



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

VALBERTO ENOC RODRIGUES DA SILVA FILHO

**UMA NOVA ABORDAGEM PARA A SEGMENTAÇÃO PULMONAR COM
REINCLUSÃO DE NÓDULOS**

FORTALEZA

2018

VALBERTO ENOC RODRIGUES DA SILVA FILHO

UMA NOVA ABORDAGEM PARA A SEGMENTAÇÃO PULMONAR COM REINCLUSÃO
DE NÓDULOS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do 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 mestre em Engenharia de Teleinformática. Área de Concentração: Engenharia IV

Orientador: Dr. Paulo César Cortez

Coorientador: Dr. Tarcísio Ferreira Maciel

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)

S584n Silva Filho, Valberto Enoc Rodrigues da.
Uma nova abordagem para a segmentação pulmonar com reinclusão de nódulos / Valberto Enoc Rodrigues da Silva Filho. – 2018.
62 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2018.

Orientação: Prof. Dr. Paulo César Cortez.

Coorientação: Prof. Dr. Tarcísio Ferreira Maciel.

1. Segmentação Pulmonar. 2. LIDC-IDRII. 3. Análise de Componentes Conectados 3D. 4. Nódulos. I. Título.

CDD 621.38

VALBERTO ENOC RODRIGUES DA SILVA FILHO

UMA NOVA ABORDAGEM PARA A SEGMENTAÇÃO PULMONAR COM REINCLUSÃO
DE NÓDULOS

Dissertação apresentada ao Curso de Mestrado Acadêmico em Engenharia de Teleinformática do 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 mestre em Engenharia de Teleinformática. Área de Concentração: Engenharia IV

Aprovada em: 27 de Junho de 2018

BANCA EXAMINADORA

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

Dr. Tarcísio Ferreira Maciel (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Auzuir Ripardo de Alexandria
Universidade Federal do Ceará (UFC)

Prof. Dr. Jarbas Joaci de Mesquita SA Junior
Universidade Federal do Ceará (UFC)

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

“...Até aqui nos ajudou o Senhor.”

(1Sm 7:12)

RESUMO

Em diversas aplicações de análise de imagens médicas, o processo de segmentação destas imagens é uma tarefa fundamental, principalmente quando se trata de sistemas de auxílio ao diagnóstico de doenças terminais, como o câncer pulmonar. Assim, um dos grandes desafios está na precisão da segmentação quanto à preservação de estruturas internas, em especial, os nódulos pulmonares justa-pleurais, que não são, em geral, incluídos na segmentação final dos pulmões. Isto prejudica as informações que podem ser úteis na inspeção de estruturas e identificação de doenças, no acompanhamento da evolução ou até mesmo nas simulações para planejamento cirúrgico. Deste modo, diferentes abordagens são utilizadas para promover a reinclusão dos nódulos, portanto, na solução do problema. Neste sentido, esta dissertação propõe uma nova abordagem para segmentação pulmonar em imagens de Tomografia Computadorizada do tórax com reinclusão de nódulos empregando técnicas de morfologia matemática clássicas para reduzir a perda de nódulos. Esta abordagem é composta por uma sequência de pré-processamento, seguida da segmentação pulmonar morfológica por análise de componentes conectados 3D, e preenchimento de buracos não morfológico, e finalmente o pós-processamento cuja finalidade é a reinclusão dos nódulos perdidos, e tem seu processo dividido em duas etapas, a saber, o fechamento da pleura pulmonar lateral através do fecho convexo da mesma, e o fechamento morfológico da região mediastinal. Para validar a abordagem, testes são realizados em uma extensa base de dados (LIDC-IDRI), bem como um padrão ouro gerado com o auxílio de médicos especialistas e comparado a uma técnica clássica de segmentação, o Crescimento de Regiões 3D, e um método baseado em classificação encontrado na literatura. As principais contribuições desta dissertação se encontram no preenchimento de buracos, que substitui o método morfológico para maior eficiência computacional, bem como o algoritmo desenvolvido para reinclusão de nódulos justa-pleurais. Os resultados comprovam que há um ganho substancial no tempo de processamento na etapa de preenchimento de buracos, chegando a ser seis vezes mais rápido do que o preenchimento morfológico. Além disso, a segmentação proposta obtém perda mínima de 1,9% de nódulos de uma quantidade total de 2663 nódulos, e chegando a 91% e 87% para as taxas de *Dice Similarity Coefficient* e Ajuste de Forma, respectivamente, na comparação da segmentação final com o padrão ouro. Neste contexto, conclui-se que a segmentação proposta, segundo as métricas utilizadas, apresenta resultados superiores aos métodos comparados quanto à perda de nódulos, bem como o tempo de processamento reduzido, sendo compatível aos métodos encontrados na literatura quanto às medidas de qualidade da segmentação.

Palavras-chave: Segmentação Pulmonar. LIDC-IDRI. Análise de Componentes Conectados 3D. Nódulos.

ABSTRACT

In several applications of medical image analysis, the image segmentation process is a fundamental task, especially when it comes to computer systems aimed at assistance in terminal diseases diagnosis, such as lung cancer. Thus, one of the major challenges lies in the segmentation accuracy regarding the preservation of internal structures, especially the just-pleural pulmonary nodules, which are not usually included in the final lung segmentation. This missing information may be critical in inspecting structures and identifying diseases, monitoring evolution, or even simulations for surgical planning. That way, different approaches are used to promote reinclusion of the nodules, therefore, in the final solution of the problem. In this sense, this dissertation proposes a new approach for pulmonary segmentation in computed tomography images of the chest with nodules reinclusion using classical mathematical morphology techniques to reduce nodule loss. This approach consists of a preprocessing sequence, followed by morphological pulmonary segmentation by 3D connected component analysis, and non-morphological hole filling, and finally the post-processing which main purpose is the reinclusion of the lost nodes, and has its process divided into two stages, namely the closure of the lateral pulmonary pleura through the its convex hull area, and the morphological closure of the mediastinal region. To validate this approach, tests are performed in an extensive database (LIDC-IDRI) as well as a gold standard generated with the assistance of medical specialists and compared to a classical segmentation technique, 3D Region Growing, and a classification-based method found in the literature. The main contributions of this dissertation are in the fill holes technique, which replaces the morphological method for greater computational efficiency, as well as the developed developed for reinclusion of justa-pleural nodules. The results prove that there is a substantial gain in processing time in the holes filling step, which is six times faster than the morphological counterpart. In addition, the proposed segmentation achieves a minimum loss of 1.9 % of nodules from a total amount of 2663 nodes, and reaching 91 % and 87 % for Similarity Coefficient and Fitness Adjust rates, respectively, in comparison of the final segmentation with the gold standard. In this context, it is concluded that the proposed segmentation, according to the metrics used, presents results superior to the methods compared to the loss of nodules, as well as the reduced processing time, being compatible with the methods found in the literature regarding measures of segmentation quality.

Keywords: Lung segmentation. LIDC-IDRI. 3D Connected Components Analysis. Nodules.

LISTA DE FIGURAS

Figura 1 – Exemplos de imagens, (a) imagem RGB; (b) imagem em escala de cinza; (c) imagem binária.	20
Figura 2 – Planos de imagens de TC (a) ilustração dos planos; (b) plano axial; (c) plano coronal; (d) plano sagital	22
Figura 3 – Faixa de valores para diferentes tecidos e órgãos em UH. Adaptado de (SIEMENS, 2004)	23
Figura 4 – Imagem de TC do tórax no eixo axial, (a) imagem original; (b) representação colorida das faixas de densidade.	24
Figura 5 – Sistema de VC típico.	24
Figura 6 – Segmentação por limiarização, (a) imagem original; (b) imagem limiarizada.	26
Figura 7 – Ilustração da aplicação do Crescimento de Região 3D, (a) determinação da semente, (b) primeira iteração do CR3D, e (c) resultado final da segmentação (RIBEIRO, 2013).	28
Figura 8 – Ilustração da aplicação do Morfologia Matemática, (a) imagem original, (b) aplicada erosão, e (c) aplicada dilatação (CAVALCANTI NETO, 2014).	29
Figura 9 – Ilustração da aplicação do Morfologia Matemática, (a) imagem original, (b) aplicada abertura, e (c) aplicado fechamento (CAVALCANTI NETO, 2014).	31
Figura 10 – Aplicação componentes conectados, (a) imagem original, (b) binarização de (a), (c) erosão binária em (b), e (d) tabela com quantidade de <i>pixels</i> de cada componente. Adaptada de Gonzalez e Woods (2012)	32
Figura 11 – Fluxograma da abordagem de segmentação pulmonar proposta.	34
Figura 12 – Ilustração da aplicação da filtragem gaussiana após limiarização, (a) imagem original, (b) imagem limiarizada (binária), (c) resultado da filtragem gaussiana aplicada na imagem b, (d) aplicado filtro gaussiano em a, e (e) aplicado limiarização em d.	35
Figura 13 – Ilustração do resultado da aplicação da Análise de Componentes Conectados 3D na segmentação pulmonar.	37
Figura 14 – Ilustração do processo de separação dos pulmões.	37
Figura 15 – Ilustração do processo de preenchimento de buracos, (a) pulmão segmentado, (b) dois maiores contornos e (c) buracos preenchidos.	38
Figura 16 – Exemplo de nódulo justa-pleural.	38

