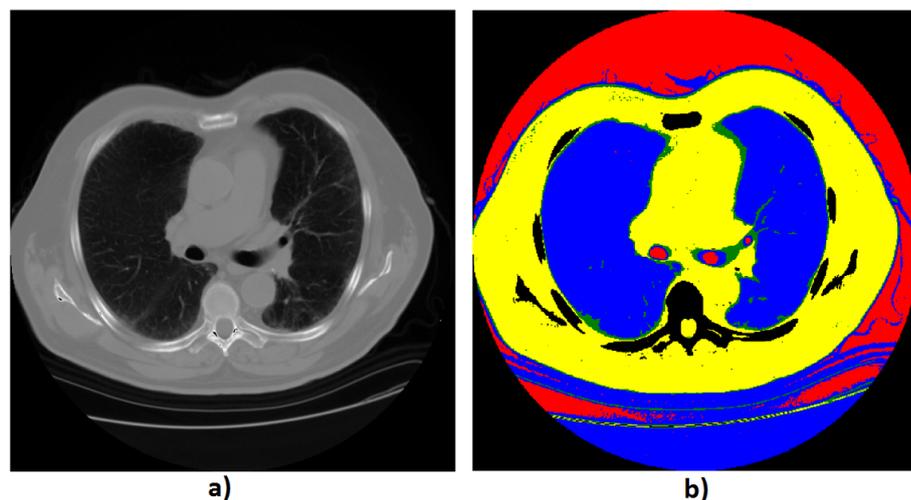
em que  $\mu_{\text{tecido}}$  é o valor do coeficiente de absorção, de um determinado tecido do corpo e  $\mu_{\text{água}}$  o análogo para a água.

A imagem de TC tipicamente é utilizada em escala de 16 *bits*, porém na prática os valores obtidos estão entre -3000 a 1000UH. Para os pulmões, as suas estruturas se encontram na faixa de -1000 a 100UH (SLUIMER *et al.*, 2005; SUAPANG *et al.*, 2010). Assim, esta faixa pode ser subdividida de forma a possibilitar uma melhor identificação e caracterização das estruturas pulmonares. De acordo com Gevenois e Yernault (1995), as faixas de densidades podem ser caracterizadas da seguinte forma:

- de -1000 a -900 UH para áreas hiperaeradas;
- de -900 a -500 UH para áreas normalmente aeradas;
- de -500 a -100 UH para áreas pouco aeradas; e
- de -100 a 100 UH para áreas não aeradas.

É possível observar na Figura 2 (a) a imagem original de TC e na Figura 2 (b) a representação das faixas de densidade na forma de cores, em que vermelho representa regiões hiperaeradas, azul as áreas normalmente aeradas, verde as áreas pouco aeradas, amarelo representa as áreas não aeradas e preto as áreas não-classificadas (CAVALCANTE, a; RITTER *et al.*, 2011).

Figura 2 – a) imagem original de TC, b) representação do exame de TC pelas faixas de densidade.



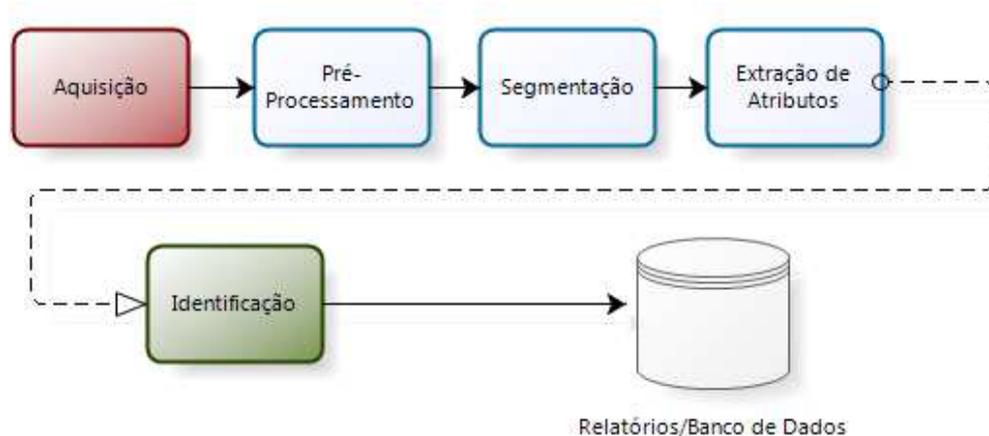
Fonte – Cavalcante (a)

## 2.2 Sistema de Visão Computacional

Um sistema de Visão Computacional (VC) típico é constituído por processos capazes de adquirir, processar e interpretar imagens referente a cenas de ambientes reais. Tais processos

são relacionados com a aquisição de imagens, pré-processamento, segmentação, identificação e a saída que pode ser uma geração de relatórios, ou interpretação de resultados (GONZALEZ *et al.*, 2009). Um fluxograma de um sistema típico de VC pode ser observado na Figura 3.

Figura 3 – Sistema de visão computacional típico.



Fonte – CAVALCANTI NETO *et al.* (2015)

A primeira etapa consiste na aquisição das imagens, que está relacionada com a obtenção das imagens através de câmeras de vídeos, máquina fotográfica digital, *scanner*. Já para obtenção de imagens médicas são utilizados equipamentos de raios-X, doppler, TC, ressonância magnética, dentre outros (HEIDJEN, 1995).

A maioria das imagens são afetadas até certo ponto por ruído, que são distúrbios na intensidade da imagem que são ou não interceptáveis. A análise da imagem são as vezes simplificadas se esse ruído for filtrado (HAYASHIBE *et al.*, 2006).

De maneira análoga, os filtros são usados em química para libertar líquidos de impurezas suspensas, passando-os através de uma camada de areia ou carvão. Os engenheiros que trabalham no processamento de sinais ampliaram o significado do filtro de termo para incluir operações que acentuam características de interesse em dados. Empregando esta definição mais ampla, filtros de imagem, pode ser usada para enfatizar bordas - isto é, limites entre objetos ou partes de objetos em imagens (YAMAGUCHI *et al.*, 2015).

Em seguida tem-se o pré-processamento que possui a finalidade de melhorar as características relevantes da imagem, ou seja, minimizar a presença de ruído, realizar realce de forma a evidenciar as características da imagem (ZHAO; PIETIKAINEN, 2007; ZRIMEC; BUSAYARAT, 2004; SHIH; WU, 2004).

Na sequência, a segmentação que pode variar de acordo com as características de

aplicação: detecção de descontinuidades e/ou similaridades de áreas ou regiões da imagem. O objetivo principal da segmentação é separar o objeto de interesse (WANG *et al.*, 2016; BURGER; BURGE, 2007; DOUGHERTY, 2009; EL-BAZ *et al.*, 2006; EVERHART *et al.*, 1994).

Após a segmentação, ocorre a extração de atributos que tem por finalidade agrupar as informações com características semelhantes em área distintas, ou seja, identificar os atributos ou feições que melhor representem as características desejadas dos objetos segmentados. Nesta etapa, podem ser utilizadas técnicas como: histograma LBP, aproximação poligonal, descritores de Fourier, texturas de Haralick, dentre outras (GAO *et al.*, 2016; JUNIOR *et al.*, 2013; GUO *et al.*, 2010; CAVALCANTE, b; JAIN, 1989; MARCHAND-MAILLET; SHARAIHA, 2000).

Tem-se subsequente à segmentação, o reconhecimento e identificação do objeto em análise que é a etapa de classificação. A classificação consiste em rotular os objetos identificados a partir dos atributos obtidos no processo anterior. Estes objetos, são então identificados para um grupo ou classe, de acordo com informações *a priori*, destes objetos, identificados pelos seus atributos que podem ser utilizadas técnicas de reconhecimento de padrões, inteligência artificial, estatística, dentre outros (MOHAMMED *et al.*, 2011; NATO *et al.*, 2000; POPE *et al.*, 1985; SABINO *et al.*, 2004; TRIER *et al.*, 1996; WEBB, 2002; WIDROW; WINTER, 1988). Por fim, essas informações podem ser utilizadas para gerar relatórios gerenciais, relatórios de exames, ou até mesmo armazenar as informações geradas para posterior análise.

### **2.2.1 Realce de imagens**

Métodos de realce de imagens digitais vêm sendo desenvolvidos em busca de melhorar cada vez mais o contraste visual, principalmente em imagens que possuem problemas de iluminação e ruído. Seu estudo é importante, tanto para utilização de diversas aplicações, quanto para outras áreas como: análise de imagens médicas (GUAN *et al.*, 2015; OMER *et al.*, 2015; HUANG; CHEN, 2014), imagens microscópicas (HADHOUD; ATTA, 2000; HARGAS *et al.*, 2010; WICKRAMASINGHE; HEISERMAN, 1977), imagens de alta resolução de televisões (KIM, 1997; ZAFARIFAR *et al.*, 2013; ZAFARIFAR *et al.*, 2010; LI *et al.*, 2014), processamento de imagens de raio-x industrial (FLOREA; VERTAN, 2007), sistemas de segurança (GONGE; GHATOL, 2017; AL-HAJ; ABDEL-NABI, 2017), etc.

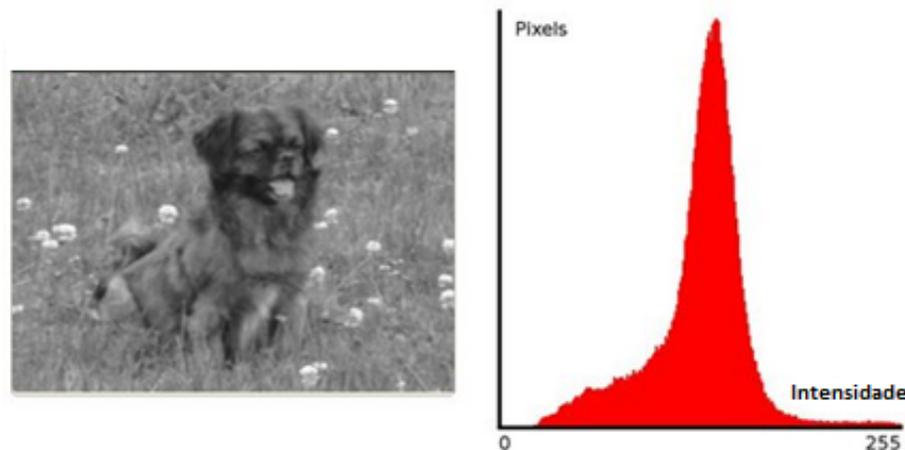
Um método popular de realce de imagens é a equalização de histograma (EH) que consiste em uma função de mapeamento baseado na Função de Distribuição Acumulada (CDF, *Cumulative Distribution Function*) a qual modifica os valores dos *pixels* da imagem de entrada,

obtendo uma imagem de saída com os valores do histograma próximos a uma distribuição uniforme, realçando assim a imagem (GONZALEZ *et al.*, 2009). Entretanto, esta abordagem possui alguns problemas de sobre-realce como a preservação de brilho (WANG; YE, 2005; IBRAHIM; KONG, 2007) e a limitação de contraste (REZA, 2004; SANTOS *et al.*, 2015).

O histograma de uma imagem digital é uma função  $h(k) = n_k$ , em que  $k$  é um nível de intensidade de luminância (geralmente entre 0 e 255 para imagens digitais) e  $n_k$  é o número de *pixels* na imagem com nível de intensidade de luminância  $k$ . O histograma pode ser normalizado, dividindo cada valor pelo tamanho da imagem.

Histogramas são a base para várias técnicas de processamento de imagem, incluindo o realce de imagem. Com base neste, o método de Equalização de Histograma (EH) é usado para realçar uma imagem através da distribuição das intensidades dos *pixels* em todo o histograma, melhorando o contraste em uma imagem, a fim de melhor distribuir os níveis de cinza ao longo do alcance da intensidade.

Figura 4 – Histograma de imagem com baixo contraste.



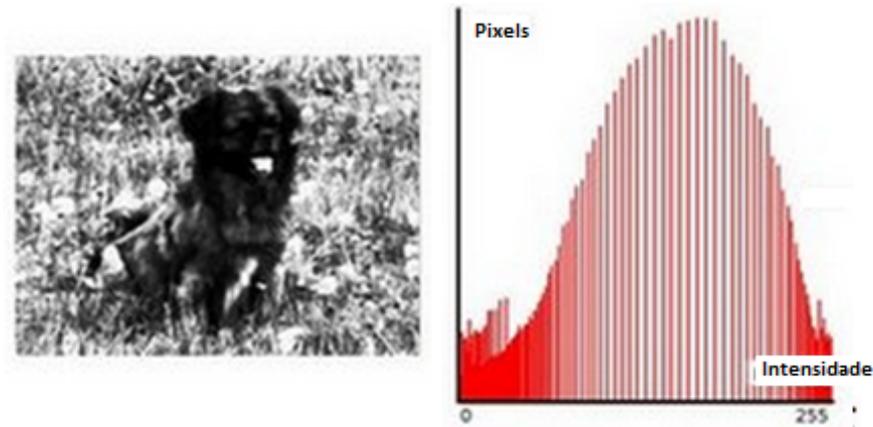
Fonte – Autor.

Como pode ser observado na Figura 4, os *pixels* da imagem original estão concentrados em torno do meio do histograma. Quando é aplicado a EH na imagem, o histograma da imagem do resultante possui distribuição mais uniforme dos níveis de cinza, ver Figura 5.

O algoritmo proposto por Abdullah-Al-Wadud *et al.* (2007) divide o histograma de imagem com base em mínimos locais e atribui intervalos de níveis de cinza específicos para cada partição antes de igualá-los separadamente. Este método melhora o contraste sem introduzir artefatos ou efeitos indesejáveis.

Este algoritmo de equalização de histograma da imagem possui base no mínimo

Figura 5 – Histograma de imagem com o histograma equalizado.



Fonte – Autor.

local e atribui intervalos de nível de cinza específicos para cada partição antes de equalizá-los separadamente. Essas partições ainda passam por um teste de particionamento para garantir a ausência de quaisquer partes dominantes.

Poddar *et al.* (2013) propõem um algoritmo de aprimoramento de contraste de imagem baseado em EH que é independente da configuração de parâmetros. Além do aprimoramento do contraste, duas variantes da metodologia proposta são apresentadas, uma das quais preserva o brilho da imagem original enquanto a outra variante aumenta o brilho da imagem de forma adaptável, apresentando um melhor contraste.

Na mesma direção, Kim *et al.* (2009) propõem um algoritmo baseado em segmentação e controle de curva de tom para uma TV LCD. Este método é específico para monitores LCD e uma das principais preocupações é o custo computacional, uma vez que o método tem de funcionar em TVs em tempo real. O algoritmo consiste em dois processos: segmentação da imagem e controle da curva de tom.

Outro algoritmo é proposto por Wang *et al.* (2008) que usa uma técnica rápida de geração de recursos locais para estabelecer um histograma combinado que represente os meios locais dos *voxels* e os níveis de cinza. Diferentes seções do histograma combinado, separadas por picos individuais, são mapeadas de forma independente na escala de histograma sob a restrição de que o histograma geral final deve ser o mais uniforme possível.

Ainda com base em histograma, Sengee *et al.* (2009) propõe um novo método chamado "Weight Clustering Histogram Equalization"(WCHE) que atribui cada lote diferente do do histograma inicial da imagem original a um *cluster* separado e calcula o peso de cada *cluster*. Então, os *clusters* adquirem as mesmas partições que o histograma de imagem de resultante.

Finalmente, as funções de transformação para o sub-histograma de cada *cluster* são calculadas com base no método EH tradicional nas novas partições adquiridas do histograma de imagem de resultado, já os níveis de cinza do sub-histograma são mapeados para a imagem de resultado pelas funções de transformação correspondentes.

Desta forma, nesta tese é utilizado o algoritmo de Abdullah-Al-Wadud *et al.* (2007) com o objetivo de realizar a equalização do histograma da imagem a ser segmentada.

### 2.2.2 *Local Binary Patterns - LBP*

*Local Binary Pattern* (LBP) é um algoritmo de textura, que possui uma característica de possuir baixa influência em termos de variações da escala de cinza, uma vez que o operador é, por definição, invariante contra qualquer transformação monótona da escala de cinza. Além disso, é computacionalmente simples e pode ser realizado com um baixo número de operações em uma pequena área e uma tabela de pesquisa (OJALA *et al.*, 2002).

O operador LBP permite detectar padrões binários locais uniformes em vizinhanças circulares de qualquer quantização do espaço angular e em qualquer resolução espacial. é definido para um caso geral, com base em um conjunto circularmente simétrico de membros vizinhos  $P$  em um círculo de raio  $R$ ,  $LBP_{P,R}^{riu2}$ , em que  $P$  é o parâmetro que controla a quantização do espaço angular,  $R$  determina a resolução espacial do operador e  $u2$  consiste na definição de quantas transições são necessárias para que o padrão binário seja uniforme (AHONEN *et al.*, 2006).

Uma análise simples de cada *pixel* na imagem em relação a uma pequena vizinhança gera um código binário denominado de código LBP. Definindo uma vizinhança como um conjunto de pontos de amostragem igualmente espaçados, em um círculo centrado no *pixel* a ser rotulado, permite que qualquer raio e número de pontos de amostragem possam ser utilizados.

Há casos em que o ponto da amostragem não se encontra no centro de um *pixel*. Neste caso, usa-se a interpolação bi linear. Assim, para calcular o LBP são consideradas as variáveis  $P$  e  $R$  que correspondem ao número total de vizinhos envolvidos e o raio da vizinhança, respectivamente. Se as coordenadas de *pixel* central são  $(0,0)$ , então as coordenadas do *pixel* vizinho são dadas por  $(-R.\sin(2\pi/P), R.\cos(2\pi/P))$ . Para valores da intensidade de cinza dos vizinhos que não estão nas grades de imagem são calculadas por interpolação (OJALA *et al.*, 1996). Na Figura 6 é possível visualizar alguns exemplos de vizinhanças.

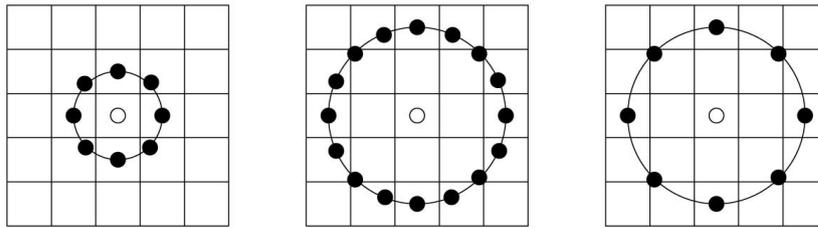


Figura 6 – exemplos de vizinhanças circulares (8,1), (16,2) e (8,2) (AHONEN *et al.*, 2006).

O operador LBP foi originalmente concebido para a descrição de textura que atribui uma etiqueta para cada *pixel* de uma imagem através da limiarização com uma janela predefinida e cada *pixel* com o valor de *pixel* central e considera o resultado como um número binário. Em seguida, o histograma dos rótulos pode ser utilizados como um descritor de textura. Na Figura 7 é ilustrado o operador básico LBP.

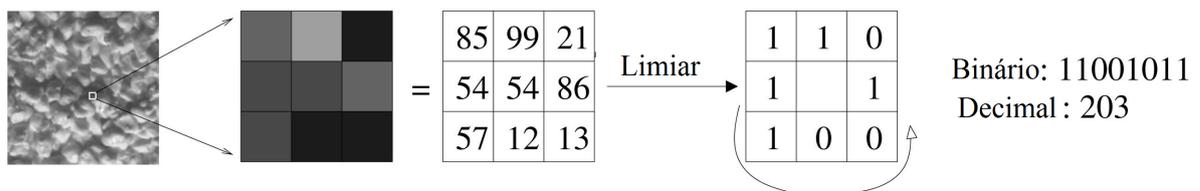


Figura 7 – operador básico LBP com vizinhança (8,1) (AHONEN *et al.*, 2006).

Outra versão para o operador é a definição dos chamados padrões uniformes. Um padrão binário local é chamado uniforme se o padrão possui, no máximo, duas transições de *bits* 0-1 ou vice-versa, quando o padrão de bits é considerado circular. Por exemplo, os padrões 00000000 (0 transições), 01110000 (2 transições) e 11001111 (2) transições são uniformes ao passo que os padrões de 11001001 (4 transições) e 01010011 (5 transições) não são uniformes.

No cálculo do histograma do LBP, os padrões uniformes são utilizados de forma que o histograma resultante possua uma posição para cada padrão uniforme e todos os padrões não uniformes são atribuídos a uma única posição. Ojala *et al.* (2002) notaram que, em seus experimentos com imagens de texturas, padrões uniformes representam um pouco menos de 90 por cento de todos os padrões ao utilizar a vizinhança (8, 1) e cerca de 70 por cento na vizinhança (16, 2). Desta forma, o código do LBP é calculado comparando o pixel com os seus vizinhos. A partir do valor do *pixel* central, a vizinhança é limiarizada em um padrão binário (GUO *et al.*,

2010), dado por

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, \quad (2.2)$$

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

em que  $g_c$  é o valor de cinza do pixel central,  $g_p$  é o valor de seus vizinhos,  $p = 0, \dots, p-1$  (OJALA *et al.*, 2002).

Após se obter o o padrão LBP de cada *pixel*, calcula-se o valor de  $U$ , definido como o número de transições espaciais, mudanças bit a bit 0/1 (GUO *et al.*, 2010)

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|. \quad (2.3)$$

Os padrões uniformes LBP referem-se aos padrões de transição que estejam limitados a  $U \leq 2$  no padrão binário (OJALA *et al.*, 2002). Neste caso, é mapeado de  $LBP_{P,R}$  para  $LBP_{P,R}^{u^2}$ . O subscrito  $u^2$  significa um padrão uniforme com ( $U \leq 2$ ) e que possui  $P(P-1) + 3$  padrões distintos que são uniformes.

Finalmente, o histograma  $H(k)$  é construído para representar a imagem de textura (KUANG *et al.*, 2018)

$$H(k) = \sum_{i=1}^I \sum_{j=1}^J f(LBP_{P,R}(i, j), k), k \in [0, K], \quad (2.4)$$

$$f(x, y) = \begin{cases} 1, & x = y, \\ 0, & \text{caso contrário,} \end{cases}$$

em que  $K$  é o valor máximo padrão do LBP,  $i$  e  $j$  são as dimensões da imagem e  $f(x, y)$  é o resultado da imagem após a transformação.

### 2.2.3 Segmentação de Imagens

A segmentação é a etapa que separa as regiões de interesse na imagem (CAVALCANTI NETO *et al.*, 2010; CAVALCANTI NETO *et al.*, 2015), destacando-as das demais regiões da imagem.

A segmentação de imagens é um campo amplo e ativo, não só na imageologia médica, mas também em visão computacional e imagens de satélite. Sua finalidade é dividir uma imagem em regiões que são significativas para uma determinada tarefa. Vários métodos e abordagens são utilizadas; a escolha de um método particular depende das características do problema a ser resolvido e o seu local onde deve ser aplicado. A segmentação é um passo essencial antes da descrição, o reconhecimento ou a classificação de uma imagem ou de seus constituintes (JAIN, 1989; DOUGHERTY, 2009).

Existem duas abordagens principais - métodos baseados na região, nos quais são detectadas as semelhanças; entre regiões e métodos baseados na fronteira, que se baseiam nas discontinuidades da imagem para formar limites em torno das regiões. A fim de desenvolver sistemas de interpretação robustos, é importante utilizar uma quantidade de informações relevantes antes da segmentação (CHO *et al.*, 1993).

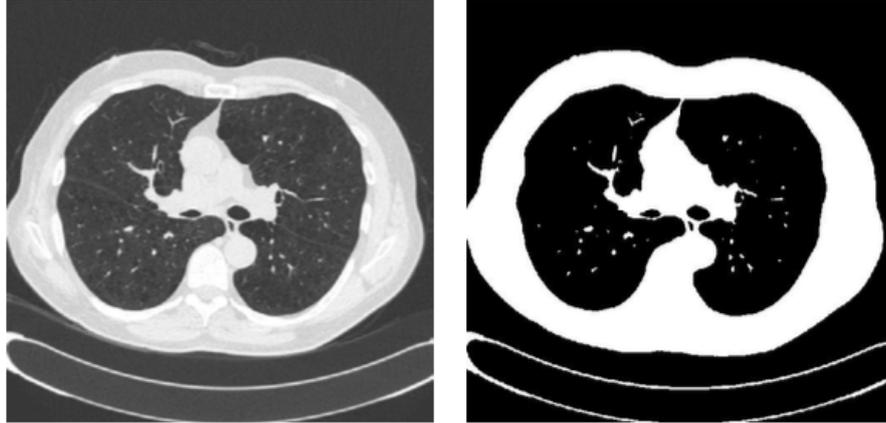
As técnicas de segmentação por similaridade baseiam-se na extração de objetos com características próximo de uma propriedade ou valor pré-definido. Dentre os métodos que integram este tipo de segmentação, destacam-se a Limiarização e o Crescimento de Região.

A limiarização é uma das técnicas mais simples e populares de segmentação que consiste na classificação dos *pixels* de acordo com limiares. A técnica de limiarização possui como objetivo realçar conjuntos de *pixels* de uma imagem que ocupam a mesma faixa de níveis de cinza de forma a extrair atributos a partir desta imagem, dividindo a imagem de acordo com o objetivo do processo (GONZALEZ *et al.*, 2009). Existem alguns tipos de limiarizações como a Limiarização adaptativa de Bernsen (1986), Limiarização adaptativa da média criada por Glasbey (1993), Limiarização adaptativa de Niblack (1986) e Limiarização adaptativa derivada do histograma criada por Pratt (2007). Desta forma, determina-se um valor, limiar, no qual a imagem em análise é percorrida e caso o valor do *pixel*  $f(x,y)$  atual seja menor do que o valor do limiar, recebe um valor mínimo. Caso seja maior, recebe um valor máximo, no qual estes valores são determinados em cada aplicação. Existem formas de se definir este limiar, algumas adaptativas e outras fixas (MCANDREW, 2004).

O resultado da aplicação da limiarização em uma imagem de pulmão é ilustrado na

Figura 8, em que a imagem da esquerda é a imagem original e a imagem resultante é ilustrada na imagem da direita.

Figura 8 – aplicação da limiarização , a) imagem original, e b) imagem limiarizada.



Fonte – Bernsen (1986).

Já as técnicas de segmentação baseadas em descontinuidade, detectam em imagens de níveis de cinza, variações abruptas de intensidade entre um *pixel* e seus vizinhos. A maioria dessas técnicas se baseiam em uma convolução bidimensional entre uma máscara específica e uma dada imagem (YADAV *et al.*, 2016; MCANDREW, 2004).

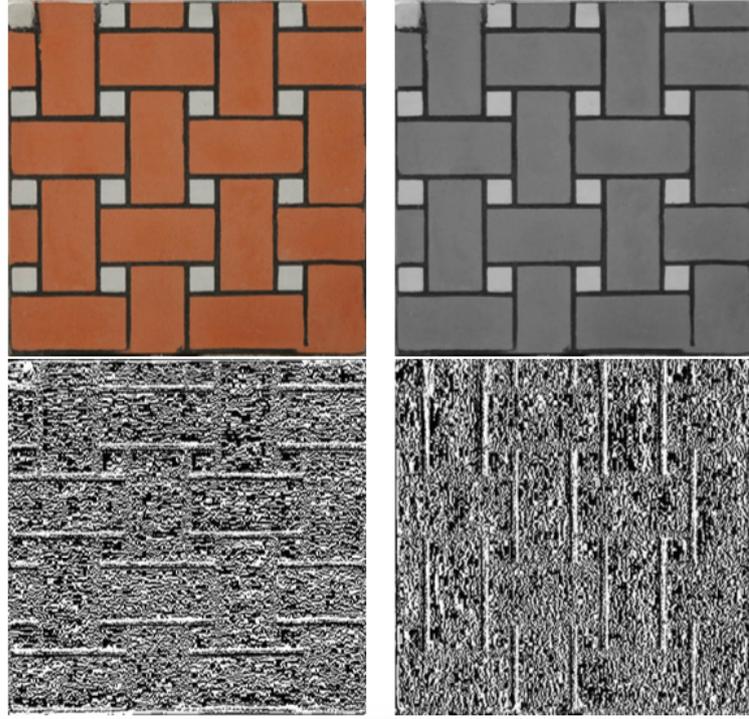
Dentre as formas de detectar as bordas de objetos em imagens, destaca-se a utilização de operadores gradiente, podendo-se citar os operadores de Roberts, Prewitt e Sobel (SIEGWART; NOURBAKHSI, 2004). Uma forma de implementar estes operadores é aplicar uma convolução bidimensional na imagem utilizando máscaras específicas.

Um exemplo de aplicação de um operador gradiente está ilustrado na Figura 9, em que a imagem original é apresentada na imagem colorida e a imagem em tom de cinza são os resultados da conversão para tom de cinza e a aplicação do filtro de detecção de borda horizontal e vertical.

#### 2.2.4 Métodos de segmentação

Nesta subsecção são descritos algoritmos da literatura com o foco a segmentação 3D. Estes algoritmos são escolhidos devido suas características de funcionamento e outros por serem estado da arte em segmentação de imagens. O primeiro artigo descrito é o GrowCut Original, o propósito de sua descrição desta subsecção é devido à sua importância no método proposto nesta tese, os outros algoritmos descritos nesta subsecção são: *Three-dimensional radial active*

Figura 9 – exemplo de aplicação do operador Sobel, a) imagem em RGB, b) imagem em tom de cinza, c) resultado do operador Sobel para identificação das linhas horizontais, e d) resultado do operador Sobel para identificação das linhas verticais.



Fonte – Autor.

*contour model* (ALMEIDA *et al.*, 2017), *Morphological Active Contours Without Edges* (CHAN; VESE, 2001), *Crescimento de Região 3D* (GONZALEZ *et al.*, 2009), *Fast level set based image segmentation using coherent propagation* (ACTON; RAY, 2009).

#### 2.2.4.1 *GrowCut Original*

Os autômatos celulares (AC) foram introduzidos por Kemeny (1967a). Desde então, utilizaram-se para modelar uma grande variedade de sistemas dinâmicos em vários domínios de aplicação, incluindo a segmentação de imagens e a detecção de bordas (POPOVICI; POPOVICI, 2002; GRADY; FUNKA-LEA, 2004). Um autômato celular é geralmente um algoritmo discreto em espaço e tempo, que opera em uma rede de espaços  $p \in P \subseteq \mathbb{Z}^n$  (*pixels* ou *voxels* no processamento de imagem).

Um autômato celular (bidirecional, determinístico) é uma tripla  $A = (S, N, \delta)$ , em que  $S$  é um conjunto de estados não vazio,  $N$  é o sistema de vizinhança e  $\delta : S^N \rightarrow S$ , em que  $S$  é a função de transição local (regra). Esta função define a regra de cálculo do estado da célula em um passo de tempo de  $t + 1$ , dado os estados das células de vizinhança no passo anterior  $t$

(PHAN; ANDROUTSOS, 2011).

Comumente, os sistemas de vizinhança  $N$  utilizam da vizinhança de Von Neumann (vizinhança-4) e Moore (Vizinhança-8) (GHOSH *et al.*, 2011):

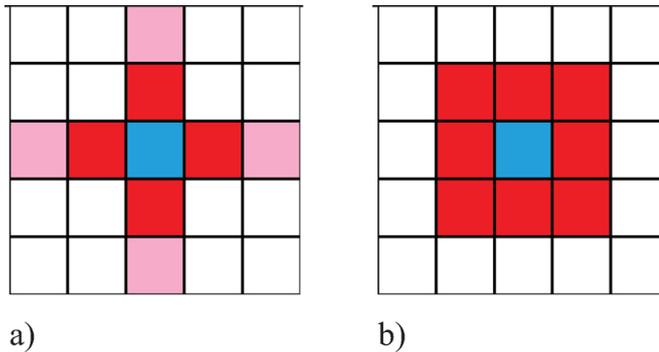
- vizinhança von Neumann

$$N(p) = \{q \in Z^n : \|p - q\|_1 := \sum_{i=1}^n |p_i - q_i| = 1\}; \quad (2.5)$$

- vizinhança Moore

$$N(p) = \{q \in Z^n : \|p - q\|_\infty := \max_{i=1,n} |p_i - q_i| = 1\}; \quad (2.6)$$

Figura 10 – a) As células vermelhas são referentes à vizinhança Von Neumann para a célula azul; b) As células são a vizinhança Moore para a célula azul.



Fonte – Elyor e Lee (2013)

É possível observar a diferença das vizinhanças Von Neumann e Moore através da Figura 10, em que a Figura 10 (a) consiste na vizinhança Von Neumann e a Figura 10 (b) consiste na vizinhança Moore (ELYOR; LEE, 2013).

O estado da célula  $S_p$  em nosso caso é uma tripla  $(l_p, \theta_p, \vec{C}_p)$ , o rótulo  $l_p$  da célula atual, 'força' da célula atual  $\theta_p$  e o vetor de característica da célula  $\vec{C}_p$ , definido pela imagem. Sem perda de generalidade, assume-se  $\theta_p \in [0; 1]$ .

Uma imagem digital é uma matriz bidimensional de  $k \times m$  pixels. Uma imagem não rotulada pode então ser considerada como um estado de configuração particular de um autômato celular, em que o espaço celular  $P$  é definido pela matriz  $k \times m$  definida pela imagem e os estados

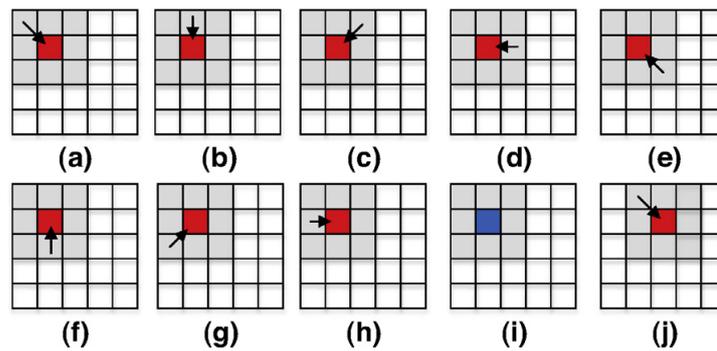
iniciais para  $\forall p \in P$  são definidos por (KEMENY, 1967b; PHAN; ANDROUTSOS, 2011)

$$\begin{aligned} l_p &= 0, \\ \theta_q &= 0, e \\ \vec{C}_p &= RGB_\rho \end{aligned} \tag{2.7}$$

em que  $RGB_\rho$  é um vetor de matriz tridimensional de  $\rho$  color dos *pixels* no espaço RGB.

Nessa técnica baseado em autômatos celulares, o usuário inicia a segmentação especificando as sementes de segmentação, os rótulos das células das sementes são definidos, enquanto sua força é ajustada para o valor da força da semente. Estas forças estão relacionadas com as informações das intensidades dos *pixels* da região.

Figura 11 – O ataque de uma célula de defesa, em vermelho, pela sua vizinhança, em cinza.



Fonte – Cordeiro *et al.* (2016)

A célula do defensor, ver Figura 11, é representada em vermelho, enquanto a sua vizinhança é ilustrada em cinza. Cada vizinho da célula do defensor tenta obter a célula do defensor. Este ataque é baseado na força de cada célula e na diferença de valores de intensidade entre o atacante e a célula do defensor. Das Figura 11 (a) até (h), é mostrado que cada vizinho ataca a célula do defensor. Quando o ataque de uma célula é bem-sucedido, domina completamente a célula do defensor, a célula do defensor possui o rótulo da célula atacante clonada, mas sua nova força é baseada na regra de atualização. Já na Figura 11 (i) é ilustrado a mudança de etiqueta da célula do defensor. Na Figura 11 (j) é ilustrado o início do processo com outra célula. Este processo é realizado com todas as células da região. Assim, a evolução das células é realizada através de iterações, nas quais cada iteração todas as células da região agem como defensores sendo atacados por sua vizinhança (CORDEIRO *et al.*, 2016).

Nesse processo iterativo, a iteração  $t + 1$ , os rótulos das células  $l_p^{t+1}$  e forças  $\theta_p^{t+1}$

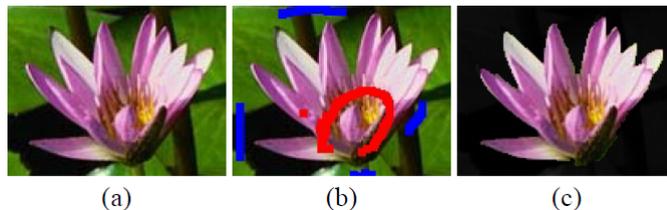
são atualizados da seguinte forma (VEZHNEVETS; L., 2005)

$$g(x) = 1 - \frac{x}{\max \|\vec{c}^n\|^2} \quad (2.8)$$

em que  $g$  é uma função de função monotônica decrescente limitada no intervalo  $[0; 1]$ .

O processo de rotulagem de *pixels* pode ser tratado, sendo o crescimento e luta pela dominação de tipos de bactérias  $K$ . As bactérias começam a se espalhar (crescer) a partir dos *pixels* da semente e tentar ocupar toda a imagem. É por isso que é chamada de método 'GrowCut'. As regras de crescimento e competição de bactérias são óbvias - em cada passo de tempo discreto, cada célula tenta "atacar" seus vizinhos. A força de ataque é definida pela força da célula atacante  $\theta_q$  e a distância entre os vetores de recurso do atacante e do defensor  $\vec{C}_q$  e  $\vec{C}_p$ . Se a força de ataque for maior que a força do defensor - a célula de defesa é "conquistada" e sua etiqueta e força são alteradas. O resultado dessas competições locais é que as bactérias mais fortes ocupam os locais vizinhos e se espalham gradualmente pela imagem (VEZHNEVETS; L., 2005).

Figura 12 – Segmentação de imagem colorida, a) imagem original, b) sementes definidas pelo usuário, c) resultado da segmentação.



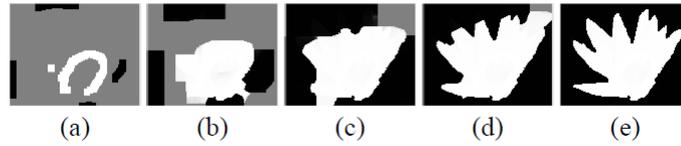
Fonte – Vezhnevets e l. (2005)

O cálculo continua até que o autômato converge para uma configuração estável, em que os estados celulares estabilizam e não mudam mais. Exemplos de segmentação de imagem são mostrados nas Figuras 12 e 13. Na Figura 12 é ilustrado a segmentação de uma imagem colorida e na Figura 13 de uma imagem em nível de cinza. O método é garantido para convergir, pois a força de cada célula é crescente e limitada.

#### 2.2.4.2 Three-dimensional radial active contour model (RAC3D)

O MCA Radial estende o conceito de duas para três dimensões. Este método trata a segmentação de um volume (3D) analisando informações 1D presentes em feixes que divergem

Figura 13 – Passos da evolução da segmentação.



Fonte – Vezhnevets e I. (2005)

de um ponto no interior do volume a ser segmentado.

Um feixe 3D  $\rho(\phi, \theta, \lambda)$  possui um terceiro parâmetro que é um ângulo adicional. Desta forma, cada feixe 3D pode ser generalizado contendo três parâmetros esféricos: seu comprimento  $\lambda$ , o ângulo  $\phi$  sendo aquele que varia em torno do eixo  $y$ , no plano  $xz$ , e o ângulo  $\theta$ , que varia ao longo do plano  $xy$  e em torno do eixo  $z$ . Estes ângulos  $\phi$  e  $\theta$  são análogos aos parâmetros de azimute e elevação no sistema de coordenadas horizontais (ALMEIDA *et al.*, 2017).

Formalmente, um feixe 3D  $\rho(\phi, \theta, \lambda)$  é definido como uma função de uma imagem  $f$  da seguinte forma, (ALMEIDA *et al.*, 2017)

$$\rho(\phi, \theta, \lambda) = f \begin{bmatrix} x_m + \lambda \text{sen}(\phi) \cos(\theta), \\ y_m + \lambda \text{sen}(\phi) \text{sen}(\theta), \\ z_m + \lambda \cos(\theta) \end{bmatrix} \quad (2.9)$$

nas quais  $(x_m, y_m, z_m)$  são as coordenadas do ponto inicial que

O conceito de energia é a principal característica dos MCAs e o único aspecto comum a todas as técnicas e variações. Essa energia atua em todos os pontos de controle na superfície em um par de ângulos  $(\phi, \theta)$ , partindo de uma origem  $m$  definida por

$$\lambda(\phi, \theta) = \underset{\lambda}{\text{argmin}} \left( - \left| \frac{\partial}{\partial \lambda} \rho(\phi, \theta, \lambda) \right|^2 \right), \quad (2.10)$$

em que *argmin* é o operador de argumento mínimo da função.

A energia total do MCA Radial 3D é a generalização da equação 2.10 é definida a

partir das novas energias internas  $E_{int}$  e externas  $E_{ext}$ :

$$E = \int_0^\pi \int_0^{2\pi} \{E_{int}[\lambda(\phi, \theta)] + E_{ext}[\lambda(\phi, \theta)]\} d\phi d\theta \quad (2.11)$$

em que  $E_{int}$  é a energia interna que é calculada pela soma das energias de curvatura e continuidade (CHEN *et al.*, 2006). Já  $E_{ext}$  é a energia externa que é obtida a partir do gradiente do contorno ativo.

### 2.2.4.3 Morphological Active Contours Without Edges (MACWE3D)

Chan e Vese (CHAN; VESE, 2001) definiram uma energia funcional para segmentação de imagens que leva em conta o conteúdo das regiões interior e exterior da curva. Assim, a função  $C$  da curva MACWE3D é definida por (NEILA *et al.*, 2014):

$$\begin{aligned} F(c_1, c_2, S) &= \mu \cdot area(S) + v \cdot volume(inside(S)) \\ &+ \lambda_1 \int_{inside(s)} \|I(x) - c_1\| dx \\ &+ \lambda_2 \int_{outside(s)} \|I(x) - c_2\| dx \end{aligned} \quad (2.12)$$

em que os parâmetros não-negativos  $\mu, v, \lambda_1$  e  $\lambda_2$  controlam o peso de cada termo.

A minimização  $\min_{c_1, c_2, S} F(c_1, c_2, S)$  é um tanto desafiador, pois, possui duas variáveis escalares adicionais que não estavam presentes no modelo de contorno original.

No entanto, dado um contorno de superfície fixo, os valores de  $c_1$  e  $c_2$  que minimizam  $F$  são a média dos valores de  $I$  dentro e fora do contorno (NEILA *et al.*, 2014). Para as superfícies  $c_1(S)$  e  $c_2(S)$ , tem-se

$$c_1(S) = \frac{\int_{inside(S)} I(x) dx}{\int_{inside(S)} dx}, c_2(S) = \frac{\int_{outside(S)} I(x) dx}{\int_{outside(S)} dx} \quad (2.13)$$

Este algoritmo morfológico ACWE é dado pelos três passos seguintes:  $u^{n+\frac{1}{3}}$ ,  $u^{n+\frac{2}{3}}$ ,

e  $u^{n+1}$ .

$$\begin{aligned}
 u^{n+\frac{1}{3}}(x) &= \begin{cases} (D_d u^n)(x) & \text{if } v > 0 \\ (E_d u^n)(x) & \text{if } v < 0 \\ u^n & \text{caso contrário} \end{cases} \\
 u^{n+\frac{2}{3}}(x) &= \begin{cases} 1 & \text{if } |\nabla u^{n+\frac{1}{3}}|(\lambda_1(I - c_1)^2 - \lambda_2(I - c_2)^2)(x) < 0 \\ 0 & \text{if } |\nabla u^{n+\frac{1}{3}}|(\lambda_1(I - c_1)^2 - \lambda_2(I - c_2)^2)(x) > 0 \\ u^{n+\frac{1}{3}} & \text{caso contrário} \end{cases} \\
 u^{n+1}(x) &= ((SI_d \circ IS_d)^\mu u^{n+\frac{2}{3}})(x).
 \end{aligned} \tag{2.14}$$

Esta equação pode ser usada de uma forma robusta para minimizar o ACWE funcional (CHAN; VESE, 2001).

#### 2.2.4.4 Region Growing 3D

O crescimento da região 3D inicia com um conjunto de pontos de semente, então as sementes crescem por análise da vizinhança. Para cada região semeada, os *voxels* vizinhos são analisados e, se suas características forem mais semelhantes à região, são adicionadas ao volume. O critério de homogeneidade é a diferença mínima entre o volume do tom de cinza de um pixel e o volume médio do tom cinza da região vizinha. Diz-se que o *voxel* pertence à mesma região que um ou mais de seus vizinhos, esta segmentação é iterativa: a cada passo, o *voxel* mais apropriado do conjunto de arestas e selecionado de acordo com o critério de homogeneidade, e seus pontos vizinhos são adicionados ao conjunto de arestas. Esse processo é repetido até que todos os *voxels* sejam alocados para uma região (LIN *et al.*, 2001; GONZALEZ *et al.*, 2009).

O processo de segmentação é inicializado com a região  $A_1$  contendo um único *voxel* da imagem e a execução do processo de segmentação consiste em um conjunto de regiões sendo identificadas,  $A_1, A_2, \dots, A_n$ . Seja  $T$  o conjunto de todos os *voxels* não alocados que fazem

fronteira com pelo menos uma destas regiões (HUANG *et al.*, 2011)

$$T = \left\{ x \notin \bigcup_{i=1}^n A_i \wedge \exists k : N(x) \cap A_k \neq \emptyset \right\} \quad (2.15)$$

em que  $N(x)$  são os *voxels* da vizinhança do ponto  $x$ . Desta forma, a diferença da medição é definida por

$$\delta(x, A_i) = |g(x) - \text{mean}_{y \in A_i}[g(y)]| \quad (2.16)$$

em que  $g(x)$  denota o valor da imagem no ponto  $x$ , e  $i$  é o índice da região  $N(x)$  que intercepta  $A_i$ . O processo do crescimento de região envolve a seleção da semente  $z \in T$  e a região  $A_j$  onde  $j \in [1, n]$  consiste em  $\delta(z, A_j) = \min_{x \in T, k \in [1, n]} \{\delta(x, A_k)\}$ . Se  $\delta(z, A_j)$  é menor to que o valor predefinido do limiar  $T$ , o *voxel* é adicionado à região  $A_j$ .

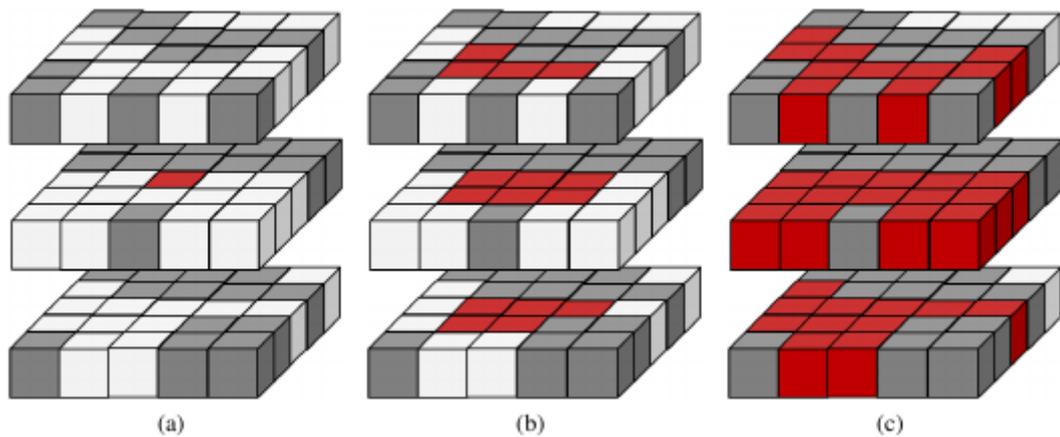
A aplicação básica do Método Crescimento de Regiões 3D é ilustrada na Figura 14 (a). Considera-se uma máscara volumétrica 3x5x5, em que as propriedades de cada *voxel* foram distinguidas por meio de atribuição de cores. Dessa forma, os *voxels* de cor branca possuem propriedade  $A$  e os de cor cinza, propriedade  $B$ . Atribue-se cor vermelha à semente. Nesse exemplo, deseja-se segmentar os *voxels* com propriedade  $A$ .

Esse método de segmentação baseia-se primordialmente em análise de similaridade na vizinhança da semente. Assim, deve ser localizada em posição estratégica para melhor desempenho do algoritmo. Na Figura 14 (a) é visualizada a posição da semente. Na Figura 14 (b) é ilustrado o resultado da primeira iteração, em que os *voxels* vizinhos com propriedade  $A$  passam a possuir o mesmo rótulo da semente. Na Figura 14 (c) é ilustrado o resultado final da segmentação através da técnica de RG 3D nos quais são segmentados os *voxels* com propriedade  $A$ .

#### 2.2.4.5 Fast level set based image segmentation using coherent propagation

Os contornos ativos podem ser vistos como um elástico (em 2D) ou um balão elástico (em 3D), e a segmentação da imagem usando contornos ativos é semelhante ao elástico sendo esticado em direção ao limite do objeto por uma força externa relacionada à informação da

Figura 14 – ilustração da aplicação do *Region Growing* 3D, a) localização da semente, b) primeira iteração do RG 3D, e c) resultado final da segmentação.



Fonte – Ribeiro (2013)

imagem, enquanto a força elástica interna tenta manter o contorno suave. O contorno do objeto pode ser representado explicitamente como curvas 2D ou malhas 3D (WANG *et al.*, 2016).

O contorno inicial é deformado objetivando a forma do objeto de interesse evoluindo iterativamente esta função de acordo com as forças externas e internas ao longo do tempo artificial (ACTON; RAY, 2009).

O método do *level set* é conhecido por exigir um longo tempo de computação para a segmentação de imagens 3D, o que limita seu uso. O algoritmo de propagação coerente permite que as funções de *level set* convirjam mais rapidamente, forçando o contorno a se mover monotonicamente de acordo com uma tendência de desenvolvimento previsto. Neste caso, as propagações reversas repetidas, causadas por ruído ou erros numéricos, são então evitadas. Também permite detectar a convergência local, de modo que as partes do limite que atingiram sua posição final, possam ser excluídas em iterações subsequentes, reduzindo assim o tempo de computação (ACTON; RAY, 2009).

Para compensar o erro de flutuação, a propagação coerente para frente e para trás é repetida periodicamente. Isso pode resultar em flutuações de grande magnitude em partes do contorno. Desta forma, a convergência gradual usando um fator de amortecimento foi implementado para resolver este problema.

Finalmente, a abordagem de propagação coerente é combinada com um novo conjunto de níveis regularizados à distância, eliminando as necessidades de reinicialização da distância (SHAH; MOGHADDAM, 2018).

### 2.3 Estado da Arte

Vezhnevets e I. (2005) descrevem um novo algoritmo para multilabel, GrowCut, interativo para realizar segmentação de imagens N-dimensionais. Dado um pequeno número de *pixels* rotulados pelo usuário, o resto da imagem é segmentada automaticamente por um AC.

Ghosh *et al.* (2011) apresentam uma nova técnica de segmentação de imagens sem supervisão baseada em autómatos celulares, motivada pelo algoritmo interativo de corte em crescimento, GrowCut. Em contraste com o método tradicional, que exige a interação do usuário para identificar classes, o algoritmo de crescimento contínuo não supervisionado (UGC) se inicia com um número aleatório de pontos de semente e converge automaticamente para uma segmentação natural.

Phan e Androutsos (2011) descrevem o GrowCut estendido para sequências de vídeos, além de fornecer melhorias e abordar áreas problemáticas para a formulação original. Isso proporciona um aumento de precisão que é o objetivo principal do trabalho.

Balocco *et al.* (2011) propõem uma nova linguagem para segmentar automaticamente o lúmen do vaso sanguíneo, que combina a informação temporal baseada em modelo extraída de imagens em sequência, com classificação espacial usando o algoritmo GrowCut.

Yamasaki *et al.* (2012) apresentam um método de corte crescido com velocidade acelerada baseado em GrowCut e apresenta um estudo comparativo de métodos de estabelecimento de sementes para segmentação rápida de imagens médicas 3D (MRI). O tempo de processamento tende a ser maior na segmentação de imagens médicas 3D devido ao grande número de *voxels* vizinhos, bem como ao número de *voxels* no total.