Figura 17 – Processamento para região lateral com fecho convexo, (a) fecho convexo dos pulmões, (b) fecho convexo reduzido, e (c) fecho convexo adicionado ao contorno pulmonar na imagem segmentada.	40
Figura 18 – Reinclusão de nódulos, (a) segmentação após fechamento de buracos, (b) fecho convexo de (a), (c) fecho convexo sobreposto em (a) para ilustração, (d) dilatação e fechamento, (e) multiplicação binária entre (b) e (d) excluído o fecho convexo.	41
Figura 19 – Comparação da medida ajuste de forma entre a abordagem proposta e CR3D.	47
Figura 20 – Uma fatia típica de um exame. (a) imagem original; (b) segmentação padrão ouro; (c) segmentação obtida pela abordagem proposta; (d) segmentação obtida pelo CR3D.	47
Figura 21 – Comparação da medida <i>dice similarity</i> entre a abordagem proposta e CR3D.	48
Figura 22 – Comparação da medida de segmentação excessiva entre a abordagem proposta e CR3D.	49
Figura 23 – Comparação da medida de segmentação insuficiente entre a abordagem proposta e CR3D.	49
Figura 24 – Exemplo de nódulo extra-pleural.	51
Figura 25 – Percentual de nódulos perdidos com base no limiar de inclusão com passo 0.1.	52
Figura 26 – Tempo de processamento médio a cada 100 exames.	54
Figura 27 – Tempo de processamento em função da quantidade de imagens por exame. .	54

LISTA DE TABELAS

Tabela 1 – Mapeamento de índices LIDC-IDRI	46
Tabela 2 – Comparação dos resultados obtidos com Shen <i>et al.</i> (2015)	50
Tabela 3 – Comparação de contagem de nódulos perdidos.	52
Tabela 4 – Comparação tempo de processamento preenchimento de buracos.	53
Tabela 5 – Comparação do tempo de processamento obtidos com Shen <i>et al.</i> (2015) . .	55

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Objetivos	16
1.1.1	<i>Objetivos Específicos</i>	16
1.2	Produção Científica	17
2	FUNDAMENTAÇÃO TÉORICA	20
2.1	Processamento de Imagens	20
2.2	Visão Computacional	23
2.2.1	Segmentação	24
2.2.1.1	<i>Segmentação por Similaridade</i>	25
2.2.1.1.1	<i>Limiarização</i>	25
2.2.1.1.2	<i>Crescimento de Regiões</i>	26
2.2.2	Morfologia Matemática	28
2.2.2.1	<i>Dilatação e Erosão</i>	29
2.2.2.2	<i>Abertura e Fechamento</i>	30
2.2.2.3	<i>Análise de Componentes Conectados</i>	30
3	METODOLOGIA	33
3.1	Segmentação do Pulmão	33
3.2	Reinclusão de Nódulos	39
4	RESULTADOS	43
4.1	Banco de Imagens	43
4.2	Especificação de Parâmetros	44
4.3	Qualidade de Segmentação	45
4.4	Contagem de Nódulos	50
4.5	Tempo de Processamento	52
5	CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS	56
	REFERÊNCIAS	58

1 INTRODUÇÃO

Câncer constitui um enorme problema para sociedade tanto em países desenvolvidos quanto subdesenvolvidos. A incidência de câncer está aumentando devido a fatores naturais relacionados ao aumento da população e idade da mesma. A Organização Mundial de Saúde (OMS) estimou, em 2012, na última pesquisa realizada, 14,1 milhões de novos casos e, em 2015, 8,8 milhões de mortos. Ainda segundo a OMS, o câncer de pulmão é o de maior prevalência e maior mortalidade, sendo responsável por 1,7 milhões dos casos supracitados (TORRE *et al.*, 2015; IASLC, 2017; OMS, 2018). No Brasil o câncer de pulmão foi responsável por 23.416 mortes em 2012, e 26.400 em 2015, apresentando um aumento anual médio de 0.41% (DATASSUS, 2015). sendo o tipo de câncer que mais fez vítimas. Segundo o INCA (2016) é estimado, para os anos de 2016 e 2017, 600 mil novos casos de câncer, sendo 8,1% câncer pulmonar.

Câncer é uma doença resultante do processo de crescimento desordenado das células de um determinado tecido, podendo se espalhar entre os órgãos do corpo humano. Quando esse crescimento se dá de forma rápida e agressiva, formam-se tumores ou nódulos. (INCA, 2016)

Pela estimativa levantada por Boing e Rossi (2007), o carcinoma pulmonar é o câncer com maior taxa de mortalidade relacionada a câncer no mundo, além de ser o de maior incidência entre os tipos de câncer de pulmão. Nos Estados Unidos foram contabilizadas 160 mil mortes por ano, enquanto que no Brasil essa taxa é de mais de 20 mil por ano entre os anos de 1979 e 2004. Esse grande número de óbitos se dá, principalmente, pela dificuldade de diagnóstico precoce, sendo a maior parte dos pacientes diagnosticados em um estágio avançado da doença, em que o tratamento curativo de retirada do tumor não é mais uma opção.

Neste sentido é importante para saúde pública o uso de meios que proporcionem diagnósticos mais rápidos e precisos. Para isso, há o uso de exames de imagem como radiografia e Tomografia Computadorizada (TC), sendo a última a mais utilizada para detecção e caracterização de nódulos pulmonares. No entanto, a avaliação dos exames TC é um processo que pode envolver a leitura de um conjunto vasto de dados volumétricos, sendo passível de erros em que nódulos não são vistos. Além disso, radiologistas menos experientes tendem a aumentar a variabilidade na detecção de nódulos menores. Em resposta a essa problemática, surgem os *Computer Assisted Diagnosis Systems (CADs)* com potencial para melhorar a precisão dos diagnósticos por imagem (JACOBS *et al.*, 2011; PU *et al.*, 2008).

Estudos mostraram que sistemas CAD aumentaram as taxas de detecção de nódulos

(RUBIN *et al.*, 2005), diminuíram as taxas de falsos positivos (DAS *et al.*, 2006) e compensaram a deficiência no desempenho do olho humano na detecção de lesões menores e de nódulos sem acoplamento vascular (MARTEN *et al.*, 2005). De fato, a capacidade de sistemas computacionais de diagnosticar de forma mais precisa e consistente nódulos pulmonares tem sido alvo de pesquisa na área de Análise de Imagens Médicas (AIM), ou Imagiologia Médica (IM). O auxílio computadorizado ao diagnóstico médico mostra-se cada vez mais importante tanto do ponto de vista clínico quanto de pesquisa.

O estudo e uso de exames de imagens médicas está se tornando cada vez mais relevante para a medicina contemporânea, pois proporciona uma visualização rica de informações das estruturas anatômicas internas para auxílio ao diagnóstico, plano terapêutico e avaliação do paciente de forma não invasiva (BI *et al.*, 2012). Assim, quantidade de exames por imagem cresceu substancialmente nas últimas décadas, várias modalidades e técnicas utilizadas na geração de imagens médicas permitem o estudo detalhado da anatomia do corpo humano. Dentre elas, a Tomografia Computadorizada (TC) se destaca pela diversidade de doenças que permite diagnosticar, bem como os diferentes tipos de tumores existentes. (DEMNER-FUSHMAN *et al.*, 2015; BIRKFELLNER, 2015).

A Tomografia Computadorizada é o exame de maior importância na detecção de nódulos pulmonares. Este exame é composto por informação volumétrica gerada a partir de um conjunto de imagens que, ao serem enfileiradas em um dos três eixos possíveis, axial, coronal e sagital, formam um volume que pode ser apresentado no espaço 3D de forma visual. Sendo assim, a necessidade do processo de segmentação 3D a partir de imagens 2D se torna fundamental (DELIBASIS *et al.*, 2014). Existem diversos caminhos para a segmentação de objetos em imagens digitais, cada um com suas respectivas vantagens e desvantagens.

O processo de segmentação de imagens é uma tarefa importante e presente em diversas aplicações de análise de imagens. Para analisar determinado órgão é normalmente necessário primeiro isolá-lo da imagem. Uma segmentação precisa fornece meios para a extração de informações relevantes à região segmentada, reconstrução visual ou mesmo para simulação e planejamento cirúrgico. Logo, a etapa de segmentação é de fundamental importância para a análise de estruturas do corpo humano através de Imagiologia Médica (HE *et al.*, 2008; HEIMANN; MEINZER, 2009; BARBOSA *et al.*, 2014).