Cordeiro *et al.* (2016) propõem uma versão semi-supervisionada adaptativa do algoritmo GrowCut, com base na modificação da regra de evolução do autômato, adicionando uma função de associação *Gaussian fuzzy* para modelar bordas não definidas.

Radman *et al.* (2017) desenvolvem um algoritmo que localiza com precisão a íris por um modelo desenhado com base no descritor Histogramas de Gradientes Orientados (HOG) e Support Vector Machine (SVM). Com base nessa localização, a textura da íris é extraída automaticamente por meio de um autômato celular que evoluiu através da técnica GrowCut. As operações pré e pós-processamento também são introduzidas para garantir maior precisão de segmentação.

Thomas *et al.* (2017) propõem um GrowCut aprimorado (IGC), um algoritmo de segmentação de imagens de tomografia com emissão de pósitrons, e testa sua aplicabilidade

clínica. Contrariamente ao método tradicional, que exige que o usuário forneça as sementes iniciais, o algoritmo IGC se inicia com uma estimativa baseada no limiar do tumor e um invólucro tridimensional morfológicamente cultivado em torno do tumor como as sementes de primeiro plano e de fundo, respectivamente. A evolução do algoritmo se baseia no método tradicional.

CHA *et al.* (2017) modificaram o método convencional de *graphcuts*, adicionando informações de forma e de movimento. Modelos de forma ativa (MFA) com funções de distâncias são usadas para capturar a informação anterior da forma, evitando que o tecido circundante indesejado se tornasse parte do objeto segmentado. Neste trabalho, o método de fluxo óptico foi usado para estimar o movimento local e estender a segmentação 3D para 4D, através da deformação de um modelo de forma anterior ao longo do tempo.

Hosseini-Asl *et al.* (2016) de forma a segmentar eficientemente um pulmão 3-D, extrai características de contextos de imagens espaciais por aprendizado não supervisionado com uma fatoração de matriz não-negativa (ICNMF) restrita incremental. Este método aplica restrições de suavização para aprender as características, que são mais robustas às que não possuem homogeneidades do tecido pulmonar e, assim, ajudam a segmentar melhor as patologias pulmonares internas do que as técnicas mais modernas e eficientes conhecidas na literatura científica.

Kasturi *et al.* (2017) propõem um método para localizar e detectar eficazmente as células cancerígenas a partir das imagens de TC 2D e 3D, reduzindo o erro de detecção feito pelo olho dos médicos. O estágio inicial do câncer é diagnosticado com o uso de técnicas de realce de imagem e segmentação de borda de Sobel. Para finalizar o pós-processamento é utilizado a técnica de *chain code* de forma a analisar as bordas e realizar a inserção de *voxels* ao volume.

Sarker *et al.* (2017) usaram as propriedades de vizinhança e conectividade dos *pixels* da imagem de TC para solucionar problemas de segmentação. Para isto, vários processamentos morfológicos são utilizados para remover o fundo, os ruídos e as vias aéreas da imagem de TC pulmonar, e em seguida, a segmentação baseada em algoritmos *k-means clustering* é utilizada para detecção de tumor nos pulmões. Por fim é realizada uma análise volumétrica dos nódulos pulmonares para predição de estágios tumorais pela classificação da Metástase Tumoral Nódulo (TNM) proposta pela Organização Mundial da Saúde (OMS).

Soliman *et al.* (2017) propõem uma estrutura para a detecção de lesão pulmonar induzida por radiação (RILI) de TC 4D. A estrutura realiza a segmentação de campos pulmonares 4D, registro de imagens deformáveis (DIR), extração de características texturais e funcionais e

classificação de voxels pulmonares usando redes neurais convolucionais 3D profundas (CNN). Esta segmentação de imagens 4D extrai os campos pulmonares dentro da fase exalar, usando a técnica anterior de forma adaptativa Gaussiana em escala múltipla seguida de propagação de rótulo para outras fases 4D usando um modelo de forma adaptativa. Então, o 4D DIR alinha localmente as fases consecutivas do ciclo respiratório usando a equação 3D de Laplace para encontrar correspondências de *voxels* entre as isosuperfícies para os pulmões fixos e móveis e o campo aleatório generalizado de Markov em Gauss (GGMRF) como uma consistência anatômica limitada.

Os trabalhos citados previamente possuem uma abordagem relacionada ao GrowCut original apresentado por Vezhnevets e I. (2005). Desta forma, houve evoluções no método de inicialização (GHOSH *et al.*, 2011; CORDEIRO *et al.*, 2016; RADMAN *et al.*, 2017). Outros abordam a expansão do algoritmo para a 3a e 4a dimensões (KASTURI *et al.*, 2017; HOSSEINI-ASL *et al.*, 2016; SOLIMAN *et al.*, 2017). Em relação aos trabalhos estudados e descritos anteriormente, os mesmos possuem uma limitação em relação à segmentação de multiestruturas 3D de forma simultânea, a presença de ruído em alguns dos métodos citados também influencia na baixa taxa da segmentação.

A partir do conhecimento dos métodos estudados e descritos anteriormente, tendo como principal objetivo resolver alguns problemas apresentados nestes métodos, propõe-se um novo método de segmentação simultânea de imagens 3D e uma inicialização 3D automática para imagens de TC do Tórax que está descrito a seguir.

### 3 METODOLOGIA

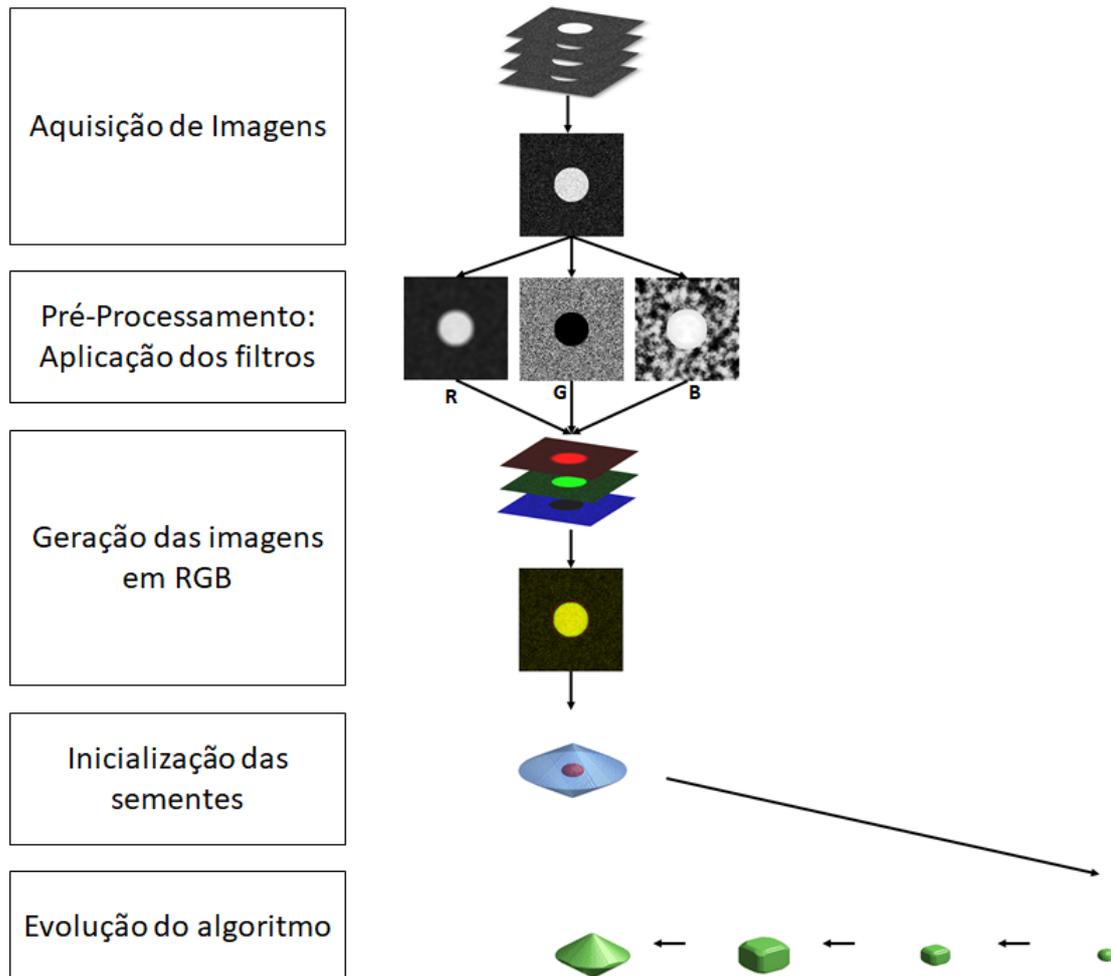
Toda a metodologia proposta para realizar a segmentação automática das imagens sintéticas e dos pulmões em imagens de TC do tórax é descrita neste Capítulo. Os parâmetros e configurações inerentes à metodologia proposta também são abordados, bem como os procedimentos para avaliação e validação da metodologia em diferentes aspectos.

#### 3.1 Descrição do método proposto

O processo de segmentação 3D do método proposto é constituído pelas seguintes etapas: aquisição das imagens, pré-processamento 2D em cada imagem, inicialização das sementes com seus respectivos rótulos e por fim é realizado a segmentação interativa da estrutura pulmonar, ou seja, os pulmões ou de volumes em imagens sintéticas.

Um fluxograma é ilustrado na Figura 15 das etapas do método proposto. Primeiro ocorre a etapa de aquisição que consiste na obtenção da imagem a partir de um arquivo, ou a partir de um *dataset*. Nesta tese, as imagens são obtidas a partir de imagens sintéticas e imagens de TC do Tórax. Em seguida, é realizado o pré-processamento 2D de cada imagem do volume 3D do exame completo. Neste pré-processamento 2D, a imagem original passa por três filtrações: filtração gaussiana (GONZALEZ *et al.*, 2009), equalização de histograma (ABDULLAH-AL-WADUD *et al.*, 2007) e filtração LBP (OJALA *et al.*, 2002). Após este pré-processamento, as imagens resultantes são agrupadas formando uma imagem no espaço RGB. O canal *R* é obtido através do resultado da aplicação da filtração gaussiana, o canal *G* é obtido através do resultado da equalização de histograma e o canal *B* da filtração LBP. Após o pré-processamento é realizada a inicialização dos rótulos sementes que devem evoluir até o estado final. Após a geração das sementes, estas evoluem de forma interativa até se estabilizarem, ou seja, atingir a forma final.

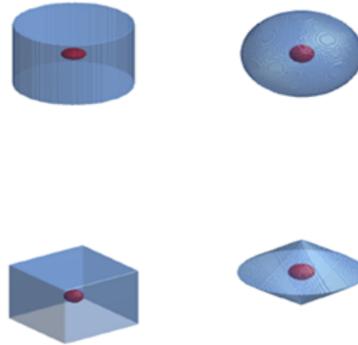
Figura 15 – Fluxograma do método proposto



Fonte – Autor.

Os testes com imagens sintéticas verificam a eficiência do método na segmentação da imagem de formas distintas de objetos e em situações de intensidades diferentes de ruído. As imagens sintéticas usadas para esses testes são mostradas na Figura 16. Foram criadas quatro imagens com o tamanho de  $300 \times 300 \times 300$  *voxels* com esses volumes. A escolha dessas formas de volumes deve-se às diferentes características de superfícies. O volume em azul consiste no volume a ser segmentado e o volume em vermelho consiste no volume referente às sementes iniciais.

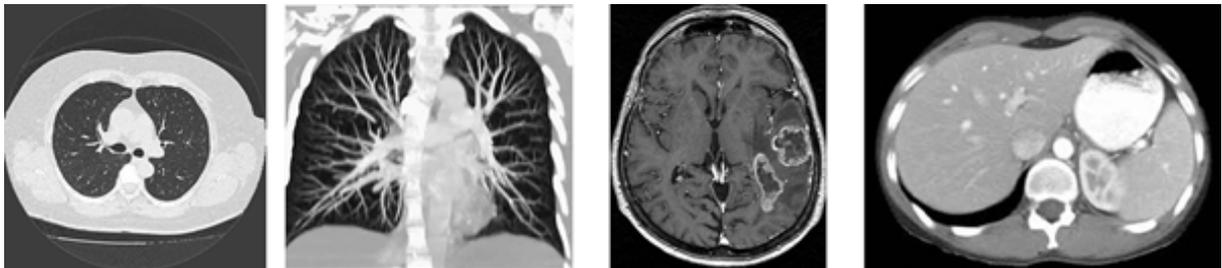
Figura 16 – Modelos dos volumes sintéticos



Fonte – Autor.

A próxima etapa do método consiste no pré-processamento 2D das imagens do volume. O objetivo deste pré-processamento para o método é a geração das forças, filtros  $R$ , filtragem gaussiana,  $G$ , realce, e  $B$ , filtragem LBP, de cada *voxel* e com isso tornar o método mais eficiente.

Figura 17 – Imagens originais de TC do pulmão, tórax, cérebro e fígado.

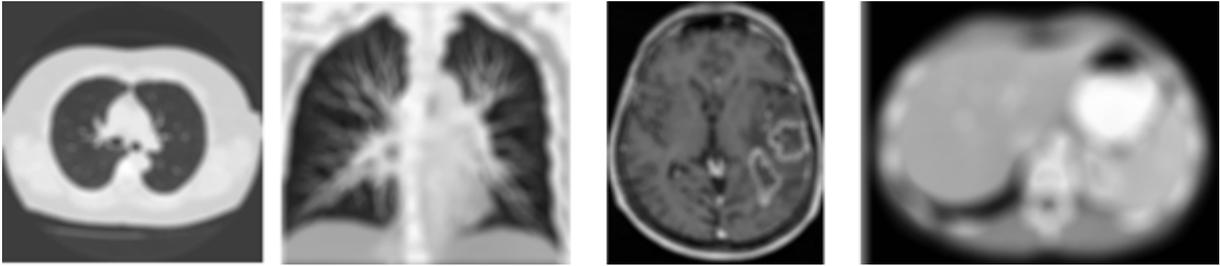


Fonte – Autor.

Na primeira filtragem, em que é aplicado um filtro gaussiano na imagem com o objetivo de suavizar componentes de alta frequência da imagem e assim aumentar a eficácia do algoritmo proposto. Nesta tese é aplicado um filtro gaussiano com elemento estruturante sendo uma esfera 11 *voxels* de diâmetro, obtido de forma empírica. Na Figura 17 são ilustradas as imagens originais de um TC do tórax, do cérebro e de um fígado. Na Figura 18 é ilustrada as imagens resultantes após a filtragem utilizando o referido filtro.

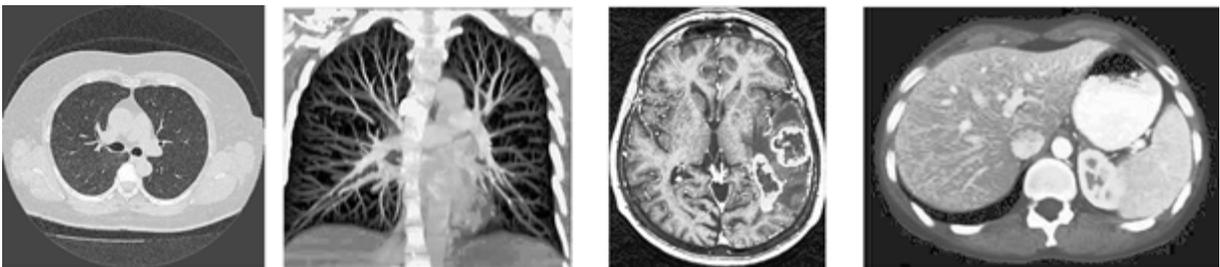
A componente  $G$  é a aplicação de um filtro de ajuste de histograma na imagem com o objetivo obter a máxima variância do histograma de uma imagem, obtendo assim uma imagem com o melhor contraste. Nesta tese é aplicado uma equalização de histograma baseado no método de Abdullah-Al-Wadud *et al.* (2007). Na Figura 19 é ilustrada as imagens resultantes após a equalização do histograma.

Figura 18 – Imagens resultantes da filtragem gaussiana



Fonte – Autor.

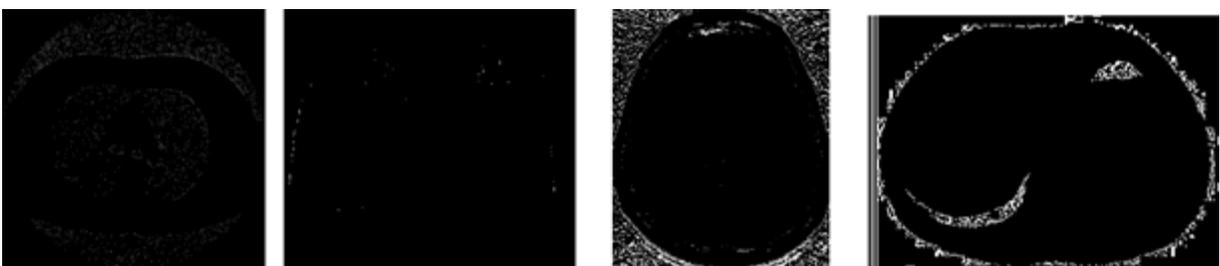
Figura 19 – Imagens resultantes da equalização do histograma



Fonte – Autor.

A componente *B* consiste na aplicação um filtro baseado no LBP na imagem com o objetivo de enfatizar as bordas e aumentar a variação dos tons de cinza entre a borda e as regiões vizinhas e assim dispor de mais informações para algoritmo proposto. Nesta tese é aplicado um filtro LBP  $u^2$ . Este método é escolhido devido o resultado da aplicação se assemelhar às estruturas a serem segmentadas (OJALA *et al.*, 2002). Na Figura 20 é ilustrada as imagens resultantes após a filtragem utilizando o LBP  $u^2$ .

Figura 20 – Imagens resultantes do filtro LBP



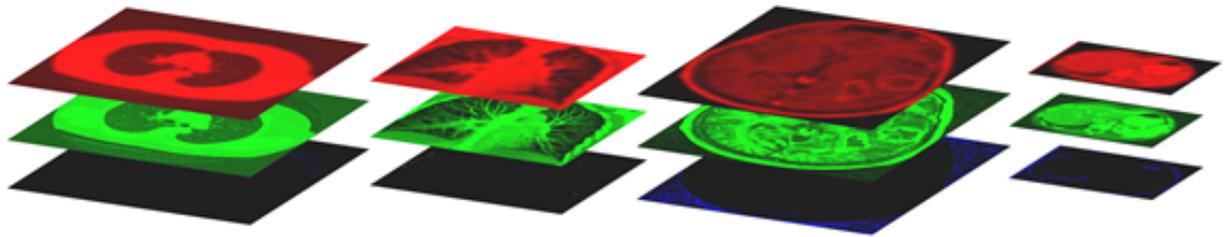
Fonte – Autor.

Após a etapa do pré-processamento 2D individual de cada imagem, o resultado compõe um novo conjunto de imagens, gerando uma nova imagem RGB. Esta nova imagem no espaço RGB produz três respectivas forças(R,G,B) de cada *voxel* no momento da segmentação interativa e baseado nestas forças é realizado a segmentação do objeto de interesse.

É possível observar na Figura 21 a configuração na qual é montada a imagem no

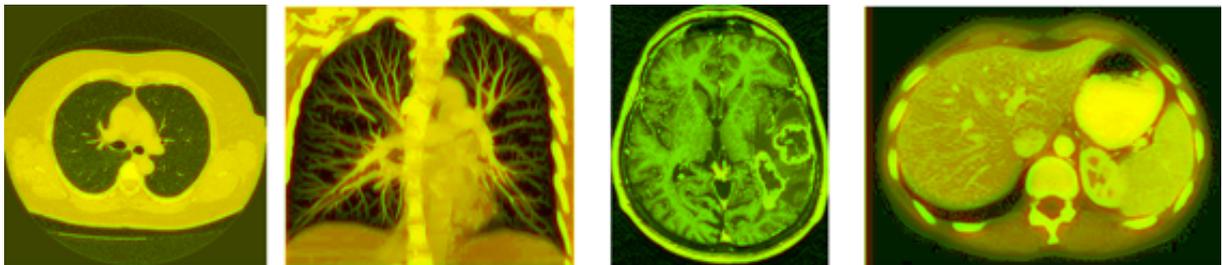
espaço de cores RGB, já na Figura 22 é possível visualizar os resultados das aplicações dos filtros nas imagens da Figura 17.

Figura 21 – Configuração da montagem no espaço RGB



Fonte – Autor.

Figura 22 – Imagens resultantes no espaço RGB obtidas a partir de suas componentes da Figura 21.



Fonte – Autor.

A próxima etapa consiste na inicialização das sementes e a rotulação dos *voxels*. A inicialização dos volumes sementes são gerados de forma manual para as imagens sintéticas e automática para os exames de TC do tórax.

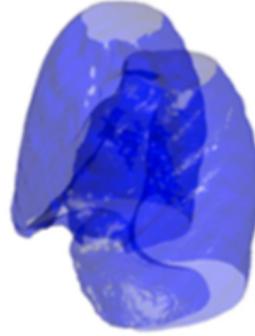
A última etapa do método consiste na segmentação interativa e o crescimento do volume. A partir da inicialização, uma vizinhança dos *voxels* rotulados são analisados e baseado na relação na interação e o estado do rótulo o *voxel* permanece com o mesmo rótulo ou troca para um novo rótulo.

Nesta tese são testadas vizinhanças de dimensões  $3 \times 3 \times 3$ ,  $5 \times 5 \times 5$ ,  $7 \times 7 \times 7$  e  $11 \times 11 \times 11$ . A dimensão da janela pode variar de acordo com a aplicação do método, em que se o objetivo for segmentar estruturas grandes, o ideal é utilizar janelas de dimensões maiores, já se o objetivo for segmentar estruturas pequenas, então é ideal utilizar janelas com dimensões menores.

O algoritmo funciona de forma iterativa até que o número máximo de iterações fornecida pelo usuário seja atingido ou então de forma que não há nenhuma variação nos rótulos durante uma iteração.

Para ilustrar o resultado do método após a o fim da interação, é possível verificar na Figura 23 o resultado da segmentação de um pulmão em uma imagem de TC.

Figura 23 – Imagem 3D obtida pelo método proposto



Fonte – Autor.

### 3.1.1 Definição das sementes iniciais para o TC do Tórax

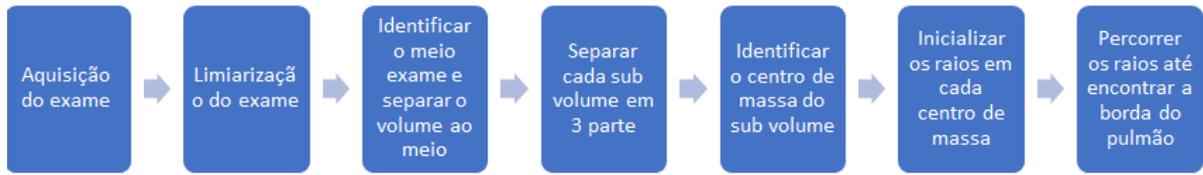
A desvantagem do GrowCut tradicional é a necessidade da interação com usuário no momento definição dos pontos iniciais das sementes, em que necessita que o mesmo informe os pontos iniciais antes da segmentação da região. Geralmente esta inicialização é realizada por intervenção manual do usuário, tornando desta forma os métodos dependentes dos operadores. Isto pode ocasionar impactos significativos no resultado, tais como aumentar o tempo de processamento, bem como gerar eventuais imprecisões na segmentação final (CAVALCANTE, b).

Nas últimas décadas, diversos métodos de inicialização automática foram propostos em diversos tipos de imagem, como por exemplo imagens de face humana (DELMAS *et al.*, 1999; ZHOU; GENG, 2004), imagens de ressonância magnética do coração (PLUEMPITIWI-RIYAWAJ; SOTTHIVIRAT, 2005; LIANG *et al.*, 2008a), imagens de ultrassom do coração (BOUHOURS, ), imagens de TC abdominais (GRANDO, ) e inclusive imagens de TC do tórax (FELIX *et al.*, 2012).

O método de inicialização proposto tem como objetivo identificar pontos internos ao pulmão, a partir de três inicializações radiais em cada pulmão, possibilitando assim a definição de pontos no ápice, no hilo e na base. O fluxograma do método proposto de inicialização pode ser observado na Figura 24.

A primeira etapa do algoritmo automático de inicialização consiste na limiarização

Figura 24 – fluxograma do método proposto de inicialização para imagens de TC do Tórax.



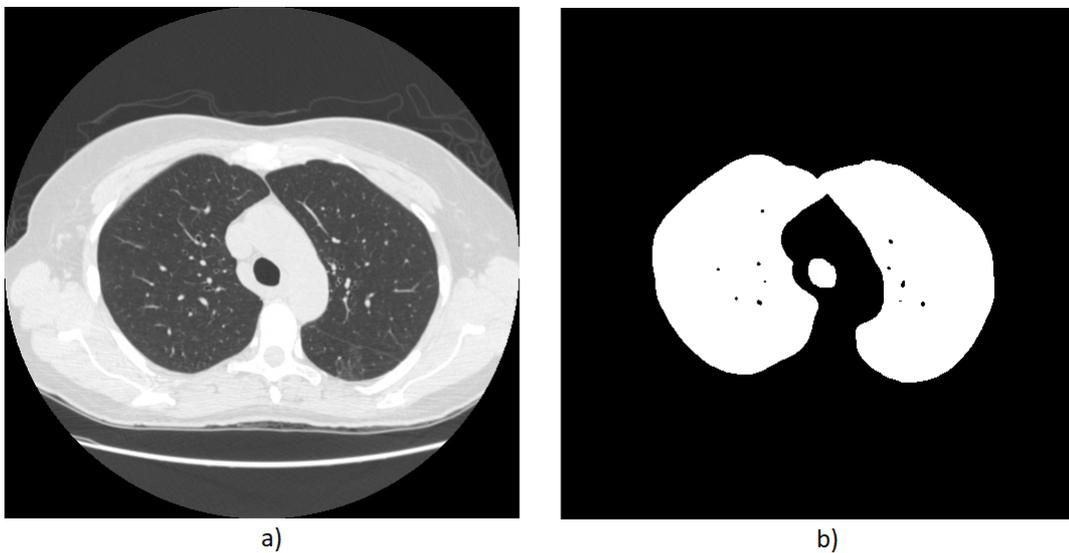
Fonte – Autor.

da imagem original de 16 *bits*. Esta é realizada com a finalidade de se extrair todas as estruturas que não compõem o parênquima pulmonar, tais como: cavidade, estrutura mediastinais, área cardíaca, o ar na parte superior e inferior da imagem e artefatos fora do tórax. Esta limiarização é aplicada na imagem original  $I_{UH}(x,y,z)$ , dada por

$$I(x,y,z)_{limiarizada} = \begin{cases} 255, & I_{UH}(x,y,z) < -600UH, \\ 0, & I_{UH}(x,y,z) \geq -600UH, \end{cases} \quad (3.1)$$

em que  $I(x,y,z)_{limiarizada}$  é imagem limiarizada e  $I_{UH}(x,y,z)$  é imagem original em 16 *bits*.