O objetivo principal da segmentação é extrair e fornecer informações descritivas de um ou mais objetos de interesse na imagem. O resultado deste processo pode ser utilizado tanto

para rastreamento de objetos quanto para cálculo de medidas quantitativas. Além disso, no caso de dados volumétricos, a segmentação pode ser realizada em 2D, seguido da geração de um volume através do empilhamento das imagens, ou em 3D, processando o conjunto volumétrico diretamente. Em ambos os casos é possível realizar a reconstrução visual do objeto segmentado, a partir de diversos ângulos e perspectivas. Alguns dos métodos utilizados para esta tarefa são: limiarização, crescimento de regiões, análise de componentes conectados, *watershed*, dentre outros.

A segmentação de imagens é uma tarefa exigente que tem ampla aplicação em análise de imagens médicas, desde os sistemas de auxílio ao diagnóstico, até a simulação de processos cirúrgicos. No entanto, a segmentação de estruturas e objetos em imagens médicas é um processo complexo. Isso pode ser observado através da enorme variabilidade de estruturas e órgãos internos, além da gama de doenças que podem afetar a disposição e/ou composição dos mesmos, dificultando o processo de segmentação destes. Fibrose é um exemplo de doença que acomete os pulmões e causa a formação de cicatrizes no tecido pulmonar, modificando severamente sua textura e composição. Essas alterações são visíveis nos exames e representam obstáculos à maioria dos algoritmos de segmentação pulmonar (ELLIS; FLOWER, 2006; DEMNER-FUSHMAN *et al.*, 2015).

A etapa de segmentação do pulmão é fundamental para o processo de detecção de nódulos e isolamento do pulmão para análises posteriores. No caso de uma segmentação pulmonar imprecisa na delimitação das bordas dos pulmões, os nódulos podem ser perdidos ou confundidos com tecido normal do tórax, principalmente os nódulos justa-pleurais que são os que estão conectados às bordas dos pulmões. Prova disto é que, nas avaliações de sistemas CAD apontam que 17% dos nódulos são perdidos devido a segmentação imprecisa (SHEN *et al.*, 2015). Portanto, a qualidade da segmentação pulmonar é fundamental na determinação de desempenho de sistemas CADs (RETICO *et al.*, 2008). Sistemas CADs são compostos por um ou mais algoritmos especializados em uma tarefa que, juntos, realizam um diagnóstico médico para auxílio de médicos especialistas.

Existe uma grande quantidade de algoritmos de segmentação pulmonar, no entanto a maioria deles foi analisada em um subconjunto de imagens que não representa completamente os diversos tipos de nódulos que podem variar em seu tamanho e forma. Por esta razão, métodos de segmentação semi-automáticos foram propostos para superar a segmentação imprecisa. Métodos semi-automáticos exigem a intervenção humana para seu uso. Porém, por haver a necessidade

de um especialista para operar o sistema e revisar os resultados em cada exame, esta solução é considerada inviável, além de não ser escalável (HEDLUND *et al.*, 1982). Além dos sistemas semi-automáticos, foram propostos os métodos automáticos. Nestes métodos não há necessidade de intervenção humana no funcionamento do sistema.

Hu *et al.* (2001) apresentam uma segmentação automática usando uma combinação de operações morfológicas para garantir a reinclusão de nódulos justa-pleurais. Todavia, a eficácia das operações morfológicas é dependente da forma e das dimensões do elemento estruturante do operador. Assim, a escolha de um elemento que funcione bem para todas as formas e tamanho de nódulos pode ser uma tarefa complexa. Por exemplo, um elemento estruturante menor, pode não detectar nódulos muito grandes, e um elemento estruturante maior, pode causar uma segmentação imprecisa, expandindo os limites da área pulmonar.

O operador "*rolling ball*", que corresponde a um operador morfológico de fechamento com um elemento estruturante circular, foi utilizado em alguns trabalhos (SUN *et al.*, 2006; RETICO *et al.*, 2008). Contudo, semelhantemente a outras abordagens morfológicas, possui a dificuldade de otimização do elemento estruturante.

Pu *et al.* (2008) propõem um algoritmo de segmentação pulmonar ponto a ponto chamada de *adaptive border marching (ABM)*, projetado para tratar nódulos justa-pleurais, que são nódulos presentes na borda da pleura pulmonar. O critério de inclusão do contorno baseia-se na razão entre dois pontos da borda do pulmão em sequência. A razão entre os pontos é comparada com um limiar, e um passo é calculado para verificação dos próximos pontos. Esse método apresenta dificuldade no controle da precisão de segmentação no momento de determinação do limiar utilizado.

Seguindo na mesma direção de correção de contorno, Kim *et al.* (2003) apresentam um método que rastreia áreas em que podem conter nódulos e aplica o algoritmo de Crescimento de Regiões (CR) utilizando a textura dos nódulos como critério de inclusão. Todavia, o desafio dessa abordagem se encontra na otimização das dimensões da janela e também na determinação do valor de limiar do CR.

Já Ye *et al.* (2009) utilizam código de cadeia de *Freeman* para corrigir os contornos. Para cada *pixel* ao longo do contorno, o código de cadeia é utilizado para detectar pontos críticos ao examinar a transição entre regiões convexas e côncavas, determinados por um valor limiar pré definido. Entretanto, o uso desse limiar predefinido não é suficiente para segmentar corretamente os nódulos em suas mais variadas formas e tamanhos. Ainda usando o código de cadeia Choi e

Choi (2012) utiliza uma abordagem que ao invés de detectar transições entre regiões convexas e côncavas, extrai informações de gradiente do código de cadeia. Neste sentido, Shen *et al.* (2015) aprimoram a abordagem com códigos de cadeia acrescentando o classificador *support vector machine (SVM)* para identificar pares de conexões candidatas à bordas com nódulos. Todavia, seu método apresenta dificuldades na reinclusão de nódulos presentes em regiões de consolidação pulmonar ou acometida por lesões graves.

Os métodos citados anteriormente possuem alta dependência de otimização de parâmetros para funcionar nas mais diversas situações, não somente em relação as formas e tamanho dos nódulos, mas também outras doenças que são acometidas no pulmão, transformando sua estrutura interna e dificultando a tarefa de segmentação e detecção de nódulos. Além disso, os resultados apresentados não são avaliados em uma quantidade suficientemente grande e representativa de imagens de teste, comprometendo a validade e eficácia destas, além de não incluir informações de custo computacional das técnicas aplicadas.

Neste contexto, é proposto nesta dissertação uma abordagem utilizando análise de componentes conectados 3D para segmentar o pulmão e detectar a maior quantidade de nódulos possíveis. Essa abordagem é uma solução *AD HOC*, isto é, necessita de otimização de parâmetros para diferentes situações. Todavia, seu desempenho pode ser validado através de uma quantidade suficiente de exames de testes. Além disso, nesta dissertação é analisado o tempo de processamento total por exame para segmentar o pulmão em 3D.

1.1 Objetivos

O principal objetivo desta dissertação é propor uma nova abordagem para segmentação 3D dos pulmões em imagens de Tomografia Computadorizada do Tórax.

1.1.1 *Objetivos Específicos*

Os objetivos específicos que devem ser alcançados neste trabalho são:

- Criação de um *framework* de análise de imagens médicas com funcionalidades de leitura e escrita, visualização, processamento e análise de exames de TC.
- Seleção e geração de padrão ouro com supervisão de médico especialista.
- Tratamento e normalização de banco de imagens LIDC-IDRI para leitura.
- Implementação do algoritmo Crescimento de Regiões 3D (CR3D).

1.2 Produção Científica

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

- Trabalhos publicados em eventos científicos:
 - SILVA FILHO, V.E.R.; CORTEZ, P. C.; CAVALCANTI NETO, E.; RIBEIRO, A. B. N; ALMEIDA, T. M. - *A Clinically Viable Approach to Lung Segmentation and Nodules Reinclusion*. In: XXV Congresso Brasileiro de Engenharia Biomédica, 2018, Rio de Janeiro. XXV Congresso Brasileiro de Engenharia Biomédica, 2018.
 - 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.
 - 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.
 - RIBEIRO, A. B. N. ; SILVA FILHO, V. R. ; CORTEZ, P. C. ; CAVALCANTE, T. S. ; CAVALCANTI NETO, E. ; VALENTE, I. R. S. ; HOLANDA, M. A. . Crescimento de Regiões 3D Aplicado na Segmentação de Vasos Sanguíneos em Imagens de TC 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.
 - 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.
- 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 capítulo de Livro:
 - Neto, E. Cavalcanti; CORTEZ, P. C. ; CAVALCANTE, T. S. ; da Silva Filho, V. E. R. ; Filho, P. P. Rebouças ; Holanda, M. A. . Supervised Enhancement Filter Applied to Fissure Detection. IFMBE Proceedings. 1ed.: Springer International Publishing, 2015, v. 49, p. 337-340.
- Patentes depositadas:
 - 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
 - RIBEIRO, A. B. N. ; CAVALCANTE, T. S. ; HOLANDA, M. A. ; Neto, Edson Cavalcanti ; SILVA FILHO, V. R. ; ALMEIDA, T. M. . Segmentação de Vasos Sanguíneos Pulmonares em Imagens de Tomografia Computadorizada do Tórax Utilizando Análise de Densidade Pulmonar. 2015, Brasil. Patente: Privilégio de Inovação. Número do registro: BR1020150297718, título: "Segmentação de Vasos Sanguíneos Pulmonares em Imagens de Tomografia Computadorizada do Tórax Utilizando Análise de Densidade Pulmonar", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial, Depositante (s): Paulo Cesar Cortez;Universidade Federal do Ceará, Depósito: 27/11/2015
 - Neto, Edson Cavalcanti; SILVEIRA CAVALCANTE, TARIQUE ; ALCANTARA HOLANDA, MARCELO ; ENOC RODRIGUES, VALBERTO ; RIBEIRO, A. B.