Figura 25 – imagens de pulmão, a) imagem 2D original do pulmão, e b) imagem 2D limiarizada.

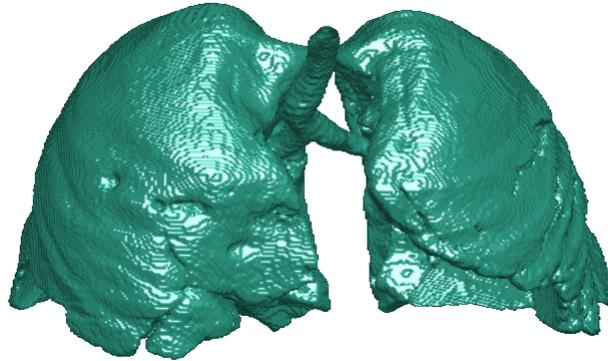


Fonte – Autor.

Na Figura 25 são ilustradas duas imagens, um original e seu resultado após a limiarização. É possível observar, na Figura 25a, a imagem do pulmão em tom de cinza e a partir desta imagem a equação 3.1 é aplicada, gerando a imagem  $I_{limiarizada}$  como pode ser visto na Figura 25b. Estas imagens estão no plano em 2D, e se concatená-las é gerado o volume resultante

na superfície 3D. O volume resultante da limiarização dos dois pulmões pode ser observado na Figura 26.

Figura 26 – volume 3D resultante do processamento de limiarização.



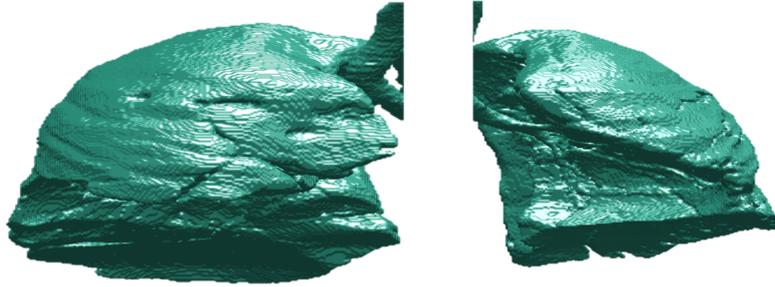
Fonte – Autor.

A segmentação baseada no limiar é um primeiro passo para a segmentação pulmonar, sendo que em alguns casos ocorre falha, por exemplo quando o pulmão possui doenças na qual a densidade pulmonar varia e se torna diferente da densidade pulmonar do pulmão sadio. Outro caso que pode vir a falhar é na segmentação por limiarização, quando o limiar não consegue distinguir o pulmão das vias aéreas. É ilustrado na Figura 25b o resultado de uma segmentação por limiar na qual as densidades de vias aéreas e pulmões são confundidas. Nesta situação, a segmentação final do pulmão conterà as informações das vias aéreas o que torna a segmentação com baixa taxa de acerto.

Desta forma, a segunda etapa consiste na separação dos dois pulmões ao meio, na qual são encontradas as coordenadas do pulmão inscrito em um cubo com o objetivo de identificar qual é o valor médio  $x_{méd}$  no eixo  $x$  de forma a dividir a região ao meio no eixo- $x$  por  $x = x_{méd}/2$ . Os volumes resultantes podem ser observados na Figura 27.

A próxima etapa consiste na separação de cada pulmão em três volumes menores, determinados pelas coordenadas do pulmão inscrito em um cubo com o objetivo de identificar qual é o valor para dividir o pulmão no eixo  $z$  em três partes. Primeiro é necessário identificar a espessura referente a cada parte do volume do pulmão, obtida por  $z_{esp} = \frac{\sum_{i=1}^n z_i}{3n}$ , em que  $z_i$  consiste no valor de  $z$  do  $i$ -ésimo *voxel* da função  $I_{limiarizada}(x, y, z)$ . A partir do valor da espessura  $z_{esp}$  é possível identificar limiares de cada região no eixo  $z$ . Desta forma, é possível identificar de forma estimada a região do eixo  $z$  para a região do ápice  $z_{apice}$ , hilo  $z_{hilo}$  e da base  $z_{base}$ , seguindo

Figura 27 – volume 3D do pulmão separado ao meio.



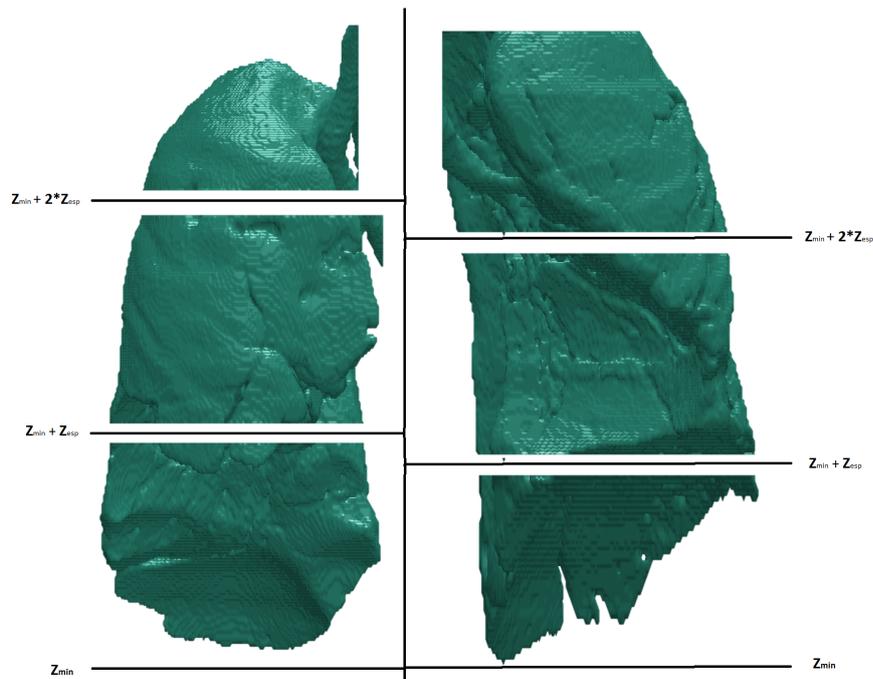
Fonte – Autor.

as desigualdades

$$\begin{aligned}
 z_{\min} &\leq z_{base} \leq z_{\min} + z_{esp} \\
 z_{\min} + z_{esp} &\leq z_{hilo} \leq z_{\min} + 2 \cdot z_{esp} \\
 z_{\min} + 2 \cdot z_{esp} &\leq z_{apice} \leq z_{\min} + 3 \cdot z_{esp},
 \end{aligned}
 \tag{3.2}$$

em que  $z_{\min}$  A separação de cada pulmão em três é possível ser observada nas Figura 28.

Figura 28 – volume 3D do pulmão esquerdo e direito separado em três partes.



Fonte – Autor.

A próxima etapa consiste em obter o centro de massa de cada volume  $C_m(x_{cm}, y_{cm}, z_{cm})$ , dados por

$$x_{cm} = \frac{\sum_i (x_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, y_{cm} = \frac{\sum_i (y_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, z_{cm} = \frac{\sum_i (z_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)} \quad (3.3)$$

em que  $x_i$ ,  $y_i$  e  $z_i$  consiste no valor de  $x$ ,  $y$  e  $z$  do  $i$ -ésimo *voxel* do volume, e  $I_{limiarizada}(x_i, y_i, z_i)$  consiste no valor da intensidade do *voxel*.

Desta forma é possível obter os valores dos centros de massa dos três volumes da base, hilo e ápice, do pulmão esquerdo através das seguintes equações

$$\begin{aligned} x_{Lbase} &= \frac{\sum_{i=1}^{x_{med}} (x_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, y_{Lbase} = \frac{\sum_i (y_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, z_{Lbase} = \frac{\sum_{i=z_{min}}^{z_{min}+z_{esp}} (z_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)} \\ x_{Lhilo} &= \frac{\sum_{i=1}^{x_{med}} (x_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, y_{Lhilo} = \frac{\sum_i (y_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, z_{Lhilo} = \frac{\sum_{i=z_{min}+2 \cdot z_{esp}}^{z_{min}+z_{esp}} (z_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)} \\ x_{Lapice} &= \frac{\sum_{i=1}^{x_{med}} (x_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, y_{Lapice} = \frac{\sum_i (y_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)}, z_{Lapice} = \frac{\sum_{i=z_{min}+3 \cdot z_{esp}}^{z_{min}+2 \cdot z_{esp}} (z_i \cdot I(x_i, y_i, z_i))}{\sum_i I(x_i, y_i, z_i)} \end{aligned} \quad (3.4)$$

e de forma análoga, calcula-se os centros de massa do pulmão direito.

De posse da posição do centro de massa de cada volume, a próxima etapa consiste em gerar feixes radiais que são as sementes dentro do sub volume do pulmão. Para gerar tais feixes, é necessário identificar a posição do centro de massa  $(x_{cm}, y_{cm}, z_{cm})$ , o comprimento do raio  $\lambda$  e o ângulo  $\phi$ , que varia em torno do eixo  $y$ , sobre o plano  $x - z$ , e o ângulo  $\theta$  que varia sobre o plano  $x - y$  e em torno do eixo  $z$ . Estes ângulos  $\phi$  e  $\theta$  são análogos aos parâmetros de azimute e elevação em um sistema de coordenadas horizontal.

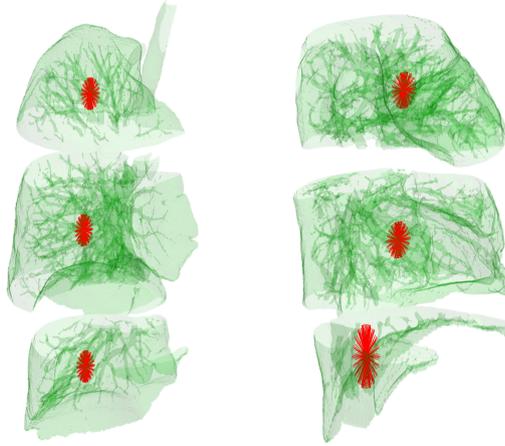
Formalmente um feixe 3D  $\rho(\phi, \theta, \lambda)$  é definido como uma função de uma imagem  $f$  através da seguinte equação (ALMEIDA *et al.*, 2017)

$$\rho(\phi, \theta, \lambda) = f \begin{bmatrix} x_{cm} + \lambda \sin(\phi) \cos(\theta) \\ y_{cm} + \lambda \sin(\phi) \sin(\theta) \\ z_{cm} + \lambda \cos(\phi) \end{bmatrix}. \quad (3.5)$$

A separação de cada sub-região do pulmão com os raios sendo gerados a partir do

centro de massa pode ser observado na Figura 29.

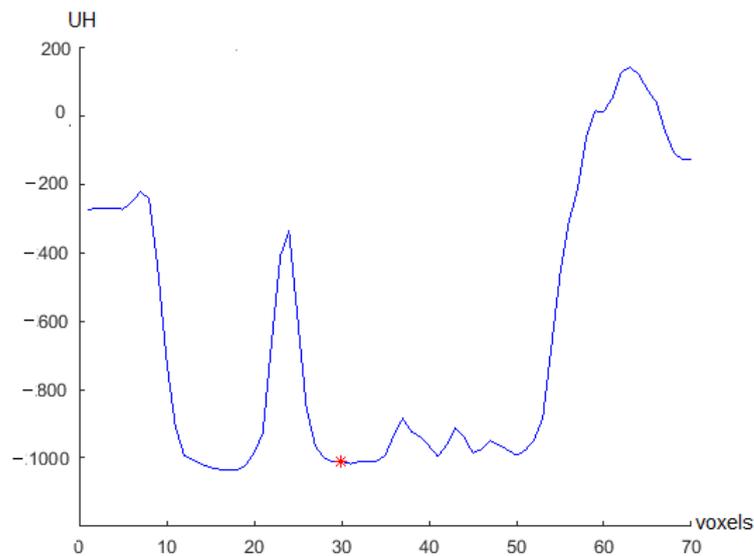
Figura 29 – inicialização dos raios no volume 3D do pulmão esquerdo e direito.



Fonte – Autor.

A partir de cada raio gerado, os *voxels* que pertencem este feixe são verificados o valor na imagem original e então são identificando os valores picos e os vales referente ao nível de densidade de acordo com as intensidades dos *voxels* percorridos. Um gráfico exemplo deste percurso pode ser observado na Figura 30, mostrando o valor mínimo, em UH, em que ocorre a parada do raio (destacado em vermelho).

Figura 30 – intensidade dos *voxels* no percurso do raio gerado.

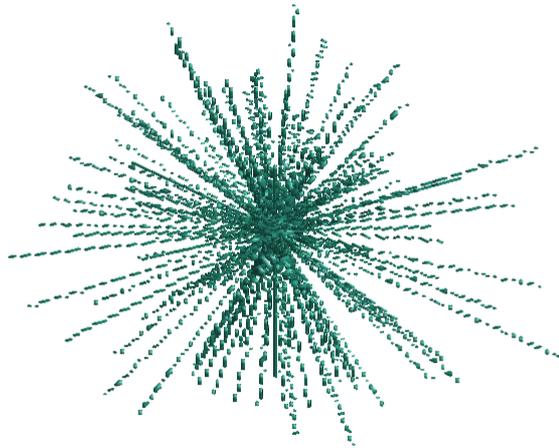


Fonte – Autor.

Após a definição de onde o raio deve parar seu crescimento, então no percurso

daquele raio, todos os pontos são definidos como sementes. Desta forma, para cada parte separada do pulmão previamente são gerados raios, de acordo com os raios ilustrados na Figura 31.

Figura 31 – raios gerados a partir do centro de massa.



Fonte – Autor.

### ***3.1.2 Regra de evolução do algoritmo***

A regra de evolução proposta possui o objetivo de segmentar imagens 3D. Para isso, é realizado a expansão do método do 2D para o 3D e é proposto a criação de uma força no espaço RGB baseada em três forças geradas, já descritas de forma a auxiliar e guiar o método a uma segmentação correta.

Os parâmetros de entrada são: o conjunto de imagens a serem segmentadas, a matriz de rótulos, ou sementes, e a matriz com o nível de confiança referente do respectivo rótulo. O algoritmo evolui baseado no algoritmo 1, mostrado a seguir. Esse algoritmo opera de forma iterativa até que o número máximo de iterações fornecidas pelo usuário seja atingido ou se não houver variação nos rótulos durante uma nova iteração.

---

**Algoritmo 1:** Regra de evolução proposta pelo 3D Autocut
 

---

**Require:**  $l_{R,G,B}, \theta, \vec{C}$   
**Ensure:** Imagem segmentada  
 // Para cada célula...  
**for**  $\forall p \in P$  **do**  
   // Cópia a força anterior  
    $l_R^{t+1} = l_{Rp}^t$ ;  
    $l_G^{t+1} = l_{Gp}^t$ ;  
    $l_B^{t+1} = l_{Bp}^t$ ;  
   // Cópia o estado anterior  
    $\theta^{t+1} = \theta_p^t$ ;  
   // vizinhos tentam atacar a célula em análise  
   **for**  $\forall q \in N(p)$  **do**  
     **if**  $g(\|\vec{C}_p - \vec{C}_q\|_3) \cdot \theta_q^t > \theta_p^t$  **then**  
        $l_R^{t+1} = l_{Rp}^t$ ;  
        $l_G^{t+1} = l_{Gp}^t$ ;  
        $l_B^{t+1} = l_{Bp}^t$ ;  
        $\theta^{t+1} = g(\|\vec{C}_p - \vec{C}_q\|_3) \cdot \theta_q^t$ ;  
     **end if**  
   **end for**  
**end for**

---

## 3.2 Avaliação do Método

Nesta seção são descritos os testes realizados para a avaliação da nova metodologia proposta sob diferentes aspectos. Basicamente, os testes objetivam avaliar a influência do ruído e a forma dos objetos na situação da aplicação do método proposto em imagens sintéticas. Também é avaliado a inicialização do método e o tamanho da janela utilizada para gerar os resultados na avaliação das imagens reais do pulmão, obtidas por exames de TC do Tórax.

### 3.2.1 Testes em Imagens Sintéticas

A forma do objeto a ser segmentado é de extrema importância, influenciando diretamente a atuação do método proposto, de acordo com a força e as características da imagem a ser segmentada. Os testes em imagens sintéticas são avaliados por duas métricas: o ajuste de posição e pelo coeficiente de similaridade Dice. Estes são escolhidos devido a sua larga utilização na literatura (GE *et al.*, 2015).

Nesse sentido, a fim de se obter uma maior variação de formas para avaliar como o método proposto se comporta e sob que circunstâncias e características, e qual configuração que

conduz ao melhor desempenho. Para tanto são realizados testes que utilizam imagens sintéticas volumétricas em formatos de cilindro, duplocone, cubo e esfera, com dimensões  $300 \times 300 \times 300$  *voxels*, ilustrados na Figura 32. A escolha desses volumes deve-se às diferentes características geométricas. A partir desses volumes, são introduzidos ruídos aditivos de forma a verificar a robustez do método. Desta forma, é possível observar as vantagens e limitações das técnicas utilizadas na segmentação dessas imagens.

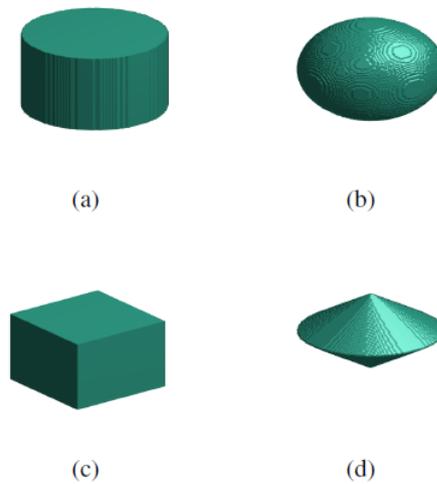


Figura 32 – Imagens sintéticas 3D utilizadas para os testes, a) cilindro, b) esfera, c) cubo e d) duplocone.

O ruído aditivo usado para contaminar as imagens sintéticas originais é gerado usando uma função gaussiana. Este tipo de ruído é usado devido a sua semelhança com o ruído que aparece em imagens médicas (BESSA *et al.*, 2015).

O ruído gaussiano é um ruído estatístico com uma função de densidade de probabilidade  $p(z)$  igual à distribuição normal. A função de densidade de probabilidade  $p$  de uma variável aleatória gaussiana  $z$  é dada por (LEE, 1980)

$$p(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(z-\mu)^2}{2\sigma^2}}, \quad (3.6)$$

em que  $z$  representa o nível de cinza,  $\mu$  o valor médio e  $\sigma$  o desvio padrão. O valor médio  $\mu$  utilizado é zero e a variância  $\sigma$  é a variável para testar o método. Diferentes valores da relação sinal/ruído (SNR) são utilizadas nas imagens de teste de acordo com a variância  $\sigma^2$ . A relação

SNR é dada por:

$$SNR = 10 \cdot \log_{10} \left( \frac{\sigma_{\text{signal}}^2}{\sigma_{\text{ruído}}^2} \right), \quad (3.7)$$

em que  $\mu$  é o valor médio dos *pixels* da imagem e  $\sigma_N$  é o desvio padrão dos *pixels* da imagem com ruído. Na Tabela 1 é possível verificar as variações de ruídos utilizados e as taxas SNR(dB).

Tabela 1 – Relação sinal-ruído nas imagens sintéticas

	Variância	SNR(dB)
	0,005	42,08
	0,01	41,95
	0,05	40,74
	0,1	39,48
	0,5	35,58
	1	34,36
	5	32,83
	0,005	41,77
	0,01	41,36
	0,05	38,83
	0,1	36,86
	0,5	32,04
	1	30,71
	5	29,07
	0,005	42,03
	0,01	41,85
	0,05	40,38
	0,1	38,95
	0,5	34,79
	1	33,54
	5	31,98
	0,005	41,3
	0,01	40,54
	0,05	36,83
	0,1	34,46
	0,5	29,25
	1	27,86
	5	26,19

Para os testes, as imagens foram geradas com variâncias de 0,005, 0,01, 0,05, 0,1, 0,5, 1 e 5 para os quatro tipos de objetos. Pode-se observar na Figura 33 os exemplos de imagens ruidosas, no meio do eixo  $z$ . As imagens da Figura 33(a) até a Figura 33(g) são as imagens do

cubo, cilindro e cone duplo, e as imagens da Figura 33(h) para a Figura 33(n) são as imagens do cubo, respectivamente.

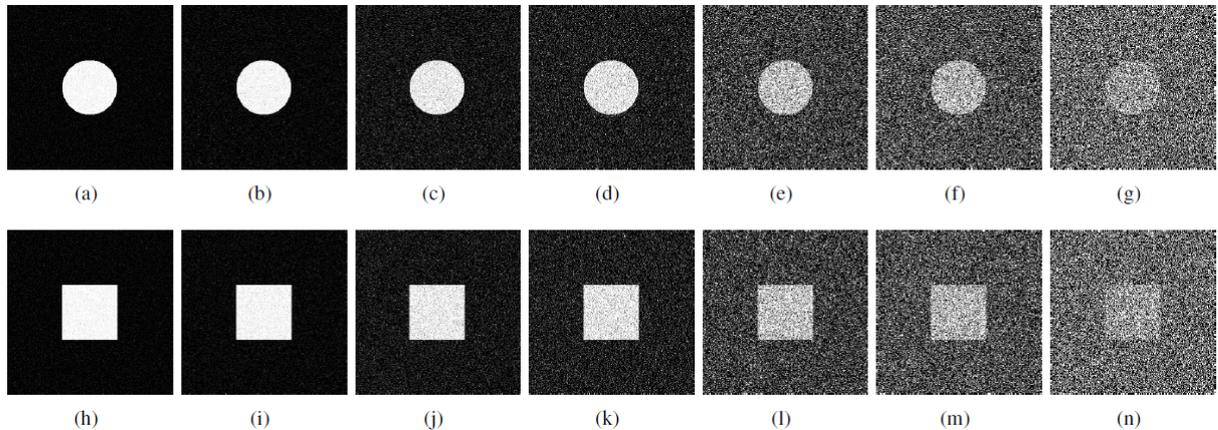


Figura 33 – Imagens sintéticas 3D utilizadas para os testes, a) cilindro, b) esfera, c) cubo e d) duplocone.

### 3.2.2 Testes em Imagens Médicas

Realizar a comparação de algoritmos de segmentação de pulmões publicados em bases públicas é uma tarefa difícil, pois são algoritmos diferentes e utilizam banco de dados variados para sua validação em seus artigos. Alguns destes podem ser reimplementados com base na publicação disponível, mas muitas vezes há parâmetros a serem definidos nos quais um profundo conhecimento do método é necessário, bem como há casos em que tais parâmetros são omitidos, ou ainda os dados de treinamento utilizados não estão disponíveis ao público. Entretanto, para realizar a comparação efetiva de todos os métodos, é necessário utilizar um conjunto de dados comum para todos.

Nesta tese, é analisado a segmentação de pulmões em imagens de TC de alta resolução do Tórax. Os 15 exames de TC utilizados para validação do método desta tese são de exames de pacientes voluntários saudáveis e pacientes com vários tipos de patologia. Para a avaliação dos métodos são utilizadas imagens de exames nas posições ápice, hilo e base obtidos a partir de imagens de TC do Tórax. As imagens adquiridas têm uma resolução de  $512 \times 512$  pixels com 16 bits. A Tabela 2 indica as características desses exames, obtidos em parceria com o Hospital Universitário Walter Cantídio, no Brasil.

De posse dos exames de TC, a validação da inicialização do algoritmo é realizada. Para isto o algoritmo descrito na Seção 3.1 é executado para cada exame. Por fim, é determinado

Tabela 2 – Tipos de exames utilizados.

<b>Exame</b>	<b>Número de Imagens</b>	<b>Patologia</b>
1	264	Normal
2	376	Normal
3	240	Fibrose
4	224	Normal
5	272	Fibrose
6	296	Normal
7	296	Enfisema
8	216	Bronquiectasia
9	264	Abestose
10	256	Normal
11	224	Bronquiectasia e Fibrose
12	224	Enfisema
13	272	Calcificação
14	224	Bandas parenquimatosas
15	224	Bronquiectasia e calcificação

por comparação utilizando quatro métricas qual a influência da inicialização no resultado final da segmentação. Para isto, no momento da inicialização são comparados a quantidade de raios gerados em cada região e o comprimento máximo de cada raio.

A avaliação da inicialização é realizada aplicando as variações de inicializações ao método proposto e verificando a segmentação final comparando através das taxas de coeficiente de similaridade Dice, ajuste de posição, ajuste de forma e ajuste de tamanho. Os dados apresentados são obtidos com o valor médio e desvio padrão dessas taxas para cada exame.

Para a avaliação da segmentação dos pulmões, cada exame de TC é submetido ao processo de segmentação descrito na Seção 3.1. Por esta razão é importante realizar a verificação da segmentação volumétrica na visão de diferentes dimensões de janela. Usam-se as mesmas métricas nesta avaliação que são empregadas no processo de inicialização.

### **3.2.3 Métricas de Avaliação**

Segundo DELVES *et al.* (1992), o primeiro passo para avaliar uma imagem segmentada é comparar as regiões detectadas na imagem segmentada com aquelas na imagem de referência. Essa comparação é baseada no processo de ajuste, combinando a região de real da imagem com a região segmentada. Há uma região que corresponde a ambos, imagem real e segmentada, essa região é denominada de região de interseção.