N. ; ALMEIDA, T. M. ; NOGUEIRA, I. C. ; MARINHO, L. S. . SFPT NEURAL: NOVA TÉCNICA DE SEGMENTAÇÃO DE FISSURAS PULMONARES BASEADA EM TEXTURAS EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADAS DO TÓRAX. 2016, Brasil. Patente: Privilégio de Inovação. Número do registro: BR1020160205506, título: "SFPT NEURAL: NOVA TÉCNICA DE SEGMENTAÇÃO DE FISSURAS PULMONARES BASEADA EM TEXTURAS EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADAS DO TÓRAX", Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial, Depositante (s): Paulo Cesar Cortez;Universidade Federal do Ceará, Depósito: 06/09/2016

2 FUNDAMENTAÇÃO TEÓRICA

Neste Capítulo inicialmente são discutidas as características das imagens médicas, em especial, as imagens adquiridas por TC do tórax, bem como conceitos básicos de processamento de imagens, incluindo técnicas de segmentação e morfologia matemática. Posteriormente, é realizada uma descrição dos diferentes tipos de nódulos pulmonares e suas propriedades presentes nas imagens de TC do tórax.

2.1 Processamento de Imagens

Uma imagem digital pode ser representada matematicamente por uma função bidimensional $f(x,y)$, em que x e y representam suas coordenadas cartesianas e a amplitude da função o valor do elemento da matriz, denominado de *pixel* correspondente (GONZALEZ; WOODS, 2012). Os valores que os *pixels* podem assumir variam de acordo com o tipo de imagem. A seguir, alguns tipos de imagens digitais, segundo McAndrew (2004):

- imagem colorida (RGB), que são caracterizadas por três canais sobrepostos de *pixels* que assumem a mesma faixa de valores, em que os canais representam as cores vermelho, verde e azul, conforme Figura 1a;
- imagem em níveis de cinza, que é caracterizada por ser representada por apenas um canal, no qual cada pixel corresponde a um nível de cinza, e é geralmente composta por 8 bits, podendo assumir valores entre 0 (preto) e 255 (branco), conforme Figura 1b;
- imagem binária em que cada pixel representa a imagem utilizando apenas 1 bit, nesse caso, podendo assumir apenas, preto ou branco, conforme Figura 1c.



Figura 1 – Exemplos de imagens, (a) imagem RGB; (b) imagem em escala de cinza; (c) imagem binária.

Além destas imagens, algumas indústrias utilizam imagens em diferentes disposições de acordo com a necessidade de suas aplicações. A indústria médica, utiliza diversos exames por imagem, cada um com suas propriedades específicas, dentre elas a tomografia computadorizada é um exame composto por um conjunto de imagens de 16 bits e apenas um canal.

A tomografia computadorizada foi introduzida para uso clínico em 1973 por Hounsfield (1973), sendo a primeira das modalidades de imagem por fatias moderna. A reconstrução de imagens a partir de dados para visualização e armazenamento em forma digital era uma novidade na época, embora seja uma prática comum atualmente (KALENDER, 2006).

Exames de TC mostraram-se uma tendência tanto em seu aspecto tecnológico, quanto em seu desempenho e uso clínico. Essa tendência contrariou a previsão de especialistas de que, até os anos 80, esse tipo de exame deveria ser substituído completamente por exame de ressonância magnética. No entanto, a TC tem ganhado ainda mais força ao introduzir o escaneamento espiral que marcou a transição de imagem por fatiamento para um modelo de volume real. Atualmente, exames de TC permitem a geração de modelos tridimensionais (3D) completos de órgãos ou até corpo humano inteiro com resolução milimétrica, ou até nanométrica dependendo da tecnologia de escaneamento utilizada (KALENDER, 2006; HOLLER *et al.*, 2014).

Devido ao exame ser composto por um único volume 3D de imagens, a partir deste volume é possível extrair imagens em três diferentes planos: axial ou transversal, sagital e coronal, como pode ser visto na Figura 2.

A imagem de exame de TC é gerada a partir de uma estimativa do cálculo de atenuação de raios-X. Semelhante às tomografias tradicionais, esse cálculo é realizado através da medição de atenuação radiográfica, nos quais a densidade da estrutura presente na imagem é proporcional ao grau de absorção dos raios-x que os atravessa.

O volume reconstruído é composto por um conjunto de imagens de mesma dimensão em que seus elementos de imagens, denominados de *voxel*, correspondem à atenuação radiográfica média do elemento 3D. Estas imagens se estendem ao longo do plano axial pela espessura da seção, ou seja, pelo espaço entre as seções ou fatias (HOUNSFIELD, 1973; BONTRAGER, 2008).

Os valores de densidade da TC são representados em Unidades Hounsfield (UH), e diferentes tipos de tecidos e estruturas do corpo humano podem ser representados por valores distintos de UH. A Figura 3 apresenta alguns dos tecidos e órgãos com diferentes valores de UH.

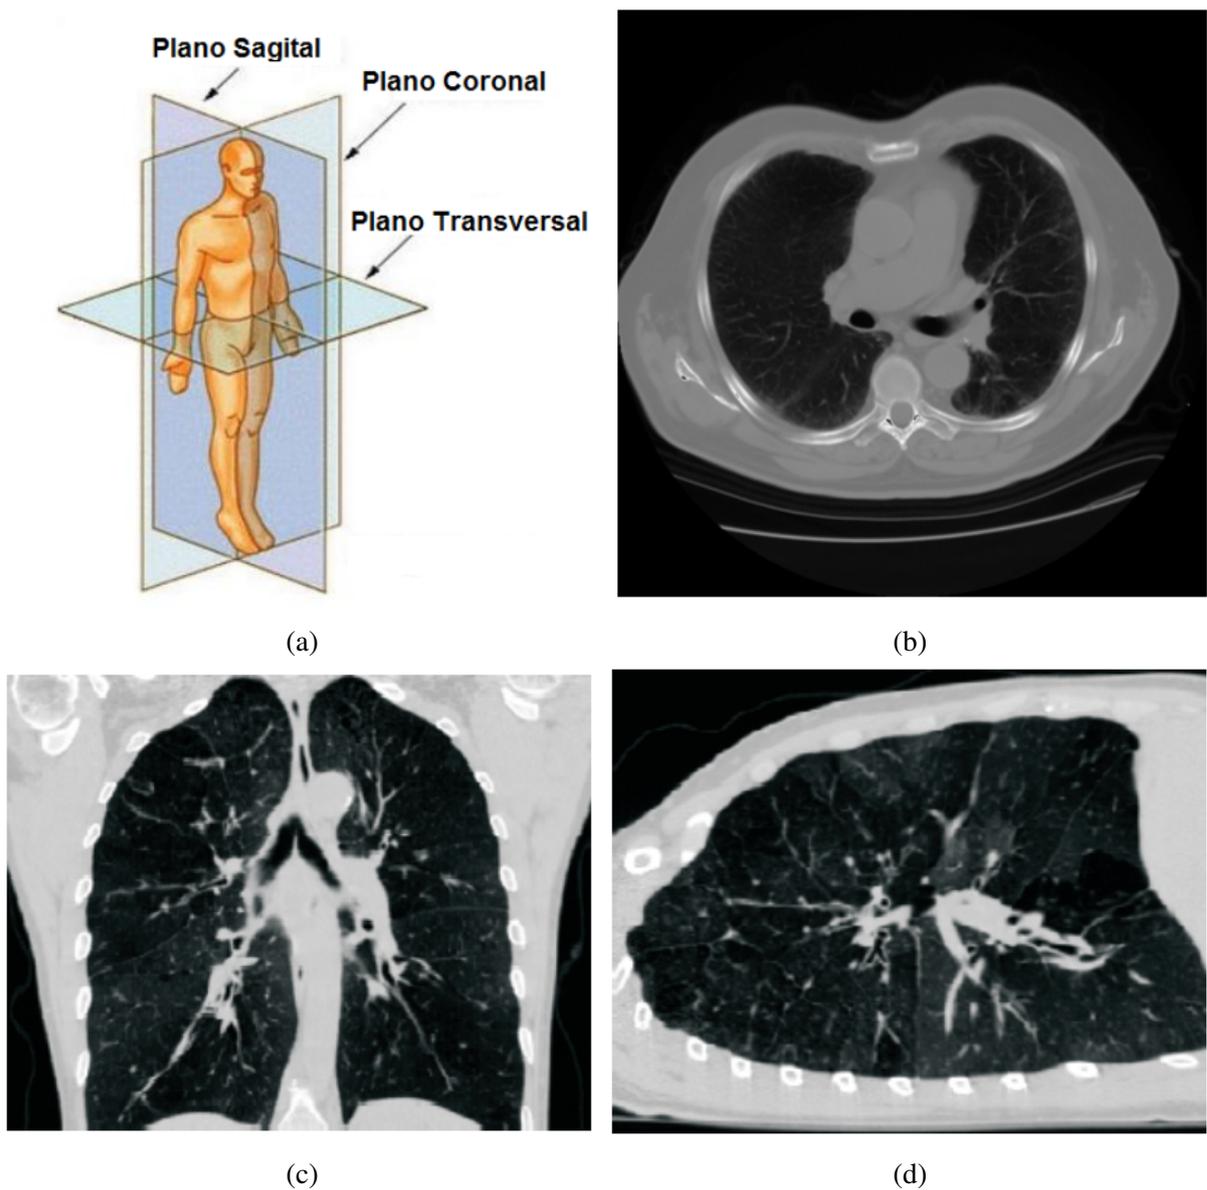


Figura 2 – Planos de imagens de TC (a) ilustração dos planos; (b) plano axial; (c) plano coronal; (d) plano sagital