Para medir a acurácia, tanto das segmentações sintéticas quanto das segmentações, em exames de TC realizadas nesta tese, é utilizado um conjunto de métricas composto por

medidas de ajustes descritas a seguir.

As medidas de ajuste Fit são baseadas na simetria entre regiões da imagem de referência  $R = r1; r2; \dots; rr$  e regiões da imagem segmentada  $S = r1; r2; \dots; rs$ , ou seja, o quanto se assemelham entre si quando sobrepostas (CAVALCANTE, b). Ajuste de posição 3D é definido por (DELVES *et al.*, 1992)

$$Fit_{posicao_{xyz}} = 1 - \frac{x_d + y_d + z_d}{3}, \quad (3.8)$$

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

$$\begin{aligned} x_d &= \frac{|\bar{x}_{gt} - \bar{x}_{seg}|}{d_x} \\ y_d &= \frac{|\bar{y}_{gt} - \bar{y}_{seg}|}{d_y} \\ z_d &= \frac{|\bar{z}_{gt} - \bar{z}_{seg}|}{d_z} \end{aligned} \quad (3.9)$$

em que  $x_{gt}$ ,  $y_{gt}$ ,  $z_{gt}$  indicam as coordenadas médias nos eixos  $x$ ,  $y$  e  $z$  da imagem 3D do padrão ouro, bem como  $x_{seg}$ ,  $y_{seg}$ ,  $z_{seg}$  indicam a analogia na imagem segmentada;  $d_x$ ,  $d_y$  e  $d_z$  representam a dimensão da imagem nos eixos  $x$ ,  $y$  e  $z$ , respectivamente. O ajuste de tamanho 3D é definido como a razão da diferença entre as áreas, ou volumes, da segmentação e do padrão ouro e a soma das mesmas, dado por (DELVES *et al.*, 1992):

$$Fit_{tamanho} = 1 - \frac{|V_{padraoouro} - V_{segmentado}|}{V_{padraoouro} + V_{segmentado}}. \quad (3.10)$$

Este valor varia entre 0 e 1, no qual 1 significa que os volumes são semelhantes e 0 significa que os volumes são diferentes. O ajuste de forma 3D é definido como a razão da diferença entre interseção e a união das as áreas, ou volumes, da segmentação e do padrão ouro, dado por (DELVES *et al.*, 1992)

$$Fit_{forma} = \frac{|A_{padraoouro} \cap A_{segmentado}|}{A_{padraoouro} \cup A_{segmentado}}. \quad (3.11)$$

em que este valor varia de 0 à 1, no qual 1 significa que há uma alta sobreposição dos volumes

e quando tender para 0 significa que os volumes tendem a ter uma baixa sobreposição. O coeficiente de similaridade de *Dice* 3D é definido por (DELVES *et al.*, 1992)

$$Dice(I_{seg}, I_{gt}) = \frac{2|I_{seg}I_{gt}|}{|I_{seg}| \cup |I_{gt}|}, \quad (3.12)$$

em que  $I_{gt}$  é a imagem de do padrão ouro e o  $I_{seg}$  é a imagem segmentada pelo algoritmo sob avaliação.

A partir da descrição de toda a metodologia, incluindo-se as métricas que devem ser empregadas no processamento de avaliação dos algoritmos de segmentação, são obtidos os resultados dos algoritmos, descritos a seguir.

## 4 RESULTADOS

Neste Capítulo são descritos os principais resultados obtidos pelo método proposto comparando com algoritmos de segmentação de imagens 3D. Os resultados são apresentados em duas partes, em que a primeira parte consiste nos testes e validação em imagens sintéticas comparando com os algoritmos de CR3D Gonzalez *et al.* (2009), Neila *et al.* (2014), Almeida *et al.* (2017). Na segunda parte é realizada a comparação na aplicação dos métodos em imagens reais de TC do Tórax com o objetivo de segmentar os pulmões. Os algoritmos usados nesta parte são Gonzalez *et al.* (2009), Acton e Ray (2009), Cheimariotis *et al.* (2017).

### 4.1 Resultados obtidos para Imagens sintéticas

Para gerar os resultados com as imagens sintéticas, a inicialização das sementes é feita manualmente, no qual uma esfera é adicionada no centro de cada volume. Nestas imagens, o objetivo é uma prova de conceito do novo algoritmo proposto empregado na técnica de segmentação com a presença de ruído. Este algoritmo é comparado com quatro algoritmos encontrados na literatura que realizam segmentação de imagens 3D e são empregados na segmentação de quatro imagens sintéticas diferentes com diferentes intensidades de ruído. Tais algoritmos são: Crescimento de Região 3D RG3D (GONZALEZ *et al.*, 2009), Contornos morfológicos ativos sem bordas MACWE3D (NEILA *et al.*, 2014) e Método de contorno ativo radial tridimensional RAC3D (ALMEIDA *et al.*, 2017). Esta comparação é realizada usando os coeficientes de similaridade Dice e ajuste de posição.

Os resultados são obtidos para vários níveis de intensidade de ruído adicionado às imagens sintéticas. Da Tabela 3 até a Tabela 6 podem ser vistos os resultados obtidos para os coeficientes de similaridade Dice e ajuste de posição.

Com base na média e desvio padrão de cada coeficiente de comparação, o método proposto possui uma média mais alta e um desvio padrão menor na segmentação dos quatro volumes. Também é possível identificar que, à medida que a variância do ruído aumenta, as taxas diminuem e, quando a variância do ruído é superior a 0,1, os demais algoritmos não conseguem segmentar. Ainda assim, o algoritmo proposto obtém os melhores resultados para ambos os coeficientes.

Os resultados dos algoritmos podem ser visualmente observados nas Figuras 34 até a Figura 37. Nos quatro casos, os algoritmos da literatura se iniciam com valores maiores para

Tabela 3 – resultados obtidos para o cilindro para os coeficiente de similaridade Dice e ajuste de posição.

Variância do ruído(v)	Método Proposto		Crescimento de Região 3D		MACWE3D		RAC3D	
	Dice	Fit	Dice	Fit	Dice	Fit	Dice	Fit
0005	0,99	0,98	1,00	1,00	1,00	1,00	0,95	0,91
005	0,99	0,98	0,98	0,96	1,00	1,00	0,92	0,86
001	0,99	0,98	0,88	0,78	1,00	0,99	0,66	0,50
01	0,99	0,98	0,88	0,78	1,00	0,99	0,68	0,52
05	0,91	0,83	0,01	0,00	0,95	0,91	0,07	0,04
1	0,80	0,67	0,00	0,00	0,55	0,38	0,04	0,02
5	0,76	0,61	0,00	0,00	0,01	0,00	0,02	0,01
<b>Média</b>	0,99	0,98	0,88	0,78	1,00	0,99	0,66	0,50
<b>Desvio Padrão</b>	0,10	0,16	0,50	0,48	0,38	0,40	0,42	0,39

Tabela 4 – resultados obtidos para o cubo para os coeficiente de similaridade Dice e ajuste de posição.

Variância do ruído(v)	Método Proposto		Crescimento de Região 3D		MACWE3D		RAC3D	
	Dice	Fit	Dice	Fit	Dice	Fit	Dice	Fit
0005	0,99	0,97	1,00	1,00	1,00	1,00	0,94	0,88
005	0,99	0,98	0,98	0,95	1,00	1,00	0,90	0,83
001	0,99	0,98	1,00	0,99	1,00	1,00	0,94	0,88
01	0,99	0,98	0,87	0,77	1,00	0,99	0,84	0,72
05	0,98	0,96	0,01	0,00	0,98	0,97	0,06	0,03
1	0,91	0,83	0,01	0,00	0,67	0,50	0,06	0,03
5	0,90	0,81	0,00	0,00	0,01	0,00	0,03	0,01
<b>Média</b>	0,99	0,97	0,87	0,77	1,00	0,99	0,84	0,72
<b>Desvio Padrão</b>	0,04	0,08	0,51	0,50	0,37	0,39	0,46	0,43

Tabela 5 – resultados obtidos para o duplocone para os coeficiente de similaridade Dice e ajuste de posição.

Variância do ruído(v)	Método Proposto		Crescimento de Região 3D		MACWE3D		RAC3D	
	Dice	Fit	Dice	Fit	Dice	Fit	Dice	Fit
0005	0,99	0,98	1,00	1,00	1,00	1,00	0,90	0,83
005	0,98	0,97	0,98	0,96	1,00	1,00	0,87	0,78
001	0,99	0,97	1,00	1,00	1,00	1,00	0,90	0,83
01	0,99	0,97	0,87	0,77	1,00	0,99	0,86	0,76
05	0,98	0,96	0,03	0,01	0,99	0,97	0,21	0,12
1	0,78	0,64	0,02	0,01	0,98	0,96	0,22	0,12
5	0,70	0,54	0,00	0,00	0,03	0,02	0,16	0,09
<b>Média</b>	0,98	0,97	0,87	0,77	1,00	0,99	0,86	0,76
<b>Desvio Padrão</b>	0,12	0,19	0,51	0,50	0,36	0,37	0,37	0,37

Tabela 6 – resultados obtidos para a esfera para os coeficiente de similaridade Dice e ajuste de posição.

Variância do ruído(v)	Método Proposto		Crescimento de Região 3D		MACWE3D		RAC3D	
	Dice	Fit	Dice	Fit	Dice	Fit	Dice	Fit
0005	0,99	0,98	0,88	0,78	1,00	0,99	0,90	0,82
005	0,99	0,98	0,88	0,78	1,00	0,99	0,90	0,82
001	0,99	0,98	0,88	0,78	1,00	0,99	0,90	0,82
01	0,99	0,98	0,88	0,78	1,00	0,99	0,90	0,82
05	0,98	0,96	0,01	0,01	0,99	0,98	0,15	0,08
1	0,82	0,70	0,01	0,01	0,90	0,81	0,06	0,03
5	0,80	0,67	0,00	0,00	0,02	0,01	0,05	0,02
<b>Média</b>	0,99	0,98	0,88	0,78	1,00	0,99	0,90	0,82
<b>Desvio Padrão</b>	0,09	0,14	0,46	0,42	0,37	0,37	0,44	0,41

esses coeficientes para o nível de ruído de 0,0005, mas quando o nível de ruído atinge o valor 0,5, cada um dos algoritmos não funcionam como esperado.

Figura 34 – imagens resultantes após a aplicação dos métodos para segmentação do cilindro.

Variância do ruído ( $\sigma^2$ )	0	0,0005	0,001	0,005	0,1	0,5	1	5
Método Proposto								
Crescimento de Região 3D								
MACWE3D								
RAC3D								

Figura 35 – imagens resultantes após a aplicação dos métodos para segmentação do cubo.

Variância do ruído ( $\sigma^2$ )	0	0,0005	0,001	0,005	0,1	0,5	1	5
Método Proposto								
Crescimento de Região 3D								
MACWE3D								
RAC3D								

Figura 36 – imagens resultantes após a aplicação dos métodos para segmentação do duplo cone.

Variância do ruído ( $\sigma^2$ )	0	0,0005	0,001	0,005	0,1	0,5	1	5
Método Proposto								
Crescimento de Região 3D								
MACWE3D								
RAC3D								

Figura 37 – imagens resultantes após a aplicação dos métodos para segmentação da esfera.

Variância do ruído ( $\sigma^2$ )	0	0,0005	0,005	0,001	0,5	0,1	1	5
Método Proposto								
Crescimento de Região 3D								
MACWE3D								
RAC3D								

O baixo desempenho do algoritmo Crescimento de Região 3D (GONZALEZ *et al.*, 2009) em imagens de maior intensidade de ruído é devido a sua sensibilidade ao ruído. Desta forma, é possível observar que, apesar do aumento da intensidade do ruído gaussiano, o algoritmo proposto ainda mantém maiores valores para os coeficientes Dice e ajuste de posição.

Na avaliação do algoritmo do método de Contorno Ativo Radial Tridimensional RAC3D (ALMEIDA *et al.*, 2017) é visto que quando a intensidade do ruído é baixa obtém uma taxa da ordem de 0,9, coeficientes Dice, mas quando o nível de ruído aumenta, o resultado não atinge o resultado esperado. Quando a variância do ruído é superior a 0,5, este algoritmo não consegue distinguir o que é ruído e qual o volume a ser segmentado.

O algoritmo de Contornos Morfológicos Ativos Sem Bordas (MACWE3D) (NEILA *et al.*, 2014) atinge uma maior taxa do coeficiente Dice médio dos dados, mas seu desvio padrão é alto. Isso acontece porque consegue um ótimo desempenho com baixos níveis de ruído, mas com um maior nível de ruído, o seu desempenho diminui substancialmente. Sua média de resultados é maior do que o método proposto, nos quatro casos atingindo uma taxa de sucesso de 0,99, enquanto o método proposto atinge 0,98. Entretanto, o desvio padrão é 0,5, o desvio padrão do método proposto é de apenas 0,1.

Nos quatro casos, os métodos iniciam com um valor elevado para os coeficientes no nível de ruído igual a 0, mas quando este nível atinge o valor de 1, o desempenho do algoritmo diminui.

Isso ocorre porque, após a adição do ruído, a imagem perde suas características originais, dificultando a definição do volume a ser segmentado. Apesar do aumento da dificuldade de segmentação, o algoritmo proposto possui um maior valor dos coeficientes atingindo acima

de 0,8. Isto é devido à geração de forças no espaço RGB que auxiliam o algoritmo no momento da segmentação com adicionais informações que permitem distinguir o objeto a ser segmentado.

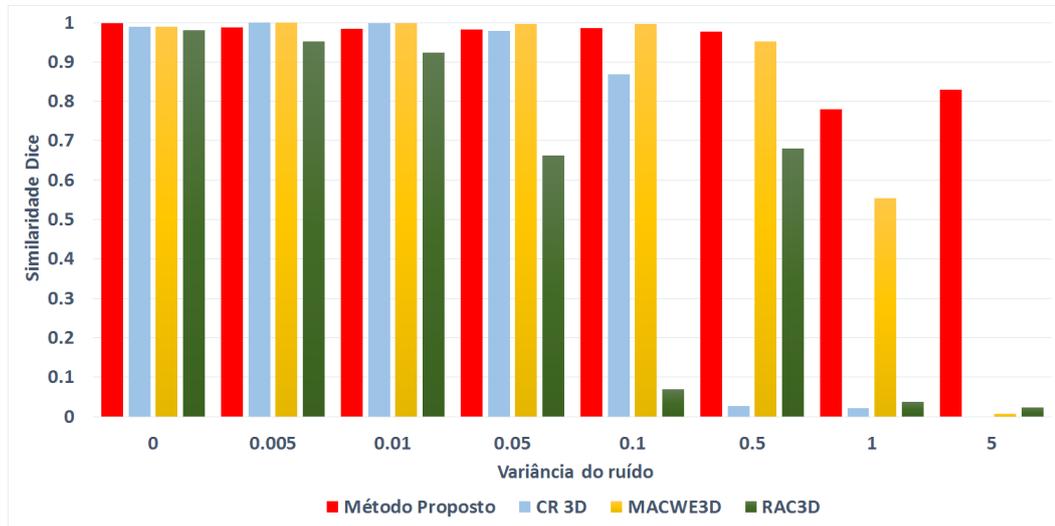


Figura 38 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume do cilindro.

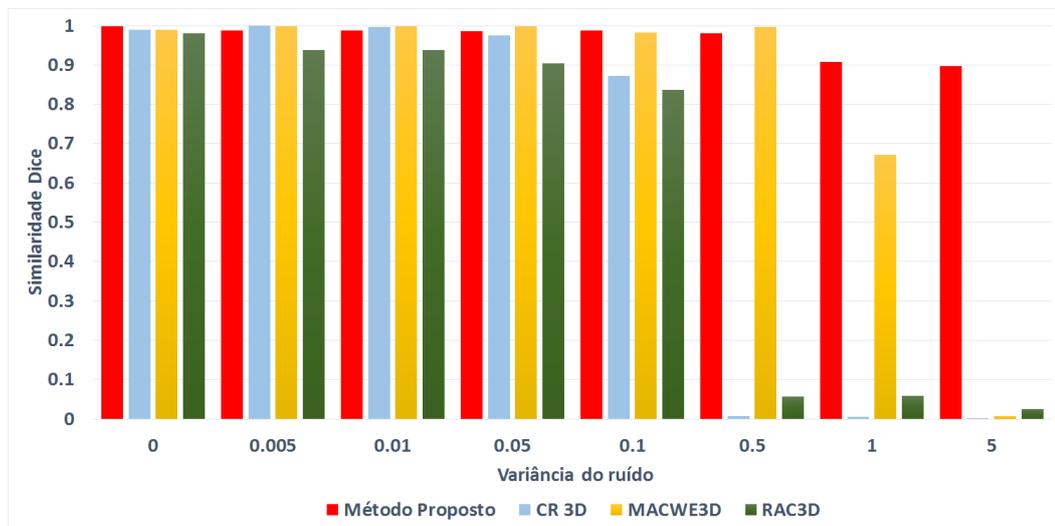


Figura 39 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume do cubo.

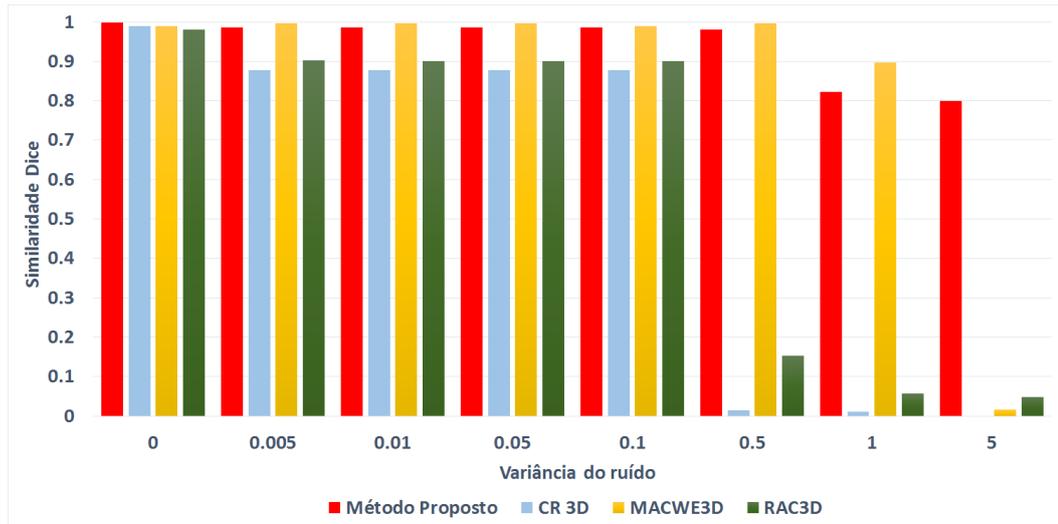


Figura 40 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume do duplo cone.

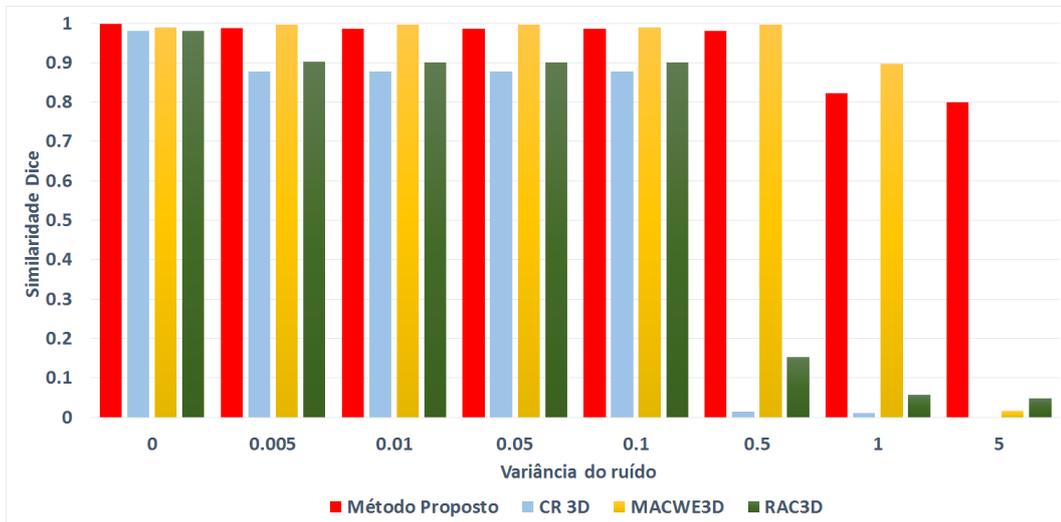


Figura 41 – Coeficiente de similaridade Dice baseado na variância do ruído para o volume da esfera.

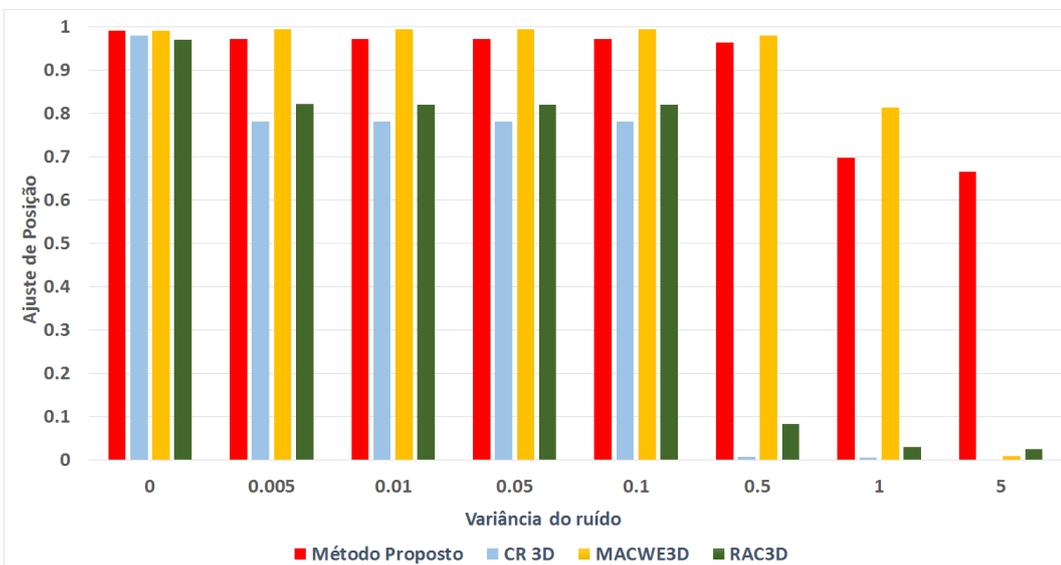


Figura 45 – Ajuste de posição baseado na variância do ruído para o volume da esfera.

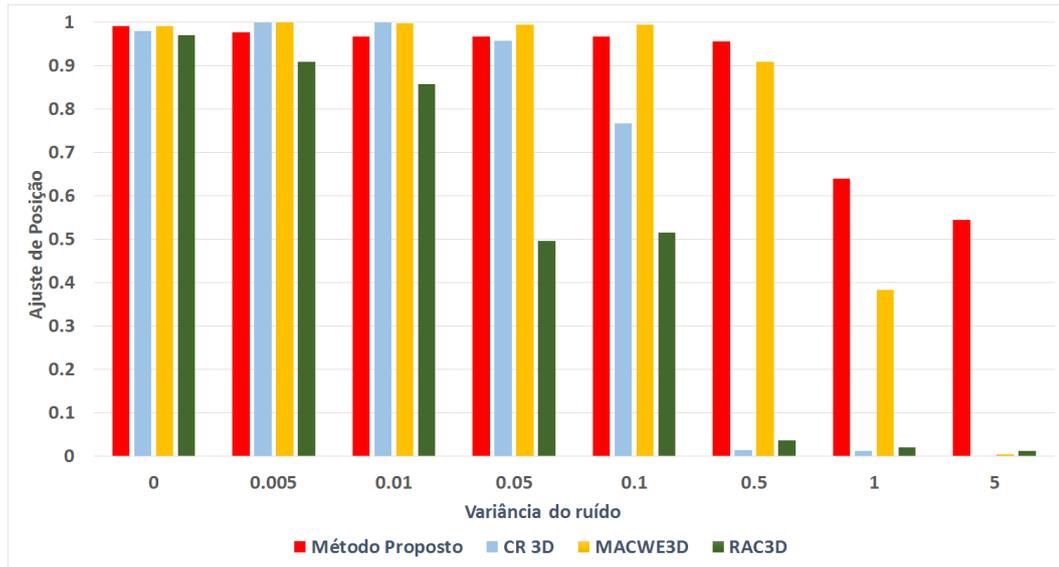


Figura 42 – Ajuste de posição baseado na variância do ruído para o volume do cilindro.

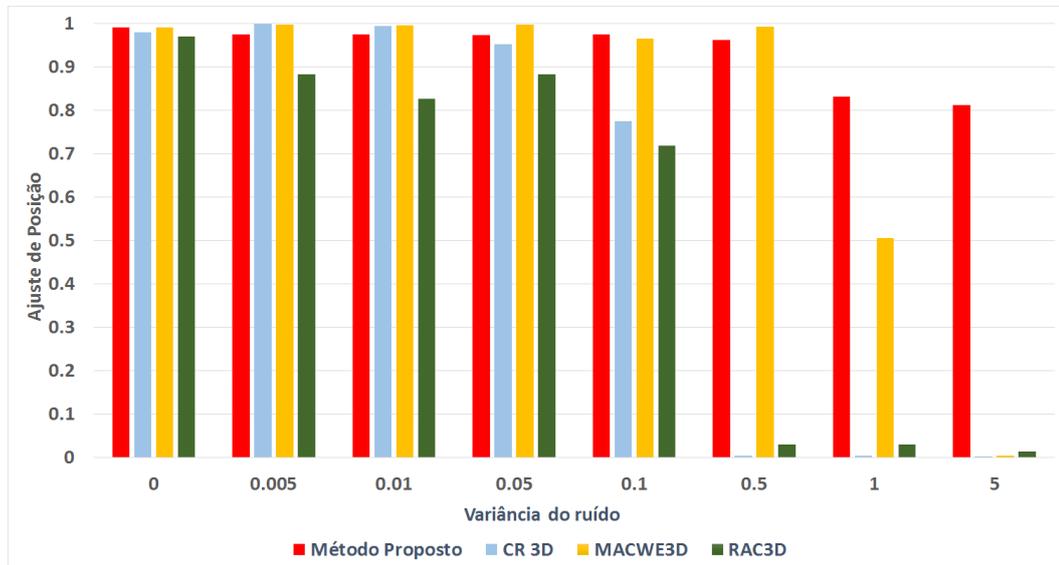


Figura 43 – Ajuste de posição baseado na variância do ruído para o volume do cubo.