As aquisições de imagens de TC são tipicamente realizadas em escala de 16 bits, no entanto, os valores medidos se encontram apenas na faixa de -3000 a 1000 UH (SLUIMER *et al.*, 2005). Por exemplo, o pulmão e suas estruturas internas possuem valores compreendidos entre -1000 UH e 100 UH. Ao variar essa faixa de valores é possível identificar e caracterizar estruturas pulmonares, sendo as principais faixas de densidade pulmonares listadas a seguir (GEVENOIS; YERNAULT, 1995):

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

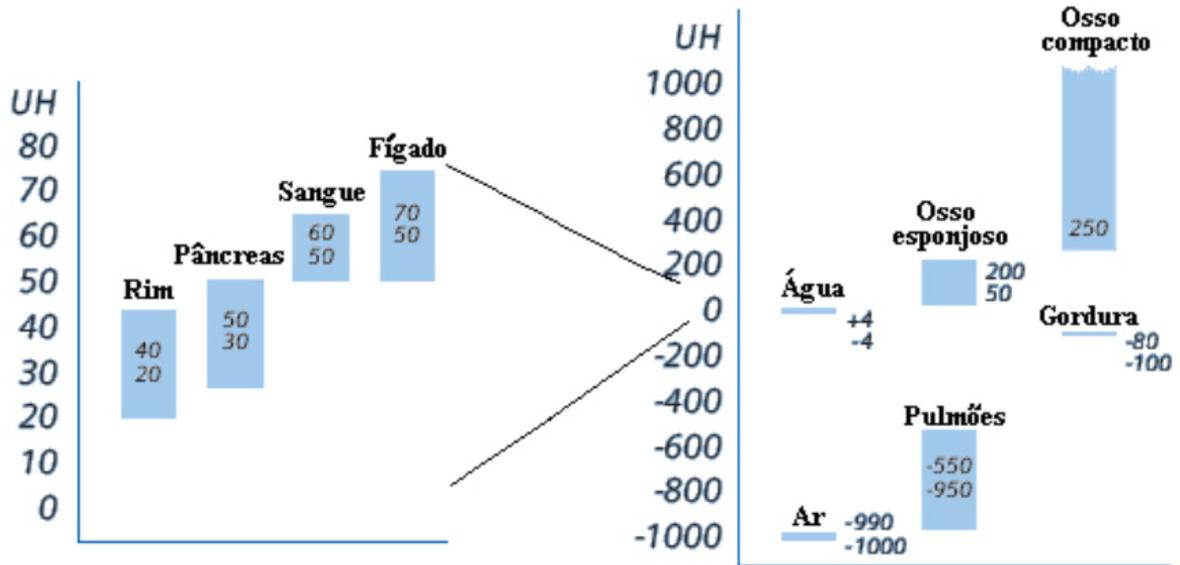


Figura 3 – Faixa de valores para diferentes tecidos e órgãos em UH. Adaptado de (SIEMENS, 2004)

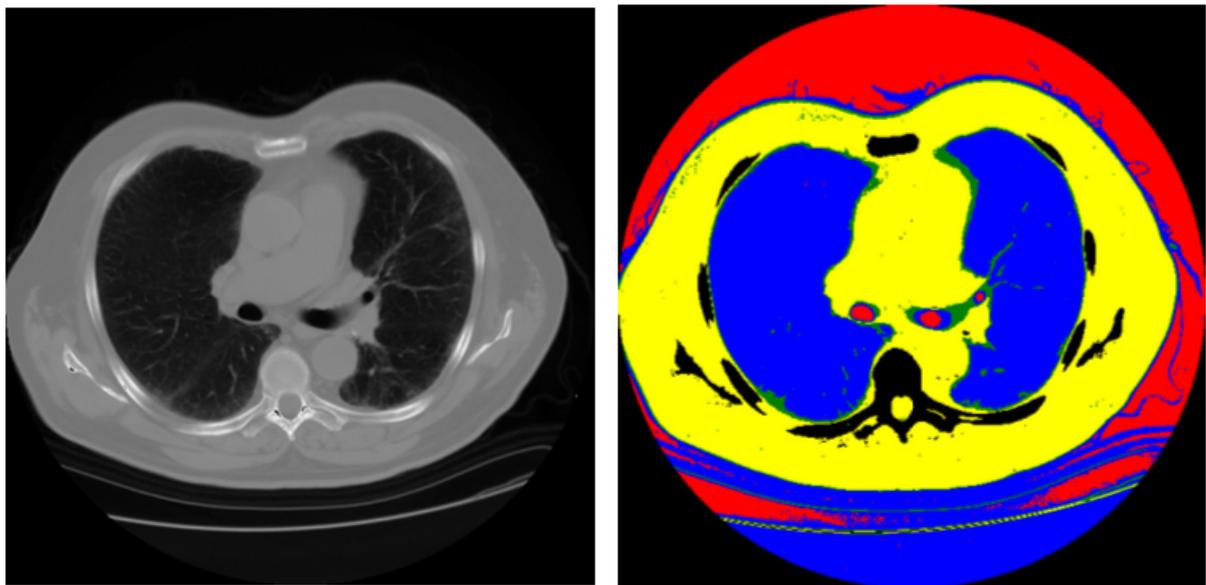
- de -100 a 100 UH para áreas não aeradas.

Uma imagem típica de TC do tórax, com máscaras coloridas para as suas áreas correspondentes, está mostrada na Figura 4. Cada cor vista na Figura 4b representa uma faixa de densidade, em que as regiões hiperaeradas estão em vermelho, regiões normalmente aeradas em azul, regiões pouco aeradas em verde e finalmente regiões não classificadas, em preto. Essas imagens são geradas pelo *LISA - Lung Image System Analysis*, que é uma ferramenta de auxílio ao diagnóstico de imagens de tomografia computadorizada dos pulmões. Este sistema é descrito detalhadamente por Valente *et al.* (2016).

O exame de TC pode apresentar características semelhantes ou até mesmo artefatos radiológicos que podem estar associados a uma variedade de enfermidades. Isto torna o diagnóstico, por este exame clínico, um problema difícil. Dessa forma, processamento de imagens de TC tem assumido um papel fundamental em auxiliar a avaliação clínica dos pacientes na visualização deste tipo de exame (STRZELECKI *et al.*, 2013).

2.2 Visão Computacional

Um sistema de Visão Computacional (VC) pode ser subdividido em etapas bem definidas: aquisição, pré-processamento, segmentação, extração de atributos e identificação (GONZALEZ; WOODS, 2012). Considerando a breve exposição do sistema de aquisição de exames de TC da seção anterior, esta dissertação concentra-se nas etapas de pré-processamento e segmentação e suas técnicas utilizadas. Um sistema típico de VC está ilustrado na Figura 5.



(a) (b)
 Figura 4 – Imagem de TC do tórax no eixo axial, (a) imagem original; (b) representação colorida das faixas de densidade.

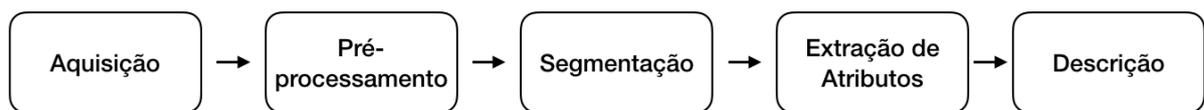


Figura 5 – Sistema de VC típico.

A etapa de pré-processamento consiste na aplicação de técnicas de filtragem com o objetivo de redução de ruídos ou adequação da imagem para melhor realce e para etapas posteriores de um sistema de VC. Esta etapa tem fundamental importância tanto para um ponto de vista de realce, quanto de preparação das imagens para as etapas de processamento subsequentes. Já a etapa de segmentação consiste em separar a imagem em sub-regiões de interesse. Nesse contexto, a segmentação é aplicada ao exame de TC do tórax, para extração da região pulmonar (GONZALEZ; WOODS, 2012).

2.2.1 Segmentação

A segmentação de imagens é uma etapa de VC e de análise de imagens com vasta variedade de aplicações. Esta etapa é fundamental para um sistema de VC e análise de imagem, em especial, em imagens médicas para detecção e diagnóstico de doenças. Seu objetivo final é subdividir a imagem em regiões de interesse. Para tanto, há diversas abordagens existentes de acordo com o problema a ser resolvido, bem como a estratégia de análise da imagem. Esta etapa

é essencial para o processo de descrição e classificação do objeto a ser segmentado (JAIN, 1989; DOUGHERTY, 2009).

A segmentação de imagens pode ser dividida em duas abordagens: segmentação por descontinuidades e segmentação por similaridade. Segmentação por descontinuidades baseia-se na detecção de fronteiras da região de interesse a fim de delimitar a região do objeto. A segmentação por similaridade baseia-se na subdivisão de regiões com características semelhantes, como cor ou forma e características do objeto a ser segmentado. Para aumentar a robustez do sistema a ser desenvolvido, é importante considerar informações da imagem que possam direcionar a melhor abordagem de segmentação (CHO *et al.*, 1993; GONZALEZ; WOODS, 2012).

2.2.1.1 Segmentação por Similaridade

A segmentação por similaridade é realizada através da separação de objetos de interesse com base em semelhanças de suas características. Essas características podem ser a cor (valor de intensidade do *pixel*), altura, largura, área da região, entre outras. Dentre as técnicas de segmentação com essa abordagem, destacam-se a limiarização, crescimento de regiões.

2.2.1.1.1 Limiarização

A limiarização é uma das técnicas mais populares e pioneiras de segmentação. O processo de limiarização mais simples consiste em classificar os *pixels* em segundo plano e primeiro plano de acordo com o nível de intensidade dos *pixels*, sendo esse processo chamado de binarização. Todavia, pode ser aplicado para dividir a imagem em mais de dois planos. Sua aplicação se dá pela comparação de todos os valores de intensidade com um valor de limiar e modificá-los para a intensidade desejada, geralmente máximo (branco) e mínimo (preto), ou valores intermediários no caso de limiarização não binária, resultando no realce de regiões compreendidas em faixas de níveis de cinza semelhantes. Gonzalez e Woods (2012) a define como a divisão da imagem em regiões de acordo com o valor do *pixel*.

Desta forma, é determinado um valor de referência, ou limiar, no qual cada *pixel* da imagem é comparado. O valor de cada *pixel* é modificado máximo (branco), caso seja maior que o valor de limiar, e modificado mínimo (preto), caso contrário. Neste caso, resultando em uma imagem binária. O valor do limiar pode ser fixo, escolhido empiricamente de acordo com a aplicação, ou adaptativo, em que o valor é determinado em função de propriedades estatísticas

de distribuição dos *pixels*. Essas propriedades podem ser a média total dos valores, mediana, desvio padrão, entre outras.

Alguns autores propuseram diversos limiares adaptativos. Glasbey (1993) propôs um limiar baseado no valor médio dos *pixels*, já Pratt (1991) usa um valor de limiar baseado na derivada do histograma da imagem e Otsu (1979) desenvolveu outra abordagem baseada em busca exaustiva do valor de limiar que maximiza a variância entre os objetos da imagem. A Figura 6 apresenta um exemplo da aplicação do limiar em uma imagem de TC do pulmão. A Figura 6a é a imagem original e a Figura 6b a imagem limiarizada em dois níveis (binária).

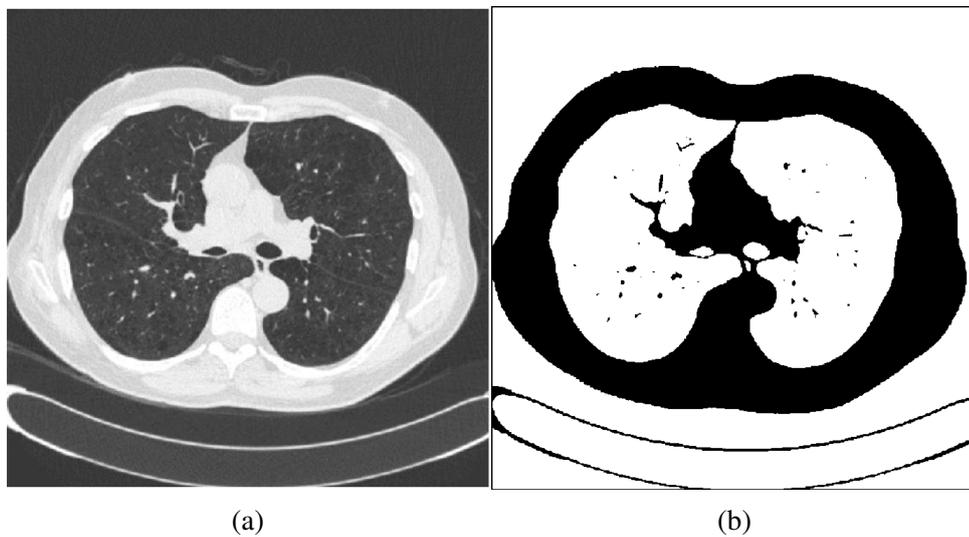


Figura 6 – Segmentação por limiarização, (a) imagem original; (b) imagem limiarizada.

2.2.1.1.2 Crescimento de Regiões

O crescimento de regiões faz parte do grupo de técnicas de segmentação por similaridades, em que é realizado o agrupamento de *pixels*, delimitando as sub-regiões com bordas definidas, a partir de critérios pré-configurados. Este algoritmo trata de agrupar *pixels* vizinhos, partindo de um *pixel* inicial, denominado de semente. Novos *pixels* são acrescentados à região até que o critério de parada seja atingido (GONZALEZ; WOODS, 2012). Essa técnica pode ser aplicado tanto em 2D quanto 3D. Enquanto uma imagem em 2D contém as direções x e y dos eixos de coordenadas, em 3D é possível aplicar a mesma ideia considerando o eixo z o índice da imagem em uma pilha de imagens 2D.

Seja R uma região de N *pixels* vizinhos de uma semente com nível de cinza y . Defina-se a média da região \bar{X} e dispersão S^2 por (SHAPIRO; STOCKMAN, 2001):

$$\bar{X} = \frac{1}{N} \sum_{[x,y,z] \in R} I[x,y,z] \quad (2.1)$$

$$S^2 = \sum_{[x,y,z] \in R} (I[x,y,z] - \bar{X})^2. \quad (2.2)$$

Considerando o *pixel semente*, y e todos os *pixels* da região R são independentes e normalmente distribuídos, um limiar pode ser definido por

$$T = \left[\frac{(N-1)N}{(N+1)} \frac{(y - \bar{X}^2)}{S^2} \right]^{\frac{1}{2}}. \quad (2.3)$$

De modo que, caso T seja um valor pequeno, y é adicionado à região R e o valor da média \bar{X} é atualizado. A nova média de dispersão é dada por

$$\bar{X}_i = \frac{(N \cdot \bar{X}_{i-1} + y)}{(N+1)}. \quad (2.4)$$

Por outro lado, se o valor de T for muito alto, torna-se menos provável que o valor de y faça parte da região R em crescimento. Se y for um valor diferente de todos os vizinhos, inicia-se uma nova região S (SHAPIRO; STOCKMAN, 2001):

$$S_i^2 = S_{i-1}^2 + (y - \bar{X}_{novo})^2 + N(\bar{X}_{novo} - \bar{X}_{antigo})^2 \quad (2.5)$$

Um exemplo de aplicação do método de Crescimento de Regiões 3D é ilustrado na Figura 7. A partir de um conjunto de imagens que formam um volume de dimensão $3 \times 5 \times 5$, em que os *voxels* são representados por uma cor diferente, de acordo com suas características. Assim, deseja-se segmentar *voxels* brancos do volume, tendo como semente os *voxels* vermelhos.

Sabendo que esse método baseia-se na similaridade entre a semente e os *voxels* vizinhos, a escolha da posição inicial da semente deve ser realizada de forma estratégica para se obter o melhor desempenho (CAVALCANTI NETO, 2014). A Figura 7a apresenta o posicionamento da semente escolhida. A Figura 7b mostra o processo de segmentação após a primeira iteração. A Figura 7c ilustra o resultado final da segmentação, a partir da semente escolhida, em que pode-se ver a região vermelha segmentada.