Outra maneira de realizar a validação do método proposto é realizar a comparação com os métodos encontrados na literatura pesquisada pela variação das dimensões da janela, o valor médio para cada método, desvio padrão e tipo de volume selecionado. Os resultados com base nos coeficientes Dice e ajuste de posição podem ser vistos da Figura 38 até a Figura 41 e 42 até a Figura 45, respectivamente.

Pode-se observar que o algoritmo proposto obtém resultados com altas taxas de acerto, mesmo para variâncias maiores. Em relação aos algoritmos da literatura, obtém valores elevados na presença de ruído de baixa intensidade, mas quando a intensidade aumenta, esses valores diminuem substancialmente.

## 4.2 Resultados obtidos para exames de TC do Tórax

Os resultados são obtidos pelo processamento de 15 exames de TC do tórax, comparado com o padrão ouro gerado por pneumologistas e radiologistas. Estes resultados são divididos em três etapas. A primeira etapa é a análise comparativa de desempenho do algoritmo de inicialização automática para o método aplicado ao pulmão. A segunda etapa consiste na obtenção de resultados com a variação de dimensões da janela do método proposto. Por fim, a terceira etapa mostra os resultados obtidos para o algoritmo proposto na segmentação final com técnicas de segmentação.

### 4.2.1 Resultado obtidos para a inicialização automática

Para os resultados obtidos para a inicialização do algoritmo proposto com aplicação na segmentação dos pulmões, são apresentadas, por exame, 15 volumes finais. É ilustrado na Tabela 7 as variações da quantidade de raios e comprimento de raios para realizar a avaliação da inicialização. Nestes resultados são analisados a influência do comprimento e quantidade de raios em relação à segmentação final.

Tabela 7 – Variações do comprimento e quantidade de raios.

Variável	Variações( <i>voxels</i> )		
Quantidade de raios	60	80	100
Comprimento dos raios	60	80	100

Nestas análises considerada-se correta a inicialização que obtém um resultado final da segmentação com valores dos coeficientes acima de 0,9 em relação ao padrão ouro que é usado como referência para a verificação. A verificação desta condição é efetuada baseada nas métricas descritas na subseção 3.2.3 em relação ao padrão ouro.

Desta forma, é calculado um percentual de acerto para a segmentação de cada exame que consiste na média e desvio padrão dos valores para cada um dos valores de comprimento máximo do raio e quantidade de raios. Assim, geram-se os resultados para cada uma das dimensões das janelas 3, 5, 7 e 11 *voxels*. Assim, o valor da média e desvio padrão final para cada dimensão de janela são obtidos.

Os resultados obtidos para o coeficiente de similaridade Dice está ilustrado na Tabela 8. Desta forma, é possível verificar que, a partir do aumento da quantidade de raios e do comprimento do raio, a taxa do coeficiente Dice aumenta. Estas taxas, por exame, variam entre

0,59 até 0,96 com um desvio padrão variando entre 0,02 a 0,17.

Destaca-se o exame 15 no qual obtém a menor taxa relacionado com o coeficiente Dice, mas ainda com uma taxa acima de 0,6. Assim, é possível observar que, para este exame, a inicialização influencia de forma a não contribuir para uma melhor segmentação. No restante dos exames, é obtido uma taxa média de acima de 0,90. Embora se tenham diversos exames com doenças distintas e exames normais, é importante destacar a influência da inicialização em relação à segmentação final.

Tabela 8 – Coeficiente Dice de similaridade em relação à quantidade de raios e comprimento dos raios.

Exame	60 raios / 60 voxels	60 raios / 80 voxels	60 raios / 100 voxels	80 raios / 60 voxels	80 raios / 80 voxels	80 raios / 100 voxels	100 raios / 60 voxels	100 raios / 80 voxels	100 raios / 100 voxels
1	0.92 ± 0.11	0.93 ± 0.08	0.93 ± 0.05	0.92 ± 0.1	0.93 ± 0.06	0.93 ± 0.04	0.92 ± 0.1	0.93 ± 0.06	0.93 ± 0.03
2	0.93 ± 0.12	0.94 ± 0.07	0.94 ± 0.04	0.93 ± 0.11	0.94 ± 0.06	0.94 ± 0.03	0.93 ± 0.1	0.94 ± 0.05	0.94 ± 0.03
3	0.92 ± 0.12	0.93 ± 0.08	0.94 ± 0.06	0.92 ± 0.11	0.93 ± 0.07	0.94 ± 0.05	0.92 ± 0.1	0.94 ± 0.06	0.94 ± 0.03
4	0.89 ± 0.09	0.89 ± 0.05	0.89 ± 0.03	0.89 ± 0.08	0.89 ± 0.03	0.89 ± 0.02	0.89 ± 0.08	0.89 ± 0.03	0.89 ± 0.02
5	0.87 ± 0.1	0.88 ± 0.07	0.88 ± 0.04	0.87 ± 0.09	0.88 ± 0.05	0.89 ± 0.03	0.88 ± 0.09	0.88 ± 0.05	0.89 ± 0.03
6	0.94 ± 0.1	0.95 ± 0.06	0.95 ± 0.04	0.95 ± 0.09	0.95 ± 0.05	0.95 ± 0.03	0.95 ± 0.09	0.95 ± 0.05	0.95 ± 0.02
7	0.94 ± 0.11	0.95 ± 0.06	0.96 ± 0.04	0.94 ± 0.1	0.95 ± 0.05	0.96 ± 0.03	0.94 ± 0.1	0.96 ± 0.05	0.96 ± 0.02
8	0.89 ± 0.17	0.93 ± 0.12	0.95 ± 0.08	0.9 ± 0.16	0.94 ± 0.1	0.95 ± 0.07	0.9 ± 0.15	0.94 ± 0.1	0.95 ± 0.06
9	0.89 ± 0.16	0.92 ± 0.11	0.94 ± 0.08	0.9 ± 0.15	0.93 ± 0.1	0.94 ± 0.07	0.9 ± 0.15	0.93 ± 0.09	0.94 ± 0.06
10	0.93 ± 0.15	0.95 ± 0.1	0.96 ± 0.07	0.93 ± 0.14	0.95 ± 0.08	0.96 ± 0.06	0.94 ± 0.14	0.95 ± 0.08	0.96 ± 0.05
11	0.85 ± 0.14	0.89 ± 0.1	0.92 ± 0.08	0.86 ± 0.14	0.9 ± 0.09	0.93 ± 0.06	0.86 ± 0.13	0.91 ± 0.09	0.93 ± 0.06
12	0.93 ± 0.14	0.95 ± 0.1	0.95 ± 0.08	0.93 ± 0.13	0.95 ± 0.08	0.96 ± 0.06	0.93 ± 0.13	0.95 ± 0.08	0.96 ± 0.05
13	0.94 ± 0.12	0.95 ± 0.08	0.96 ± 0.06	0.95 ± 0.11	0.96 ± 0.06	0.96 ± 0.04	0.95 ± 0.1	0.96 ± 0.05	0.96 ± 0.03
14	0.77 ± 0.16	0.86 ± 0.13	0.91 ± 0.1	0.79 ± 0.16	0.88 ± 0.12	0.92 ± 0.08	0.8 ± 0.16	0.88 ± 0.11	0.92 ± 0.07
15	0.59 ± 0.11	0.63 ± 0.08	0.63 ± 0.05	0.6 ± 0.11	0.63 ± 0.07	0.64 ± 0.04	0.61 ± 0.11	0.63 ± 0.06	0.64 ± 0.03

Os resultados obtidos para o coeficiente de ajuste de tamanho estão ilustrados na Tabela 9. Desta forma, pode-se verificar que o algoritmo proposto obtém valores maiores para estes do que o Coeficiente Dice. Isto significa que, na segmentação final, quando avaliado o comprimento dos raios, os resultados se aproximam ao padrão-ouro. Assim, observa-se que, com o aumento da quantidade de raios e do comprimento do raio, a taxa do coeficiente de ajuste de tamanho aumenta. Os melhores resultados são obtidos quando se tem 80 raios e 100 *voxels* de comprimento máximo e quando se tem 100 raios e 100 *voxels* de comprimento. As taxas por exame variam entre 0,76 até 0,99 com um desvio padrão variando entre 0,02 à 0,16.

Os resultados obtidos para o coeficiente de ajuste de posição estão ilustrados na Tabela 10. Neste caso, o algoritmo obtém uma taxa acima de 0,9 em relação à posição final da segmentação para todos os exames. Desta forma, verifica-se que menores quantidades de raios e comprimento, o ajuste final da posição obtém uma taxa maior. As taxas por exame variam entre 0,94 até 1,00 com um desvio padrão variando entre 0,00 a 0,01.

Os resultados obtidos para o coeficiente de ajuste de forma estão ilustrados na Tabela

Tabela 9 – Ajuste de Tamanho em relação à quantidade de raios e comprimento dos raios.

Exame	60 raios / 60 voxels	60 raios / 80 voxels	60 raios / 100 voxels	80 raios / 60 voxels	80 raios / 80 voxels	80 raios / 100 voxels	100 raios / 60 voxels	100 raios / 80 voxels	100 raios / 100 voxels
1	0.95 +- 0.11	0.96 +- 0.08	0.96 +- 0.05	0.95 +- 0.1	0.96 +- 0.06	0.97 +- 0.04	0.95 +- 0.1	0.96 +- 0.06	0.97 +- 0.03
2	0.96 +- 0.12	0.97 +- 0.07	0.98 +- 0.05	0.97 +- 0.11	0.98 +- 0.06	0.98 +- 0.03	0.97 +- 0.11	0.98 +- 0.06	0.98 +- 0.03
3	0.94 +- 0.12	0.96 +- 0.08	0.96 +- 0.06	0.95 +- 0.11	0.96 +- 0.06	0.97 +- 0.04	0.95 +- 0.11	0.97 +- 0.06	0.97 +- 0.03
4	0.97 +- 0.1	0.98 +- 0.05	0.99 +- 0.04	0.97 +- 0.09	0.98 +- 0.04	0.99 +- 0.03	0.97 +- 0.09	0.98 +- 0.04	0.99 +- 0.02
5	0.92 +- 0.11	0.93 +- 0.07	0.94 +- 0.05	0.92 +- 0.09	0.93 +- 0.05	0.94 +- 0.04	0.92 +- 0.09	0.93 +- 0.05	0.94 +- 0.03
6	0.97 +- 0.1	0.98 +- 0.07	0.98 +- 0.04	0.97 +- 0.09	0.98 +- 0.06	0.98 +- 0.03	0.98 +- 0.09	0.98 +- 0.05	0.99 +- 0.03
7	0.95 +- 0.11	0.97 +- 0.06	0.98 +- 0.04	0.96 +- 0.1	0.97 +- 0.05	0.98 +- 0.03	0.96 +- 0.1	0.97 +- 0.05	0.98 +- 0.02
8	0.9 +- 0.17	0.95 +- 0.12	0.97 +- 0.08	0.92 +- 0.16	0.96 +- 0.11	0.97 +- 0.07	0.92 +- 0.16	0.96 +- 0.1	0.97 +- 0.06
9	0.91 +- 0.16	0.94 +- 0.11	0.96 +- 0.08	0.91 +- 0.15	0.95 +- 0.1	0.96 +- 0.07	0.92 +- 0.15	0.95 +- 0.09	0.96 +- 0.06
10	0.94 +- 0.15	0.96 +- 0.1	0.97 +- 0.07	0.95 +- 0.14	0.97 +- 0.08	0.97 +- 0.06	0.95 +- 0.14	0.97 +- 0.08	0.98 +- 0.05
11	0.86 +- 0.15	0.9 +- 0.1	0.94 +- 0.08	0.87 +- 0.14	0.92 +- 0.09	0.94 +- 0.06	0.87 +- 0.13	0.92 +- 0.08	0.95 +- 0.06
12	0.94 +- 0.14	0.96 +- 0.1	0.97 +- 0.08	0.94 +- 0.13	0.96 +- 0.08	0.97 +- 0.06	0.94 +- 0.13	0.96 +- 0.07	0.97 +- 0.05
13	0.95 +- 0.12	0.97 +- 0.08	0.97 +- 0.06	0.96 +- 0.11	0.97 +- 0.06	0.97 +- 0.04	0.96 +- 0.1	0.97 +- 0.05	0.98 +- 0.03
14	0.79 +- 0.16	0.88 +- 0.13	0.93 +- 0.1	0.81 +- 0.16	0.9 +- 0.12	0.94 +- 0.08	0.82 +- 0.16	0.9 +- 0.11	0.94 +- 0.07
15	0.76 +- 0.16	0.85 +- 0.13	0.89 +- 0.1	0.78 +- 0.16	0.86 +- 0.12	0.9 +- 0.08	0.79 +- 0.16	0.87 +- 0.11	0.91 +- 0.07

Tabela 10 – Ajuste de Posição em relação à quantidade de raios e comprimento dos raios.

Exame	60 raios / 60 voxels	60 raios / 80 voxels	60 raios / 100 voxels	80 raios / 60 voxels	80 raios / 80 voxels	80 raios / 100 voxels	100 raios / 60 voxels	100 raios / 80 voxels	100 raios / 100 voxels
1	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.0
2	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
3	0.99 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0
4	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0
5	1.0 +- 0.01	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.01	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0
6	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0
7	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
8	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
9	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.01	0.99 +- 0.0	1.0 +- 0.01	1.0 +- 0.01	0.99 +- 0.0	1.0 +- 0.01	1.0 +- 0.0
10	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0
11	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0
12	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.01	1.0 +- 0.0
13	0.9 +- 0.0	0.91 +- 0.0	0.91 +- 0.0	0.91 +- 0.0	0.92 +- 0.0	0.92 +- 0.0	0.91 +- 0.0	0.92 +- 0.01	0.92 +- 0.0
14	0.99 +- 0.0	1.0 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.01	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.01
15	0.94 +- 0.01	0.95 +- 0.01	0.94 +- 0.0	0.94 +- 0.0	0.95 +- 0.0	0.94 +- 0.0	0.94 +- 0.0	0.95 +- 0.0	0.94 +- 0.0

Tabela 11 – Ajuste de Forma em relação à quantidade de raios e comprimento dos raios.

Exame	60 raios / 60 voxels	60 raios / 80 voxels	60 raios / 100 voxels	80 raios / 60 voxels	80 raios / 80 voxels	80 raios / 100 voxels	100 raios / 60 voxels	100 raios / 80 voxels	100 raios / 100 voxels
1	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.0
2	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
3	0.99 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0
4	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0
5	1.0 +- 0.01	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.01	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0
6	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0
7	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
8	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
9	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.01	0.99 +- 0.0	1.0 +- 0.01	1.0 +- 0.01	0.99 +- 0.0	1.0 +- 0.01	1.0 +- 0.0
10	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0
11	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0
12	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.01	1.0 +- 0.0	1.0 +- 0.01	1.0 +- 0.01	1.0 +- 0.0
13	0.9 +- 0.0	0.91 +- 0.0	0.91 +- 0.0	0.91 +- 0.0	0.92 +- 0.0	0.92 +- 0.0	0.91 +- 0.0	0.92 +- 0.01	0.92 +- 0.0
14	0.99 +- 0.0	1.0 +- 0.01	0.99 +- 0.01	0.99 +- 0.0	1.0 +- 0.0	0.99 +- 0.01	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.01
15	0.94 +- 0.01	0.95 +- 0.01	0.94 +- 0.0	0.94 +- 0.0	0.95 +- 0.0	0.94 +- 0.0	0.94 +- 0.0	0.95 +- 0.0	0.94 +- 0.0

11. Neste caso, o algoritmo obtém uma taxa menor, compara-se em relação outras métricas, mas ainda obtém uma taxa com valores acima de 0,9.

A partir dos resultados obtidos, é possível perceber que a inicialização pode influen-

ciar diretamente na segmentação final. Os melhores resultados são produzidos quando se tem 80 raios e 100 *voxels* de comprimento máximo e 100 raios e 100 *voxels* de comprimento.

#### 4.2.2 Resultados obtidos para variação das dimensões da janela

É ilustrado na Tabela 7 as variações das dimensões utilizadas para obter os resultados. Neste resultado será analisado a influência da dimensão e quantidade de raios em relação à segmentação final.

Tabela 12 – Variações das dimensões de janelas.

Variável	Variações( <i>voxels</i> )
Dimensões de janelas	$3 \times 3 \times 3, 5 \times 5 \times 5, 7 \times 7 \times 7, 11 \times 11 \times 11$

Nesta avaliação, usam-se as métricas: Coeficiente Dice de similaridade, Ajuste de forma, ajuste de posição e ajuste de tamanho. Nestes resultados, são analisadas as segmentações finais de acordo com a variação da janela utilizada no algoritmo proposto. Para a análise da segmentação é considerado uma taxa elevada, os resultados que estão acima de 0,9 para estes coeficientes. A verificação desta condição é efetuada baseada nas métricas descritas na subseção 3.2.3 em relação ao padrão ouro.

Além dos valores para cada um dos coeficientes são calculados a média e o desvio padrão sendo calculado para cada exame variando a dimensão da janela 3, 5, 7 e 11 *voxels*. Para cada exame e cada conjunto de dimensão de janela, é gerado o resultado com a variação da quantidade de raios e comprimento máximo de raios.

A primeira métrica a ser analisada é o coeficiente de similaridade Dice, cujos resultados estão na Tabela 13. Nesta tabela, observa-se que com o aumento das dimensões da janela, o valor do coeficiente de similaridade Dice aumenta. Estes variam entre 0,55 a 0,96 com um desvio padrão variando entre 0,00 à 0,13.

É possível observar que a dimensão da janela pode influenciar de forma direta no resultado final da segmentação, produzindo uma diferença no resultado final obtido. Visto que se tem diversos exames com doenças distintas e normais, é importante observar a influência da dimensão da janela utilizada em relação à segmentação final mas sempre em uma relação direta. Assim, o aumento nas dimensões das janelas, aumenta também a precisão da segmentação para cada exame.

Os resultados obtidos para o coeficiente de ajuste de tamanho são mostrados na

Tabela 13 – Coeficiente Dice de similaridade em relação à dimensão da janela.

Exame	3 x 3 x 3	5 x 5 x 5	7 x 7 x 7	11 x 11 x 11
1	0.85 +- 0.07	0.88 +- 0.06	0.92 +- 0.02	0.93 +- 0.0
2	0.87 +- 0.08	0.92 +- 0.02	0.94 +- 0.01	0.94 +- 0.0
3	0.85 +- 0.08	0.88 +- 0.07	0.92 +- 0.04	0.94 +- 0.01
4	0.85 +- 0.07	0.87 +- 0.04	0.89 +- 0.01	0.89 +- 0.0
5	0.82 +- 0.07	0.84 +- 0.06	0.86 +- 0.03	0.89 +- 0.01
6	0.89 +- 0.07	0.94 +- 0.03	0.95 +- 0.01	0.95 +- 0.0
7	0.90 +- 0.09	0.94 +- 0.06	0.95 +- 0.03	0.96 +- 0.01
8	0.79 +- 0.12	0.81 +- 0.11	0.88 +- 0.08	0.95 +- 0.02
9	0.78 +- 0.11	0.81 +- 0.09	0.87 +- 0.06	0.94 +- 0.02
10	0.84 +- 0.1	0.86 +- 0.1	0.91 +- 0.07	0.96 +- 0.01
11	0.79 +- 0.11	0.8 +- 0.1	0.83 +- 0.08	0.93 +- 0.03
12	0.83 +- 0.09	0.86 +- 0.09	0.9 +- 0.07	0.96 +- 0.01
13	0.88 +- 0.08	0.92 +- 0.07	0.94 +- 0.04	0.96 +- 0.01
14	0.73 +- 0.13	0.75 +- 0.13	0.8 +- 0.12	0.92 +- 0.05
15	0.55 +- 0.08	0.56 +- 0.08	0.58 +- 0.07	0.64 +- 0.02

Tabela 14. Neste caso é possível observar que o algoritmo proposto obtém valores maiores do que o Coeficiente Dice. Isto significa que na segmentação final quando avaliado o tamanho de cada pulmão, os resultados se aproximam ao padrão-ouro. Entretanto, os melhores resultados são encontrados quando se tem 80 raios e 100 *voxels* de comprimento máximo e quando temos 100 raios e 100 *voxels* de comprimento.

Tabela 14 – Ajuste de Tamanho em relação às dimensões das janelas.

Exame	3 x 3 x 3	5 x 5 x 5	7 x 7 x 7	11 x 11 x 11
1	0.88 +- 0.07	0.92 +- 0.06	0.95 +- 0.02	0.97 +- 0.01
2	0.9 +- 0.09	0.96 +- 0.03	0.97 +- 0.01	0.98 +- 0.01
3	0.88 +- 0.09	0.91 +- 0.07	0.95 +- 0.04	0.97 +- 0.01
4	0.94 +- 0.08	0.96 +- 0.05	0.98 +- 0.02	0.99 +- 0.01
5	0.86 +- 0.08	0.89 +- 0.06	0.92 +- 0.04	0.94 +- 0.01
6	0.92 +- 0.07	0.97 +- 0.03	0.98 +- 0.01	0.99 +- 0.01
7	0.92 +- 0.09	0.96 +- 0.06	0.97 +- 0.03	0.98 +- 0.01
8	0.81 +- 0.12	0.84 +- 0.11	0.9 +- 0.08	0.97 +- 0.02
9	0.8 +- 0.11	0.83 +- 0.1	0.9 +- 0.06	0.96 +- 0.02
10	0.85 +- 0.11	0.88 +- 0.1	0.93 +- 0.07	0.98 +- 0.01
11	0.8 +- 0.11	0.82 +- 0.11	0.85 +- 0.09	0.95 +- 0.03
12	0.85 +- 0.09	0.87 +- 0.09	0.92 +- 0.07	0.97 +- 0.01
13	0.9 +- 0.09	0.93 +- 0.07	0.96 +- 0.04	0.98 +- 0.01
14	0.76 +- 0.13	0.78 +- 0.13	0.83 +- 0.12	0.94 +- 0.05
15	0.72 +- 0.13	0.74 +- 0.13	0.79 +- 0.12	0.91 +- 0.05

Em relação ao coeficiente de ajuste de posição, os resultados obtidos estão na Tabela

15. Observa-se que há uma baixa variação de valores do coeficiente indicando praticamente nenhuma influência das dimensões da janela sobre este coeficiente.

Tabela 15 – Ajuste de Posição em relação às dimensões das janelas.

Exame	3 x 3 x 3	5 x 5 x 5	7 x 7 x 7	11 x 11 x 11
1	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0
2	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
3	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0
4	1.0 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0
5	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0
6	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
7	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
8	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0
9	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0
10	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0
11	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.01	0.99 +- 0.0
12	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
13	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0	1.0 +- 0.0
14	0.99 +- 0.0	0.99 +- 0.0	0.99 +- 0.0	1.0 +- 0.0
15	0.94 +- 0.0	0.94 +- 0.0	0.94 +- 0.01	0.95 +- 0.0

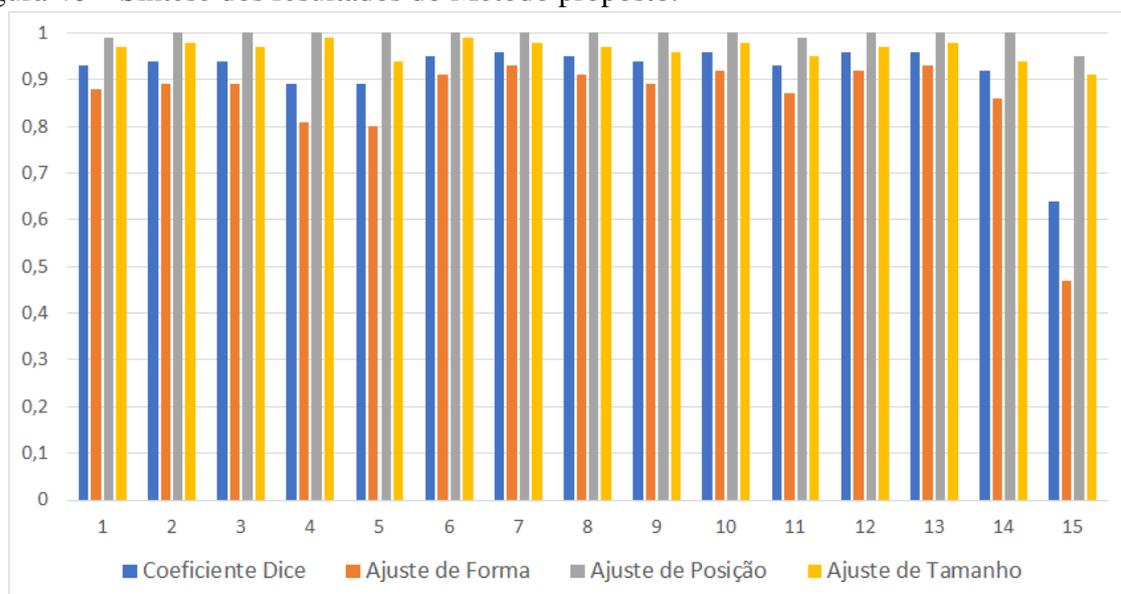
Por fim, obtém-se os resultados para o coeficiente de ajuste de forma que podem ser vistos na Tabela 16. Esta métrica realiza a avaliação da forma final da segmentação comparada com o padrão ouro. Baseado nos resultados obtidos, destaca-se que as dimensões das janelas têm uma influência na forma final da segmentação. Assim, para dimensões menores de janela, a forma final se distancia do padrão ouro, mas quando aumenta a dimensão da janela, os valores deste coeficiente se elevam.

Tabela 16 – Ajuste de Forma em relação às dimensões das janelas.