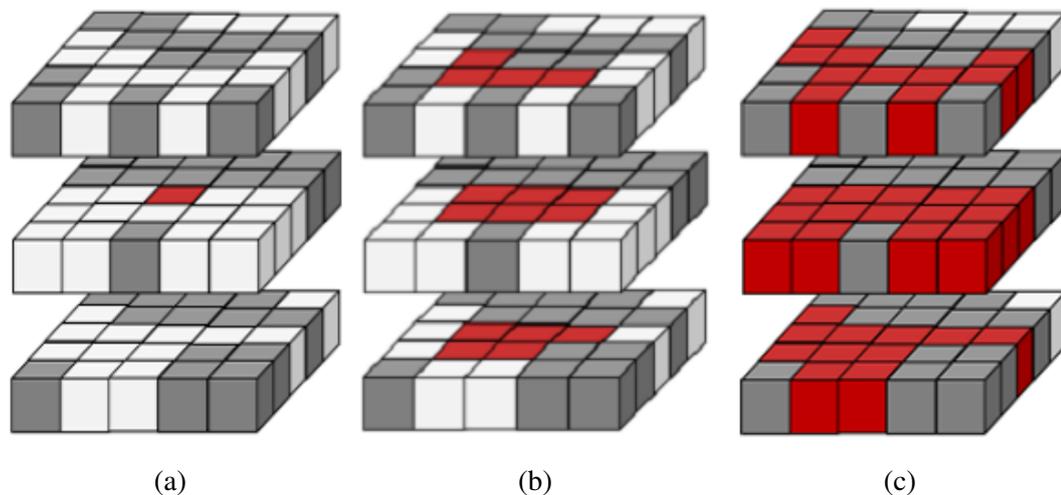


Figura 7 – Ilustração da aplicação do Crescimento de Região 3D, (a) determinação da semente, (b) primeira iteração do CR3D, e (c) resultado final da segmentação (RIBEIRO, 2013).

2.2.2 Morfologia Matemática

A Morfologia Matemática possui um amplo campo de atuação dentro da Visão Computacional e tem como objetivo principal destacar componentes da imagem de acordo com formas descritivas, como bordas, curvas convexas, e formatos geométricos distintos. Todavia, Morfologia Matemática também pode ser aplicada no pré-processamento, reduzindo ruídos da imagem, ou pós-processamento em técnicas como esqueletização, poda, ou até mesmo segmentação por descontinuidade, usado como um detector de bordas (GONZALEZ; WOODS, 2012; MCANDREW, 2004; MARCHAND-MAILLET; SHARAIHA, 1999).

Neste campo de estudo, são definidos alguns operadores morfológicos básicos: Dilatação, Erosão, Anti-Dilatação e Anti-Erosão. Muitos dos algoritmos morfológicos podem ser compostos pela combinação dessas operações primitivas (BANON; BARRERA, 1994).

Morfologia matemática é amplamente composta por operações de conjuntos, geralmente realizada entre dois conjuntos não-vazios, em que um dos conjuntos representa a imagem principal, e o outro o elemento estruturante. O elemento estruturante pode ser visto como uma sub-imagem de tamanho e forma variantes, de acordo com o resultado esperado da operação morfológica (GONZALEZ; WOODS, 2012).

Desta forma, assumindo que imagens em níveis de cinza podem ser representadas por conjuntos cujos componentes se encontram no espaço Z^3 , sendo dois componentes as coordenadas x e y da imagem e o terceiro o seu valor de intensidade que pode representar a cor da imagem, é plenamente possível realizar operações morfológicas em imagens não binárias. Todavia, estas operações podem ser particularizadas para o caso de imagens binárias, que são

analogamente representadas no espaço Z^2 , portanto, simplificando suas aplicações, de modo que os conjuntos morfológicos representam os diferentes objetos presentes na imagem. Neste caso, trata-se de morfologia matemática binária (GONZALEZ; WOODS, 2012).

2.2.2.1 Dilatação e Erosão

Neste sentido, seja A , a imagem a ser filtrada e B o elemento estruturante. A operação de dilatação binária $A \oplus B$ em Z^2 pode ser definida pela seguinte expressão (GONZALEZ; WOODS, 2012):

$$(A \oplus B) = \{z | (\hat{B})_z \subseteq A\}, \quad (2.6)$$

de modo que o resultado da dilatação de A por B consiste em um conjunto com todos os pontos $z = (x, y)$ para cada elemento B_z em A . De semelhante modo, a erosão binária de A por B , $A \ominus B$ pode ser definida por

$$(A \ominus B) = \{z | [(\hat{B})_z \cap A] \subseteq A\}, \quad (2.7)$$

em que \hat{B} é a reflexão de B sobre sua origem e transladado por z , i.e. para cada elemento $x \in B$, A é transladado por estas coordenadas. Este processo resulta na expansão da imagem original (GONZALEZ; WOODS, 2012). Essa operação é ilustrada na Figura 8. O resultado do operador de erosão sobre a imagem original é mostrada na Figura 8b e a Figura 8c apresenta o resultado do operador de dilatação sobre a imagem original.

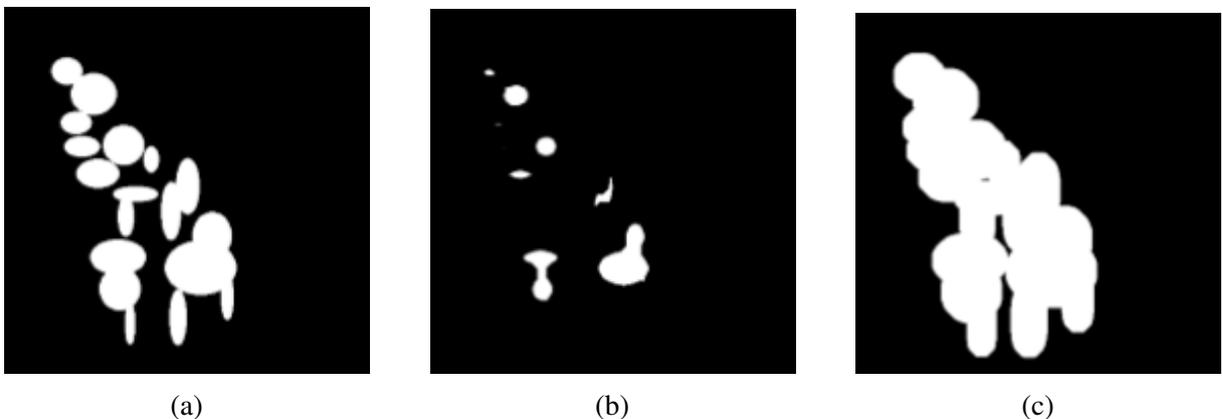


Figura 8 – Ilustração da aplicação do Morfologia Matemática, (a) imagem original, (b) aplicada erosão, e (c) aplicada dilatação (CAVALCANTI NETO, 2014).

A combinação de operadores morfológicos pode formar novas funções de grande importância no realce de imagens, por exemplo, o gradiente morfológico, abertura, fechamento, dentre outras.

2.2.2.2 *Abertura e Fechamento*

A abertura binária é o resultado da operação de erosão binária seguida da dilatação binária, e é definida como se segue (GONZALEZ; WOODS, 2012):

$$(A \circ B) = (A \ominus B) \oplus B, \quad (2.8)$$

em que tem como efeito a suavização de bordas e eliminação de ruídos. Esta sequência de operações promove a união de todas as translações de B pertencentes a A (GONZALEZ; WOODS, 2012; MCANDREW, 2004; JAIN, 1989).

Ao inverter a sequência de operações, fazendo a dilatação binária seguida da erosão binária, obtém-se a operação de fechamento binário, expressa da seguinte forma (GONZALEZ; WOODS, 2012):

$$(A \bullet B) = (A \oplus B) \ominus B. \quad (2.9)$$

Essa operação tem como resultado a conexão entre contornos próximos, bem como o preenchimento de lacunas no contorno da imagem alvo (GONZALEZ; WOODS, 2012; JAIN, 1989). A Figura 9a apresenta a imagem original, as Figuras 9b e 9c ilustram as operações de abertura e fechamento sobre a imagem original, respectivamente.

2.2.2.3 *Análise de Componentes Conectados*

Análise de componentes conectados é geralmente usado em problemas de processamento de imagens para atribuir rótulos a objetos conectados em imagens binárias (NARASIMHAN *et al.*, 2017). Seja A um conjunto contendo um ou mais componentes conectados que formam uma imagem I , cujos elementos possuem valor 0 (valores de fundo) e 1 (valores de frente). Desta forma, é atribuído o valor 1 para cada ponto que corresponde a um componente

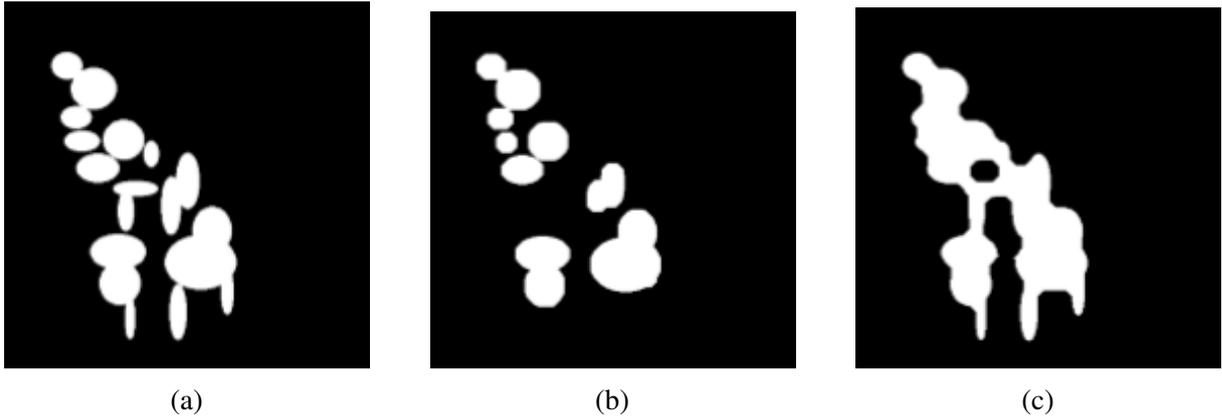


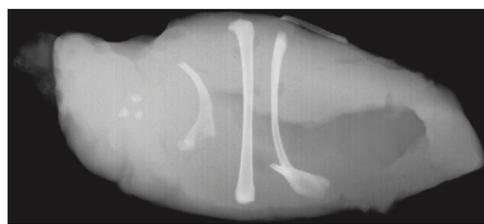
Figura 9 – Ilustração da aplicação do Morfologia Matemática, (a) imagem original, (b) aplicada abertura, e (c) aplicado fechamento (CAVALCANTI NETO, 2014).