Exame	3 x 3 x 3	5 x 5 x 5	7 x 7 x 7	11 x 11 x 11
1	0.74 +- 0.09	0.79 +- 0.08	0.85 +- 0.04	0.88 +- 0.01
2	0.77 +- 0.11	0.86 +- 0.04	0.88 +- 0.01	0.89 +- 0.01
3	0.73 +- 0.1	0.79 +- 0.09	0.85 +- 0.06	0.89 +- 0.01
4	0.74 +- 0.09	0.77 +- 0.05	0.8 +- 0.02	0.81 +- 0.0
5	0.69 +- 0.09	0.72 +- 0.07	0.76 +- 0.05	0.8 +- 0.01
6	0.81 +- 0.1	0.88 +- 0.05	0.9 +- 0.01	0.91 +- 0.0
7	0.82 +- 0.12	0.89 +- 0.09	0.91 +- 0.05	0.93 +- 0.01
8	0.65 +- 0.12	0.69 +- 0.13	0.78 +- 0.11	0.91 +- 0.04
9	0.63 +- 0.11	0.68 +- 0.11	0.78 +- 0.08	0.89 +- 0.03
10	0.72 +- 0.12	0.76 +- 0.12	0.83 +- 0.1	0.92 +- 0.02
11	0.65 +- 0.12	0.67 +- 0.11	0.72 +- 0.1	0.87 +- 0.05
12	0.71 +- 0.11	0.75 +- 0.11	0.82 +- 0.1	0.92 +- 0.02
13	0.79 +- 0.11	0.85 +- 0.1	0.9 +- 0.06	0.93 +- 0.01
14	0.58 +- 0.13	0.61 +- 0.13	0.67 +- 0.13	0.86 +- 0.08
15	0.38 +- 0.07	0.39 +- 0.07	0.41 +- 0.06	0.47 +- 0.02

São ilustrados na Figura 46 os resultados obtidos, por exame, para cada métrica utilizada para avaliação. Para obter estes resultados, cada exame o melhor resultado foi obtido com a respectiva configuração e este foi ilustrado no gráfico. A partir deste gráfico, é possível observar que as taxas do coeficiente de similaridade atingem valores acima de 0,9. Já o coeficiente de similaridade *Dice* conserva a sensibilidade do conjuntos de dados mais homogêneos e atribui menos peso aos valores heterogêneos..

Figura 46 – Síntese dos resultados do Método proposto.



Em relação ao ajuste de posição e ao ajuste de tamanho o algoritmo proposto nesta

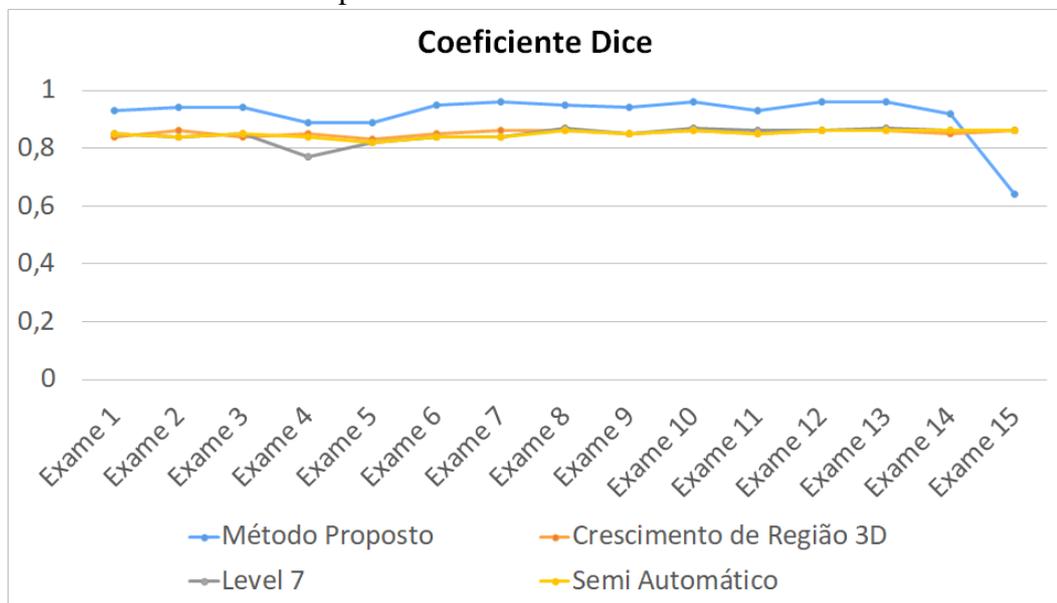
tese possui valores acima de 0,9 chegando a 1,0. Portanto, pode-se concluir que a segmentação final possui a posição final e o tamanho, volume, final próxima ao padrão-ouro. Já em relação ao ajuste de forma, em alguns dos exames, são obtidas taxas inferiores a 0,9 e outras acima, em que se conclui que a forma final da segmentação se distancia um pouco em relação ao padrão-ouro. Estes casos ocorrem devido à variação da intensidade do ruído e a posição inicial das sementes.

#### 4.2.3 Resultados obtidos para os algoritmos avaliados

Nesta subseção são apresentados os resultados obtidos para o método proposto e os métodos do Crescimento de Região 3D (GONZALEZ *et al.*, 2009), *Level Set* (ACTON; RAY, 2009) e um método semi-automático (CHEIMARIOTIS *et al.*, 2017) de segmentação para os 15 exames utilizados nesta tese.

Uma comparação é ilustrada na Figura 47 entre os coeficientes de similaridade Dice obtidos em cada exame estudado nesta tese para cada método aplicado. Assim, verifica-se que o método proposto obtém melhores resultados nos 14 primeiros exames, exceto no último exame que obtém um valor baixo para o coeficiente Dice.

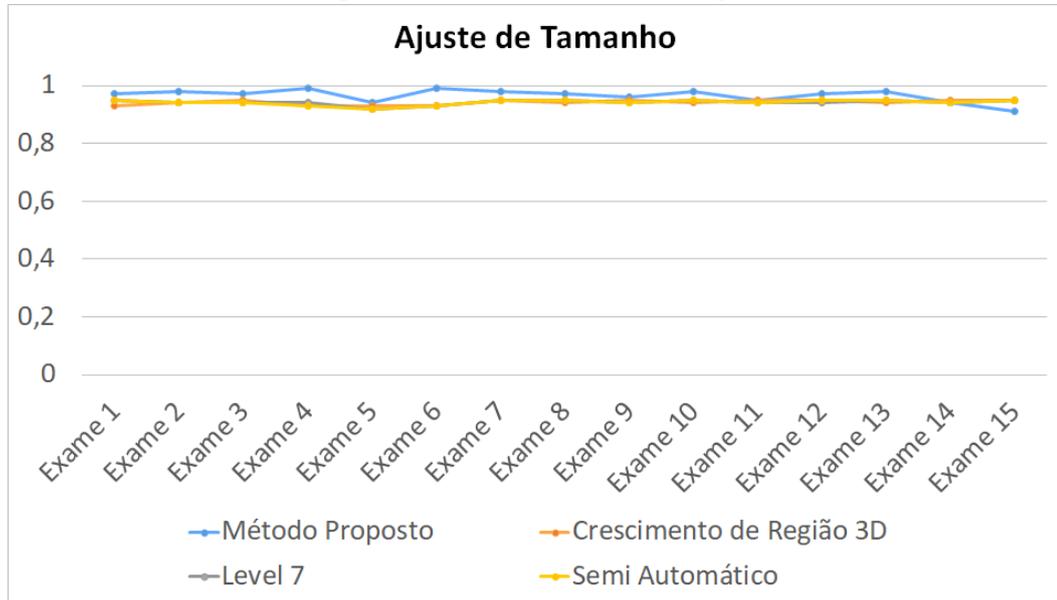
Figura 47 – Resultados obtidos para os métodos baseado no coeficiente Dice.



É ilustrado na Figura 48 o resultado da aplicação da métrica de ajuste de tamanho aos resultados dos algoritmos abordados nesta tese. Assim, observa-se que os resultados obtidos para esta métrica estão próximo ao padrão ouro. O método proposto obtém um melhor resultado em quase todos os exames, exceto o exame 15. Em alguns exames, 4, 6, 10 e 13, o método

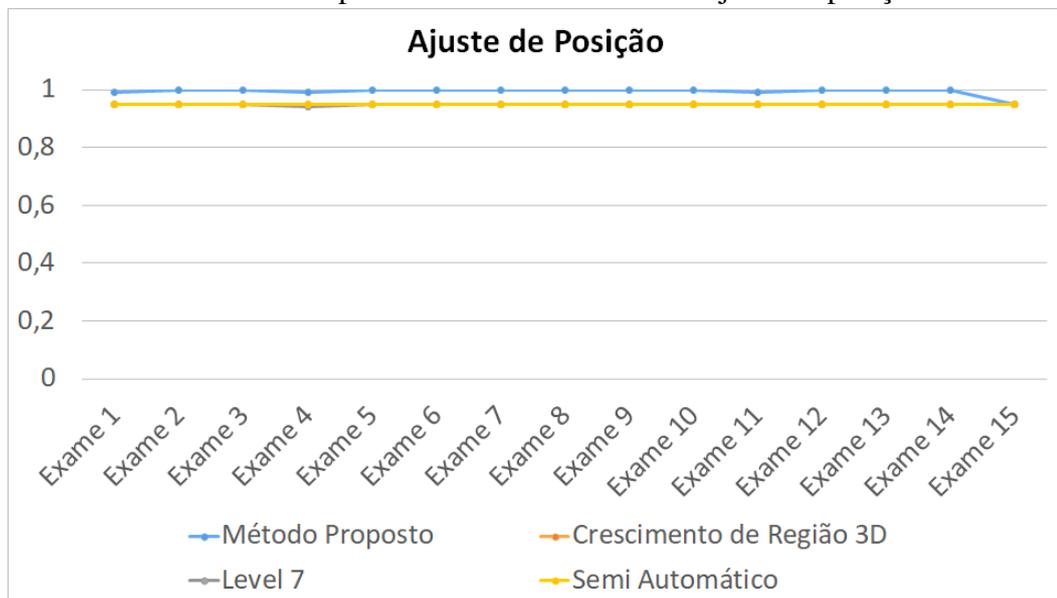
proposto obtém a taxa próxima a 1, com seu menor valor obtido para o exame 15.

Figura 48 – Resultados obtidos para os métodos baseado no ajuste de tamanho.



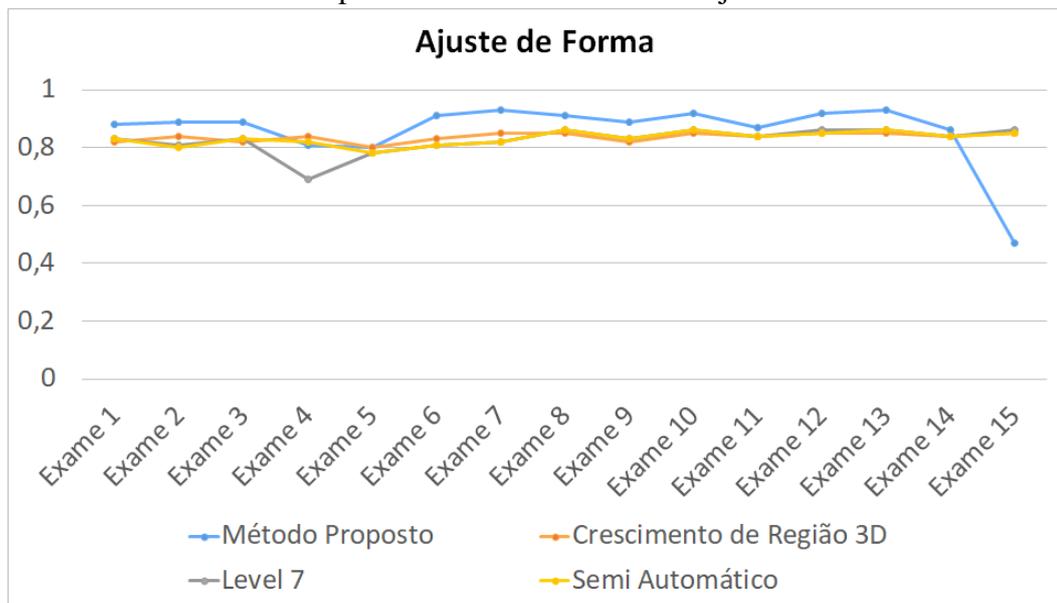
Em relação ao coeficiente de ajuste de posição, o resultado comparativo entre o método proposto e das outras técnicas podem ser observados na Figura 49. Nesta Figura é possível observar que os algoritmos se comportam de maneira semelhante em relação à posição final da segmentação. Portanto, os resultados são próximos, mas o método proposto ainda obtém valores maiores comparados com os algoritmos avaliados nesta tese, que por exame, variam entre 0,94 até 1,00 com um desvio padrão variando entre 0,00 a 0,01.

Figura 49 – Resultados obtidos para os métodos baseado no ajuste de posição.



Por fim, a análise é feita baseado no coeficiente de ajuste de forma. O resultado do comparativo entre os métodos pode ser visto na Figura 50. Baseado nos resultados obtidos, observa-se que os valores do coeficiente ajustem de forma possui uma maior variação comparado com as outras métricas. Em relação a esta métrica, os valores deste coeficiente obtidos pelos algoritmos variaram entre 0,7 e 0,95, no qual em alguns exames o resultado da segmentação se distancia do seu padrão ouro.

Figura 50 – Resultados obtidos para os métodos baseado no ajuste de forma.



Com base nos resultados obtidos para o método proposto, tanto na segmentação de imagens sintéticas quanto para imagens de TC de tórax, bem como para os demais métodos avaliados, algumas conclusões podem ser obtidas. O método proposto possui um elevado nível de estabilidade na presença de ruído, mesmo este possuindo uma alta intensidade. É possível observar também que de acordo com o aumento das dimensões das janelas, da quantidade de raios e dos comprimentos dos raios melhores é a segmentação final realizada pelo método proposto.

## 5 CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Nesta tese é proposto um método de segmentação para estruturas 3D, capaz de realizar a segmentação de imagens gerais e o pulmão em imagens de TC do tórax. Para compor este método, são propostos e descritos um método de segmentação baseado em autômatos 3D, um método de segmentação de mais de uma estrutura 3D de forma simultânea, energia para método de segmentação 3D baseado em composição de forças no espaço RGB e um método de inicialização automática para segmentação de pulmões.

Para verificar o desempenho do algoritmo proposto, são realizados testes de segmentação em imagens sintéticas. Assim, são utilizados tamanhos diferentes de janelas, volumes diferentes e níveis diferentes de ruído. Ainda nestes testes é realizada uma comparação com os métodos do CR3D (GONZALEZ *et al.*, 2009), MACWE3D (NEILA *et al.*, 2014) e RAC3D (ALMEIDA *et al.*, 2017). Os resultados obtidos para estas imagens são avaliados de acordo com o coeficiente de similaridade Dice e o ajuste de posição. Tais resultados comprovam que o algoritmo proposto funciona adequadamente tanto para imagens com baixo e alto nível de ruído, para todos os objetos sintéticos testados, com relação com medidas de ajuste de posição e coeficiente Dice acima de 0.95. Em geral, o método proposto obtém valores de coeficientes acima do que os demais algoritmos avaliados. Acredita-se que é devido a flexibilidade intrínseca da composição das forças no espaço RGB e a expansão para 3D.

Os resultados obtidos pelo método de inicialização automática do algoritmo proposto. Tal método utiliza funções de centróide que possuem o objetivo de definir sementes nas regiões da base, do hilo e do ápice. A partir destes pontos são gerados raios no sentido do pulmão com o objetivo de adicionar pontos na inicialização de forma espaçados na região à ser segmentada auxiliando assim em uma segmentação uniforme.

Para validar a acurácia do método de inicialização proposto, é verificados o resultado final da segmentação de acordo com a variação dos tamanhos máximos de raios e a quantidade de raios. Para realizar a validação foram utilizadas as medidas de similaridade Dice, medidas de ajuste de posição, forma e tamanho. Para as 135, 15 exames e 9 combinações de tamanhos e quantidade de raios, inicializações realizadas, foi possível observar que de acordo com o aumento da quantidade de raios e tamanho dos raios, maior as taxas aumentam. Desta forma o algoritmo proposto obteve uma taxa de acima de 0,6, no pior caso, baseado no coeficiente de similaridade Dice. Chegando à uma taxa média de acima de 0.90 no restante dos casos. Em relação às outras métricas as taxas variam 0.9 até 1.0, o que indica que o algoritmo consegue realizar bem a

segmentação do pulmão de forma automática.

Para que o algoritmo proposto realize uma segmentação correta dos pulmões, é necessário verificar a influência do tamanho da janela utilizada para o momento da evolução do algoritmo. Para realizar a validação foram utilizadas as medidas de similaridade Dice, medidas de ajuste de posição, forma e tamanho. Para os 60, 4 tamanhos de janelas e 15 exames, possibilidades de evoluções, foi possível observar que de acordo com o aumento do tamanho da janela, maior é a taxa de obtida no final da segmentação. Desta forma o algoritmo proposto obteve uma taxa de acima de 0.5, no pior caso, baseado no coeficiente de similaridade Dice. Chegando à uma taxa média de acima de 0,90 no restante dos casos. Em relação às outras métricas as taxas variam 0.9 até 1.0, o que indica que o algoritmo consegue realizar bem a segmentação do pulmão de forma automática.

Para verificar o desempenho do algoritmo proposto, são realizados testes de segmentação em 15 exames de imagens de TC do pulmão com diversas patologias. Assim, para realizar a verificação final do método, é realizada uma comparação com os métodos do CR3D (GONZALEZ *et al.*, 2009), Level Set (ACTON; RAY, 2009) e o método semi automático no qual necessita a intervenção do especialista para realizar a segmentação. As segmentações são avaliadas de acordo com o coeficiente de similaridade Dice e o ajuste de posição. O algoritmo proposto foi superior na maioria dos exames abordados nesta tese, tendo um desempenho menor só em relação ao exame 15 quando comparando a forma final da segmentação e a similaridade Dice.

As contribuições dos trabalhos são método de segmentação baseado em autômatos 3D que utiliza uma composição de forças no espaço RGB, a geração de energia para método de segmentação 3D baseado em composição de forças no espaço RGB e um método de inicialização automática para segmentação de pulmões.

O sucesso da segmentação baseado no algoritmo proposto, bem como a utilização da inicialização proposta, estimula o desenvolvimento de pesquisas que podem ser sugeridas como trabalhos futuros, como por exemplo:

- estudo do impacto de outras agregações de forças no espaço RGB;
- estudo da variação de tamanhos maiores e maiores quantidades de raios na inicialização;
- levantamento e análise de tempo de processamento e eficiência computacional na segmentação pulmonar;
- implementação de métodos de segmentação de estruturas pulmonares de forma paralela e

utilizando de unidade de processamento gráfico;

- realizar a verificação de aplicação do algoritmo proposto em outras estruturas do corpo humano por exemplo fígado, cérebro, vasos sanguíneos, nódulos, vias aéreas; e
- integração do método proposto ao Sistema de Análise de Imagens Pulmonares (LISA), registrado para fins de pesquisa na área médica.

## REFERÊNCIAS

- ABDULLAH-AL-WADUD, M.; KABIR, M. H.; DEWAN, M. A. A.; CHAE, O. A dynamic histogram equalization for image contrast enhancement. **IEEE Transactions on Consumer Electronics**, v. 53, n. 2, p. 593–600, May 2007.
- ACTON, S.; RAY, N. **Biomedical Image Analysis: Segmentation**. Morgan Claypool, 2009. 108- p. ISBN 9781598290219. Disponível em: <<https://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6812688>>.
- AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face description with local binary patterns: Application to face recognition. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 28, n. 12, p. 2037–2041, Dec 2006. ISSN 0162-8828.
- AL-HAJ, A.; ABDEL-NABI, H. Digital image security based on data hiding and cryptography. In: **2017 3rd International Conference on Information Management (ICIM)**. [S.l.: s.n.], 2017. p. 437–440.
- ALEXANDRIA, A. R. de. **Psnakes: method of active contours using radial energy Hilbertiana for segmentation of the left ventricle in ultrasound images**. 2011. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2011.
- ALMEIDA, T. M. de; CAVALCANTE, T. da S.; CORTEZ, P. C. 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.
- ARIYÜREK, M. O.; GÜLSÜN, M.; DEMIRKAZIK, F. Accessory fissures of the lung: evaluation by high-resolution computed tomography. **European Radiology**, Springer-Verlag, v. 11, n. 12, p. 2449–2453, 2001. ISSN 0938-7994. Disponível em: <<http://dx.doi.org/10.1007/s003300100852>>.
- BALOCCO, S.; GATTA, C.; CIOMPI, F.; PUJOL, O.; CARRILLO, X.; MAURI, J.; RADEVA, P. Combining growcut and temporal correlation for ivus lumen segmentation. In: \_\_\_\_\_. **Pattern Recognition and Image Analysis: 5th Iberian Conference, IbPRIA 2011, Las Palmas de Gran Canaria, Spain, June 8-10, 2011. Proceedings**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. p. 556–563. ISBN 978-3-642-21257-4.
- BANON, G. J. F.; BARREIRA, J. **Bases da Morfologia Matemática para a análise de imagens binárias**. 2ed. ed. [S.l.]: INPE, 1998.
- BERNSEN, J. Dynamic thresholding of gray-level images. In: **International Conference on Pattern Recognition**. [S.l.: s.n.], 1986.
- BESSA, J. A.; CORTEZ, P. C.; FÉLIX, J. H. da S.; NETO, A. R. da R.; ALEXANDRIA, A. R. de. Radial snakes: Comparison of segmentation methods in synthetic noisy images. **Expert Systems with Applications**, v. 42, n. 6, p. 3079 – 3088, 2015. ISSN 0957-4174.
- BOUHOURS, A. **Segmentation of the left ventricle in echocardiography using active contours (snake)**, 2006. Dissertação (Mestrado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2006.

BURGER, W.; BURGE, M. J. **Digital Image Processing: An Algorithmic Introduction using Java**. 1. ed. Nova York, EUA: Springer, 2007. 566 p. ISBN 978-1-84628-379-6.

CAVALCANTE, T. da S. **Análise Comparativa de Técnicas para Segmentação Automática de Vias Aéreas em Imagens de Tomografia Computadorizada do Tórax**. Dissertação (Mestrado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2010.

CAVALCANTE, T. da S. **Método de superfícies ativas usando Local Binary Patterns(LBP) aplicado na segmentação de lobos pulmonares em imagens de Tomografia Computadorizada do Tórax**. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2016.

CAVALCANTI NETO, E.; GOMES, S. L.; FILHO, P. P. R.; ALBUQUERQUE, V. H. C. de. Brazilian vehicle identification using a new embedded plate recognition system. **Measurement**, v. 70, p. 36 – 46, 2015. ISSN 0263-2241.

CAVALCANTI NETO, E.; MAYA, H. C.; VARELA, A. T.; MACHADO, M.; ALEXANDRIA, A. R. de. Depth calculation using computer vision and sift. In: ELLEITHY, K.; SOBH, T.; ISKANDER, M.; KAPILA, V.; KARIM, M. A.; MAHMOOD, A. (Ed.). **Technological Developments in Networking, Education and Automation**. [S.l.]: Springer Netherlands, 2010. p. 253–256. ISBN 978-90-481-9150-5.

CHA, J. W.; FARHANGI, M. M.; DUNLAP, N.; AMINI, A. Volumetric analysis of respiratory gated whole lung and liver ct data with motion-constrained graph cuts segmentation. In: **2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. [S.l.: s.n.], 2017. p. 3405–3408. ISSN 1557-170X.

CHABRIER, S.; ROSENBERGER, C.; LAURENT, H.; EMILE, B.; MARCHÉ, P. Evaluating the segmentation result of a gray level image. In: **2004 12th European Signal Processing Conference**. [S.l.: s.n.], 2004. p. 953–956.

CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266–277, Feb 2001. ISSN 1057-7149.

CHEIMARIOTIS, G.; AL-MASHAT, M.; HARIS, K.; ALETRAS, A.; JöGI, J.; BAJC, M.; MAGLAVERAS, N.; HEIBERG, E. Automatic lung segmentation in functional spect images using active shape models trained on reference lung shapes from ct. v. 32, 12 2017.

CHEN, S.; CAO, L.; LIU, J.; TANG, X. Automatic segmentation of lung fields from radiographic images of sars patients using a new graph cuts algorithm. **Proceedings of the 18th International Conference on Pattern Recognition(ICPR'06)**, 2006.

CHEN, X.; UDUPA, J. K.; BAGCI, U.; ZHUGE, Y.; YAO, J. Medical image segmentation by combining graph cuts and oriented active appearance models. **IEEE Transactions on Image Processing**, v. 21, n. 4, p. 2035–2046, April 2012.

CHO, Z. H.; JONES, J. P.; SINGH, M. **Fundamental of Medical Imaging**. [S.l.]: John Wiley & Sons, 1993.

CORDEIRO, F. R.; SANTOS, W. P.; SILVA-FILHO, A. G. An adaptive semi-supervised fuzzy growcut algorithm to segment masses of regions of interest of mammographic images. **Applied Soft Computing**, v. 46, p. 613 – 628, 2016. ISSN 1568-4946.

- DELMAS, P.; COULON, P. Y.; FRISTOT, V. Automatic snakes for robust lip boundaries extraction. In: **Proceedings of the Acoustics, Speech, and Signal Processing, 1999. On 1999 IEEE International Conference - Volume 06**. Washington, DC, USA: IEEE Computer Society, 1999. (ICASSP '99), p. 3069–3072. ISBN 0-7803-5041-3.
- 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.
- DESHMUKH, S.; VAIKOLE, S.; SAWARKAR, S. Automatic segmentation of moving object in video using gmec. In: **2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPE5)**. [S.l.: s.n.], 2016. p. 824–829.
- DHAWAN, A. P.; HUANG, H. K.; KIM, D.-S. **Principles and Advanced Methods in Medical Imaging and Image Analysis**. [S.l.]: World Scientific, 2008.
- DOUGHERTY, G. **Digital Image Processing for Medical Applications**. [S.l.]: Cambridge, 2009.
- DRUMMOND, G. B. Computed tomography and pulmonary measurements. **British Journal of Anaesthesia**, Edinburgh-Royal Infirmary, v. 80, p. 665–671, 1998.
- EL-BAZ, A.; FARAG, A.; GIMEL, G.; FALK, R.; MOHAMEDA.EL-GHAR; ELDIASTY, T. A framework for automatic segmentation of lung nodules from low dose chestctscans. **The 18th International Conference on Pattern Recognition (ICPR'06) IEEE**, 2006.
- ELYOR, K.; LEE, G. Automatic object segmentation using mean shift and growcut. In: **The 19th Korea Japan Joint Workshop on Frontiers of Computer Vision**. [S.l.: s.n.], 2013.
- EPSTEIN, C. L. **The Mathematics of Medical Imaging**. [S.l.]: Prentice Hall, 2003.
- EUROSTAT. **Eurostat - Your key to European statistics**. 2017. Disponível em: <<http://ec.europa.eu/eurostat>>.
- EVERHART, J. J.; CANNON, T. M.; NEWELL, J. J. D.; LYNCH, D. Image segmentation applied to CT examination of lymphangioliomyomatosis. In: LOEW, M. H. (Ed.). Newport Beach, EUA: SPIE, 1994. v. 2167, n. 1, p. 87–95.
- FARHANGI, M. M.; FRIGUI, H.; SEOW, A.; AMINI, A. A. 3d active contour segmentation based on sparse linear combination of training shapes (scots). **IEEE Transactions on Medical Imaging**, PP, n. 99, p. 1–1, 2017. ISSN 0278-0062.
- FELIX, J. H. D. S.; CORTEZ, P. C.; CAVALCANTE, T. D. S.; ALEXANDRIA, A. R.; HOLANDA, M. D. A. Autoin: Method of automatic initialization of active contours applied to lungs in ct images. **IEEE Latin America Transactions**, v. 10, n. 4, p. 1954–1960, June 2012.
- FÉLIX, J. H. S. **Methods of Active Contours in Hilbert 2D image segmentation of lungs in CT of the Chest**. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2011.
- FELIX, J. H. S. **Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar**. Dissertação (Mestrado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2007.

FELIX, J. H. S.; CORTEZ, P. C.; HOLANDA, M. A.; COSTA, R. C. S. Automatic segmentation and measurement of the lungs in healthy persons and in patients with chronic obstructive pulmonary disease in ct images. In: . Margarita Island, Venezuela: V Latin American Congress on Biomedical Engineering 2007, Bioengineering Solutions for Latin America Health, 2007. v. 18, p. 370–373.

FLOREA, C.; VERTAN, C. Dynamic range enhancement in digital camera acquisition of prostheses hip xrays. In: **2007 International Symposium on Signals, Circuits and Systems**. [S.l.: s.n.], 2007. v. 1, p. 1–4.

GAO, M.; CHEN, H.; ZHENG, S.; FANG, B.; ZHANG, L. Texture image segmentation using fused features and active contour. In: **2016 23rd International Conference on Pattern Recognition (ICPR)**. [S.l.: s.n.], 2016. p. 2036–2041.

GE, Q.; LI, C.; SHAO, W.; LI, H. A hybrid active contour model with structured feature for image segmentation. **Signal Processing**, v. 108, p. 147 – 158, 2015. ISSN 0165-1684. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165168414004174>>.

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

GHOSH, P.; ANTANI, S. K.; LONG, L. R.; THOMA, G. R. Unsupervised grow-cut: Cellular automata-based medical image segmentation. In: **2011 IEEE First International Conference on Healthcare Informatics, Imaging and Systems Biology**. [S.l.: s.n.], 2011. p. 40–47.

GLASBEY, C. A. Na analisys of histogram-based thresholding algorithms. **CVGIP: Graphical Models and Image Processing**, v. 55, p. 532–537, 1993.

GONGE, S. S.; GHATOL, A. A. An enhancement in security and copyright protection technique used for digital still image. In: **2017 International Conference on Nascent Technologies in Engineering (ICNTE)**. [S.l.: s.n.], 2017. p. 1–9.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. I. **Digital Image Processing**. 3rd. ed. Knoxville: Gatesmark Publishing, 2009.

GRADY, L.; FUNKA-LEA, G. Multi-label image segmentation for medical applications based on graph-theoretic electrical potentials. In: \_\_\_\_\_. **Computer Vision and Mathematical Methods in Medical and Biomedical Image Analysis: ECCV 2004 Workshops CVAMIA and MMBIA, Prague, Czech Republic, May 15, 2004, Revised Selected Papers**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. p. 230–245. ISBN 978-3-540-27816-0.

GRANDO, N. **Segmentação de Imagens Tomográficas Visando a Cosntrução de Modelos Médicos**. Dissertação (Mestrado em Computação) - Departamento de Computação, Centro Federal de Educação Tecnológica do Paraná - CEFET-PR, Curitiba, 2005.

GUAN, T.; ZHOU, D.; LIU, Y. Accurate segmentation of partially overlapping cervical cells based on dynamic sparse contour searching and gvf snake model. **IEEE Journal of Biomedical and Health Informatics**, v. 19, n. 4, p. 1494–1504, July 2015.

GUO, Z.; ZHANG, D.; ZHANG, D. A completed modeling of local binary pattern operator for texture classification. **Image Processing, IEEE Transactions on**, v. 19, n. 6, p. 1657–1663, June 2010. ISSN 1057-7149.

HADHOUD, M. M.; ATTA, R. M. Atomic force microscope image enhancement using human visual system model properties and adaptive filters. In: **Radio Science Conference, 2000. 17th NRSC '2000. Seventeenth National**. [S.l.: s.n.], 2000. p. K1/1–K1/8.

HARGAS, L.; KONIAR, D.; HRIANKA, M.; STOFAN, S. Microscope light dimmer for biomedical image enhancement with virtual instrumentation. In: **2010 International Conference on Applied Electronics**. [S.l.: s.n.], 2010. p. 1–4.

HAYASHIBE, M.; SUZUKI, N.; NAKAMURA, Y. Laser-scan endoscope system for intraoperative geometry acquisition and surgical robot safety management. **Medical Image Analysis**, v. 10, p. 509–519, 2006.

HEIDJEN, F. V. **Image based measurement systems object recognition**. New York: Wiley, 1995.

HENDEE, W. R.; RITENOUR, E. R. **Medical Imaging Physics**. [S.l.]: Wiley-Liss, 2002.

HERBST, R. S.; MORGENSZTERN, D.; BOSHOFF, C. The biology and management of non-small cell lung cancer. **Nature**, v. 553, n. 446, Feb 2018.

HOSSEINI-ASL, E.; ZURADA, J. M.; GIMELFARB, G.; EL-BAZ, A. 3-d lung segmentation by incremental constrained nonnegative matrix factorization. **IEEE Transactions on Biomedical Engineering**, v. 63, n. 5, p. 952–963, May 2016. ISSN 0018-9294.

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

HUANG, J.; QU, W.; MENG, L.; WANG, C. Based on statistical analysis and 3d region growing segmentation method of liver. In: **2011 3rd International Conference on Advanced Computer Control**. [S.l.: s.n.], 2011. p. 478–482.

HUANG, S. C.; CHEN, W. C. A new hardware-efficient algorithm and reconfigurable architecture for image contrast enhancement. **IEEE Transactions on Image Processing**, v. 23, n. 10, p. 4426–4437, Oct 2014.

HUANG, X.; LI, S.; WANG, Y. Shape localization based on statistical method using extended local binary pattern. In: **Multi-Agent Security and Survivability, 2004 IEEE First Symposium on**. [S.l.: s.n.], 2004. p. 184–187.

IBRAHIM, H.; KONG, N. S. P. Brightness preserving dynamic histogram equalization for image contrast enhancement. **IEEE Transactions on Consumer Electronics**, v. 53, n. 4, p. 1752–1758, Nov 2007. ISSN 0098-3063.

INCA. Instituto nacional de câncer ministério da saúde. Brasília: Ministério da Saúde, July 2018.

JAIN, A. K. **Fundamentals of Digital image Processing**. [S.l.]: Prentice Hall, 1989.

JUNIOR, J. J. de M. S.; BACKES, A. R.; CORTEZ, P. C. Color texture classification based on gravitational collapse. **Pattern Recognition**, v. 46, n. 6, p. 1628 – 1637, 2013. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320312005353>>.

KAK, A. C.; SLANEY, M. **Principles of Computerized Tomographic Imaging**. Nova York, EUA: IEEE Engineering in Medicine and Biology Society, 1999. v. 1. ISBN O-87942-198-3.

KASHYAP, R.; KHOTANZAD, A. A model-based method for rotation invariant texture classification. **Pattern Analysis and Machine Intelligence, IEEE Transactions on, PAMI-8**, n. 4, p. 472–481, July 1986. ISSN 0162-8828.

KASTURI, M. M.; SUTHA, P.; JAYANTHI, V. E. Efficient edge detection method for diagnosis of 2d and 3d lung and liver images. In: **2017 International Conference on Inventive Systems and Control (ICISC)**. [S.l.: s.n.], 2017. p. 1–5.

KEMENY, J. G. Theory of self-reproducing automata. john von neumann. edited by arthur w. burks. university of illinois press, urbana, 1966. **Science**, American Association for the Advancement of Science, v. 157, n. 3785, p. 180–180, 1967. ISSN 0036-8075.

KEMENY, J. G. Theory of self-reproducing automata. john von neumann. edited by arthur w. burks. university of illinois press, urbana, 1966. **Science**, American Association for the Advancement of Science, v. 157, n. 3785, p. 180–180, 1967. ISSN 0036-8075.

KIM, S.-J.; JANG, M.-S.; PARK, G. T. Image contrast enhancement based on segmentation and tone curve control for lcd tv. In: **2009 Digest of Technical Papers International Conference on Consumer Electronics**. [S.l.: s.n.], 2009. p. 1–2.

KIM, Y.-T. Contrast enhancement using brightness preserving bi-histogram equalization. **IEEE Transactions on Consumer Electronics**, v. 43, n. 1, p. 1–8, Feb 1997. ISSN 0098-3063.

KUANG, H.; DING, Y.; LI, R.; LIU, X. Defect detection of bamboo strips based on lbp and glcm features by using svm classifier. In: **2018 Chinese Control And Decision Conference (CCDC)**. [S.l.: s.n.], 2018. p. 3341–3345.

KUMAR., S. N.; KAVITHA, V. Automatic segmentation of lung lobes and fissures for surgical planning. In: **International Conference on Emerging Trends in Electrical and Computer Technology**. [S.l.: s.n.], 2011.

LEE, J. S. Digital image enhancement and noise filtering by use of local statistics. **IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-2**, n. 2, p. 165–168, March 1980. ISSN 0162-8828.

LI, L.; FENG, W.; ZHANG, J. Contrast enhancement based single image dehazing via tv-l1 minimization. In: **2014 IEEE International Conference on Multimedia and Expo (ICME)**. [S.l.: s.n.], 2014. p. 1–6.

LIANG, J.; DING, G.; WU, Y. Segmentation of the left ventricle from cardiac mr images based on radial gvf snake. In: **2008 International Conference on BioMedical Engineering and Informatics**. [S.l.: s.n.], 2008. v. 2, p. 238–242. ISSN 1948-2914.

LIANG, T. K.; TANAKA, T.; NAKAMURA, H.; SHIRAHATA, T.; SUGIURA, H. An automated 3d emphysema extraction method using lung ct. **SICE Annual Conference 2008**, The University Electro-Communications, Japan, p. 3110–3114, 2008.

LIN, Z.; JIN, J.; TALBOT, H. Unseeded region growing for 3d image segmentation. In: **Selected Papers from the Pan-Sydney Workshop on Visualisation - Volume 2**. Darlinghurst, Australia, Australia: Australian Computer Society, Inc., 2001. (VIP '00), p. 31–37. ISBN 0-909-92580-1.

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

MARCHAND-MAILLET, S.; SHARAIHA, Y. M. **Binary Digital Image Processing**. [S.l.]: Academic Press, 2000.

MARSHALL, A. D.; MARTIN, R. R. **Computer Vision, Models and Inspection**. New York: World Scientific Publishing Company, 1992.

MARSOUSI, M.; PLATANIOTIS, K. N.; STERGIOPOULOS, S. An automated approach for kidney segmentation in three-dimensional ultrasound images. **IEEE Journal of Biomedical and Health Informatics**, v. 21, n. 4, p. 1079–1094, July 2017. ISSN 2168-2194.

MCANDREW, A. **Introduction do digital image processing with matlab**. [S.l.]: Thomson Learning, 2004.

MOHAMMED, A. A.; MINHAS, R.; WU, Q. M. J.; SID-AHMED, M. Human face recognition based on multidimensional pca and extreme learning machine. **Pattern Recognition**, v. 44, p. 2588–2597, 2011.

NASCIMENTO, J. C.; CARNEIRO, G. Deep learning on sparse manifolds for faster object segmentation. **IEEE Transactions on Image Processing**, PP, n. 99, p. 1–1, 2017. ISSN 1057-7149.

NATO, T.; TSUKADA, T.; YAMADA, K.; KOZUKA, K.; YAMAMOTO, S. Robust license-plate recognition methods for passing vehicles under outside environment. **IEEE Transactions on Vehicular Technology**, v. 49, p. 2309–2319, 2000.

NEILA, P. M.; 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. ISSN 0162-8828.

NEMA. **Digital Imaging and Communications in Medicine**. 2014. Disponível em: <<http://dicom.nema.org/>>.

NI, K.; WU, Y. Active contours driven by novel fitting term for image segmentation. **Electronics Letters**, v. 53, n. 13, p. 854–856, 2017. ISSN 0013-5194.

NIBLACK, W. **An Introduction to Digital Image Processing**. [S.l.]: Prentice Hall, 1986.

OJALA, T.; MAENPAA, T.; PIETIKAINEN, M.; VIERTOLA, J.; KYLLONEN, J.; HUOVINEN, S. Outex new framework for empirical evaluation of texture analysis algorithms. In: **Pattern Recognition, 2002. Proceedings. 16th International Conference on**. [S.l.: s.n.], 2002. v. 1, p. 701–706 vol.1. ISSN 1051-4651.

OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. **Pattern Recognition**, v. 29, n. 1, p. 51 – 59, 1996. ISSN 0031-3203.

OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution grayscale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 34, p. 971–987, 2002.

OMER, O. A.; WOJTCZYK, H.; BUZUG, T. M. Simultaneous reconstruction and resolution enhancement for magnetic particle imaging. **IEEE Transactions on Magnetics**, v. 51, n. 2, p. 1–4, Feb 2015.

PAPAGEORGIU, C. V.; ANTONIOU, D.; KALTSAKAS, G.; KOULOURIS, N. G. Role of quantitative ct in predicting postoperative fev1 and chronic dyspnea in patients undergoing lung resection. **Multidisciplinary Respiratory Medicine**, v. 5, n. 3, p. 188, 2010.

PEREIRA, J. R. Quando suspeitar clínica e radiologicamente de câncer de pulmão. **A C Farmacêutica**, 2013.

PHAN, R.; ANDROUTSOS, D. Interactive video growcut: A semi-automated video object segmentation framework using cellular automata. In: **2011 24th Canadian Conference on Electrical and Computer Engineering(CCECE)**. [S.l.: s.n.], 2011. p. 000081–000084. ISSN 0840-7789.

PLUEMPITIWIRIYAWAJ, C.; SOTTHIVIRAT, S. Active contours with automatic initialization for myocardial perfusion analysis. In: **2005 IEEE Engineering in Medicine and Biology 27th Annual Conference**. [S.l.: s.n.], 2005. p. 3332–3335. ISSN 1094-687X.

PODDAR, S.; TEWARY, S.; SHARMA, D.; KARAR, V.; GHOSH, A.; PAL, S. K. Non-parametric modified histogram equalisation for contrast enhancement. **IET Image Processing**, v. 7, n. 7, p. 641–652, October 2013.

POPE, D. L.; PARKER, D. L.; CLAYTON, P. D.; GUSTAFSON, D. E. Left ventricular border recognition using a dynamic search algorithm. **Radiology**, v. 155, n. 2, p. 513–518, 1985.

POPOVICI, A.; POPOVICI, D. Cellular automata in image processing. In: **Fifteenth International Symposium on Mathematical Theory of Networks and Systems**. [S.l.: s.n.], 2002.

PRATT, W. K. **Digital Image Processing**. [S.l.]: PIKS Scientific Inside, 2007.

RADMAN, A.; ZAINAL, N.; SUANDI, S. A. Automated segmentation of iris images acquired in an unconstrained environment using hog-svm and growcut. **Digital Signal Processing**, v. 64, p. 60 – 70, 2017. ISSN 1051-2004.

RAJ, V.; BAJAJ, A.; ENTWISLE, J. J. Implications of new (seventh) tnm classification of lung cancer on general radiologists:a pictorial review. **Current Problems in Diagnostic Radiology**, v. 40, n. 2, p. 85 – 93, 2011.

RAZALI, M. R. M.; AHMAD, N. S.; HASSAN, R.; ZAKI, Z. M.; ISMAIL, W. Sobel and canny edges segmentations for the dental age assessment. In: **2014 International Conference on Computer Assisted System in Health**. [S.l.: s.n.], 2014. p. 62–66.

REBOUÇAS FILHO, P. P. **MCA Crisp: nova técnica de segmentação dos pulmões em imagens de Tomografia Computadorizada baseada no Método de Contorno Ativo**. 2010. Dissertação (Mestrado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2010.

REBOUÇAS FILHO, P. P. **Métodos de contornos ativos crisp adaptativo 2d e 3d eplicanos na segmentação dos pulmões em iamgens de tomografia computadorizada do tórax**. 2013. Tese (Doutorado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2013.

REBOUÇAS FILHO, P. P.; CORTEZ, P. C.; FELIX, J. H. S.; CAVALCANTE, T. d. S. T. S.; HOLANDA, M. A. Adaptive 2d crisp active contour model applied to lung segmentation in CT images of the thorax of healthy volunteers and patients with pulmonary emphysema. **Brazilian Journal of Biomedical Engineering**, p. 363–376, 2013.

REZA, A. M. Realization of the contrast limited adaptive histogram equalization (clahe) for real-time image enhancement. **Journal of VLSI signal processing systems for signal, image and video technology**, v. 38, n. 1, p. 35–44, Aug 2004.

RIBEIRO, A. B. N. **Segmentação dos Vasos Sanguíneos Pulmonares em Imagens de Tomografia Computadorizada do Tórax**. 2013. Dissertação (Mestrado em Engenharia de Teleinformática) - Departamento de Engenharia de Teleinformática, Universidade Federal do Ceará, Fortaleza, 2013.

RITTER, F.; BOSKAMP, T.; HOMEYER, A.; LAUE, H.; SCHWIER, M.; LINK, F.; PEITGEN, H. O. Medical image analysis. **Pulse, IEEE**, v. 2, n. 6, p. 60–70, Nov 2011. ISSN 2154-2287.

SABINO, D.; COSTA, L.; RIZZATTI, E.; ZAGO, M. A texture approach to leukocyte recognition. **Real-Time Imaging**, v. 10, p. 205–216, 2004.

SANTOS, J. R. V. dos; CORTEZ, P. C.; FREITAS, R. F.; Cavalcanti Neto, E. Evaluation of technical of image enhancement with objectives metrics and execution average time. In: **XI Workshop Visão Computacional**. [S.l.: s.n.], 2015.

SARKER, P.; SHUVO, M. M. H.; HOSSAIN, Z.; HASAN, S. Segmentation and classification of lung tumor from 3d ct image using k-means clustering algorithm. In: **2017 4th International Conference on Advances in Electrical Engineering (ICAEE)**. [S.l.: s.n.], 2017. p. 731–736.

SENCEE, N.; BAZARRAGCHAA, B.; KIM, T. Y.; CHOI, H. K. Weight clustering histogram equalization for medical image enhancement. In: **2009 IEEE International Conference on Communications Workshops**. [S.l.: s.n.], 2009. p. 1–5. ISSN 2164-7038.

SHAH, P.; MOGHADDAM, M. A fast level set method for multi-material recovery in microwave imaging. **IEEE Transactions on Antennas and Propagation**, p. 1–1, 2018. ISSN 0018-926X.

SHARMA, R. R.; SUNGHEETHA, A. Segmentation and classification techniques of medical images using innovated hybridized techniques: a study. In: **2017 11th International Conference on Intelligent Systems and Control (ISCO)**. [S.l.: s.n.], 2017. p. 192–196.

SHIH, F. Y.; WU, Y.-T. The efficient algorithms for achieving euclidean distance transformation. **IEEE Transactions on Image Processing**, v. 13, n. 8, p. 1078–1091, Aug 2004. ISSN 1057-7149.

SIEGWART, R.; NOURBAKHSI, I. R. **Introduction to Autonomous Mobile Robots**. [S.l.]: The MIT Press, 2004.

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

- SOLIMAN, A.; KHALIFA, F.; SHAFFIE, A.; DUNLAP, N.; WANG, B.; ELMAGHRABY, A.; GIMEL'FARB, G.; GHAZAL, M.; EL-BAZ, A. A comprehensive framework for early assessment of lung injury. In: **2017 IEEE International Conference on Image Processing (ICIP)**. [S.l.: s.n.], 2017. p. 3275–3279.
- STERN, E. J.; SWENSEN, S. J. **High-Resolution CT of the chest**. [S.l.]: Maple Press, 2001.
- SUAPANG, P.; DEJHAN, K.; YIMMUN, S. Medical image archiving, processing, analysis and communication system for teleradiology. In: **TENCON 2010 - 2010 IEEE Region 10 Conference**. [S.l.: s.n.], 2010. p. 339–345. ISSN pending.
- THOMAS, H. M. T.; DEVAKUMAR, D.; SASIDHARAN, B.; BOWEN, S. R.; HECK, D. K.; SAMUEL, E. J. J. Hybrid positron emission tomography segmentation of heterogeneous lung tumors using 3d slicer: improved growcut algorithm with threshold initialization. **Journal of Medical Imaging**, v. 4, n. 1, p. 011009, 2017.
- TRIER, O.; JAIN, A.; TAXT, T. Feature extraction methods for character recognition - a survey. 1996. Disponível em: <citeseer.ist.psu.edu/trier95feature.html>.
- VEZHNEVETS, V.; L. eta. "**GrowCut-- Interactive Multi-Label N-D Image Segmentation By Cellular Automata**. 2005.
- WANG, C.; FRIMMEL, H.; SMEDBY Örjan. Fast level-set based image segmentation using coherent propagation. **Medical Physics**, v. 41, n. 7, p. 073501, 2016. Disponível em: <<https://aapm.onlinelibrary.wiley.com/doi/abs/10.1118/1.4881315>>.
- WANG, C.; YE, Z. Brightness preserving histogram equalization with maximum entropy: a variational perspective. **IEEE Transactions on Consumer Electronics**, v. 51, n. 4, p. 1326–1334, Nov 2005. ISSN 0098-3063.
- WANG, Q.; CHEN, L.; SHEN, D. Fast histogram equalization for medical image enhancement. In: **2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society**. [S.l.: s.n.], 2008. p. 2217–2220. ISSN 1094-687X.
- WEBB, A. **Statistical Pattern Recognition**. [S.l.]: Wiley, 2002.
- WEBB, W. R.; MULLER, N. L.; NAIDICH, D. P. **High-Resolution CT of the LUNG**. [S.l.]: Ma, 2001.
- WHO. **World Health Organization**. 2014.
- WHO. **World Health Organization**. 2018.
- WICKRAMASINGHE, H. K.; HEISERMAN, J. Image enhancement in the scanning acoustic microscope using analogue filters. **Electronics Letters**, v. 13, n. 25, p. 776–777, December 1977. ISSN 0013-5194.
- WIDROW, B.; WINTER, R. Neural nets for adaptative filtering and adaptative pattern recognition. **IEEE Computer**, v. 21, p. 25–39, 1988.
- YADAV, A. K.; ROY, R.; RAJKUMAR; VAISHALI; SOMWANSHI, D. Thresholding and morphological based segmentation techniques for medical images. In: **2016 International Conference on Recent Advances and Innovations in Engineering (ICRAIE)**. [S.l.: s.n.], 2016. p. 1–5. ISSN 5090-2806.

- YAMAGUCHI, Y.; UEHARA, K.; KIMURA, H. Tracking small object by image processing on smart phone. In: **2015 International Conference on Informatics, Electronics Vision (ICIEV)**. [S.l.: s.n.], 2015. p. 1–4.
- YAMASAKI, T.; CHEN, T.; YAGI, M.; HIRAI, T.; MURAKAMI, R. Comparative study of interactive seed generation for growcut-based fast 3d mri segmentation. In: **Proceedings of The 2012 Asia Pacific Signal and Information Processing Association Annual Summit and Conference**. [S.l.: s.n.], 2012. p. 1–4.
- YUSHKEVICH, P. A.; GERIG, G. Itk-snap: An interactive medical image segmentation tool to meet the need for expert-guided segmentation of complex medical images. **IEEE Pulse**, v. 8, n. 4, p. 54–57, July 2017. ISSN 2154-2287.
- ZAFARIFAR, B.; BELLERS, E. B.; WITH, P. H. N. de. Application and evaluation of texture-adaptive skin detection in tv image enhancement. In: **2013 IEEE International Conference on Consumer Electronics (ICCE)**. [S.l.: s.n.], 2013. p. 88–91.
- ZAFARIFAR, B.; MARTINIERE, A.; WITH, P. H. N. de. Improved skin segmentation for tv image enhancement, using color and texture features. In: **2010 Digest of Technical Papers International Conference on Consumer Electronics (ICCE)**. [S.l.: s.n.], 2010. p. 373–374. ISSN 2158-3994.
- ZHAO, G.; PIETIKAINEN, M. Dynamic texture recognition using local binary patterns with an application to facial expressions. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 29, n. 6, p. 915–928, June 2007. ISSN 0162-8828.
- ZHOU, Z.-H.; GENG, X. Projection functions for eye detection. **Pattern Recognition**, v. 37, n. 5, p. 1049 – 1056, 2004. ISSN 0031-3203.
- ZRIMEC, T.; BUSAYARAT, S. 3d modelling and visualization of the human lung. **Proceedings of the 2nd International Symposium on 3D Data Processing, Visualization, and Transmission**, IEEE Computer Society, 2004.