conexo em A . O objetivo é encontrar todos os componentes conectados na imagem I , partindo de I_0 . O seguinte processo iterativo cumpre esse objetivo (GONZALEZ; WOODS, 2012):

$$I_k = (I_{k-1} \oplus B) \cap A \quad k = 1, 2, 3, \dots \quad (2.10)$$

em que B é o elemento estruturante e k a quantidade de iterações ao final do processo. Tem-se o conjunto com todos os elementos conectados quando $I_k = I_{k-1}$, e I_k contém todos os componentes da imagem de entrada.

Ao extrair cada componente, comumente são rotulados para que possam ser identificados, filtrados, destacados, dentre outras operações relevantes de acordo com a aplicação. Além disso, cada componente pode ser representado por suas propriedades e características para que possam ser diferenciados entre si. Essas propriedades podem ser as mais diversas, como sua forma geométrica, centroide, área, perímetro, área convexa, circularidade, bem como área retangular, orientação, dentre outras (GONZALEZ; WOODS, 2012). Deste modo, a Figura 10 ilustra uma aplicação desta técnica, detalhando em uma tabela cada componente encontrado na imagem e sua respectiva quantidade de *pixels*.



(a)



(b)



(c)

Componente conexo	Número de pixels no componente conexo
	11
	9
	9
	39
	133
	1
	1
	743
	7
10	11
11	11
12	9
13	9
14	674
15	85

(d)

Figura 10 – Aplicação componentes conectados, (a) imagem original, (b) binarização de (a), (c) erosão binária em (b), e (d) tabela com quantidade de *pixels* de cada componente. Adaptada de Gonzalez e Woods (2012)

3 METODOLOGIA

Neste capítulo são descritas as etapas da abordagem de segmentação pulmonar e reinclusão de nódulos proposta nesta dissertação. A sequência do processo é composta pelas etapas: aquisição de imagens, filtragem gaussiana 3D, limiarização automática, análise de componentes conectados 3D para extração do parênquima pulmonar, preenchimento de buracos e reinclusão de nódulos.

O filtro gaussiano 3D é utilizado para suavizar as bordas e evitar o surgimento de ruídos após a limiarização automática, que consiste em uma pré-segmentação das estruturas de baixa densidade, incluindo o pulmão. O resultado desta limiarização é um exame de TC binário composto por diversas imagens 2D que compõem o volume. Em seguida, usa-se a análise de componentes conectados 3D para eliminar os volumes indesejados, com o objetivo de extrair apenas o parênquima pulmonar. A seguir, o preenchimento de buracos é aplicado ao volume pulmonar para fechar o contorno do mesmo, incluindo assim, possíveis nódulos presentes na região interna do pulmão. Embora exista uma operação morfológica para fechamento de buracos, nesta dissertação uma abordagem heurística é proposta por apresentar vantagens em relação ao método morfológico e é uma das contribuições desta dissertação. Finalmente é realizado o processo de reinclusão de nódulos justa-pleurais que também consiste em uma nova abordagem proposta por esta dissertação, sendo considerada sua principal contribuição. A Figura 11 ilustra as etapas da abordagem proposta com as respectivas imagens representativas de cada etapa.

A etapa de aquisição consiste na leitura de uma ou mais imagens de entrada para serem processadas. Nesta dissertação, os exames de TC foram adquiridos através do banco de imagens *Lung Image Database Consortium (LIDC-IDRI)*, que é detalhado no Capítulo 4.

3.1 Segmentação do Pulmão

A fase de segmentação pulmonar consiste nas seguintes etapas: filtragem gaussiana 3D, limiarização automática, análise de componentes conectados 3D e preenchimento de buracos.

A primeira etapa é a filtragem gaussiana 3D, onde ocorre a suavização da imagem, prevenindo o surgimento de ruídos indesejados decorrentes da etapa de limiarização automática. O excesso de ruídos pode dificultar o processo de localização do volume pulmonar pela análise de componentes conectados. Além disso, aumentar o tempo de processamento devido a maior quantidade de contornos a serem processados.

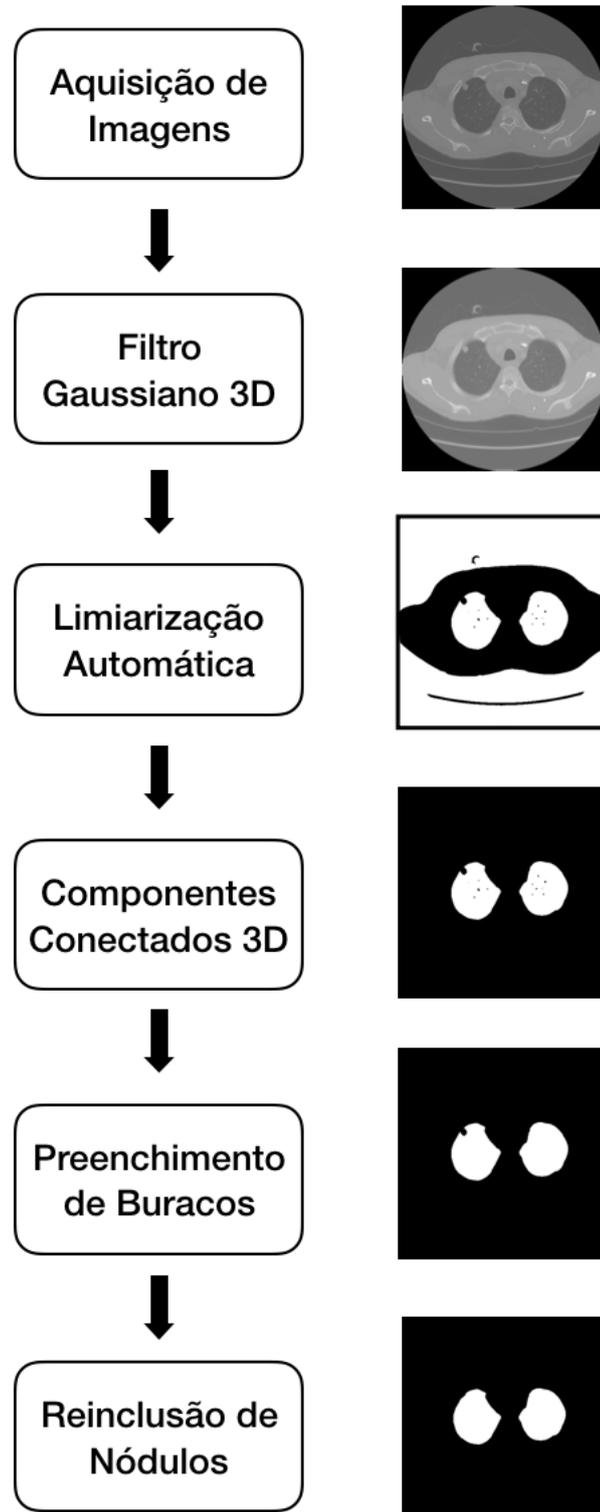


Figura 11 – Fluxograma da abordagem de segmentação pulmonar proposta.

O filtro gaussiano é aplicado na imagem original, antes da limiarização, pois com seu efeito de suavização de bordas e "borramento", há naturalmente a remoção de pequenos pontos. Por outro lado, se aplicado o filtro após a limiarização, portanto na imagem binária, não há ganho na aplicação dessa filtragem.

Como pode ser visto na Figura 12, a aplicação do filtro gaussiano após a limiarização não remove o ruído remanescente da imagem original. Na Figura 12a, observa-se um ruído no canto superior esquerdo da imagem, na Figura 12b o ruído, destacado em vermelho, permanece na imagem binária e na Figura 12c nota-se que o ruído não é removido pelo filtro gaussiano. Por outro lado, a Figura 12d, mostra o processo na ordem em que é implementado nesta dissertação. Na Figura 12d, a aplicação do filtro gaussiano na imagem original, ao invés da imagem limiarizada, e finalmente em 12e a limiarização aplicada na imagem suavizada pelo filtro gaussiano onde pode-se notar a remoção do ruído em questão.

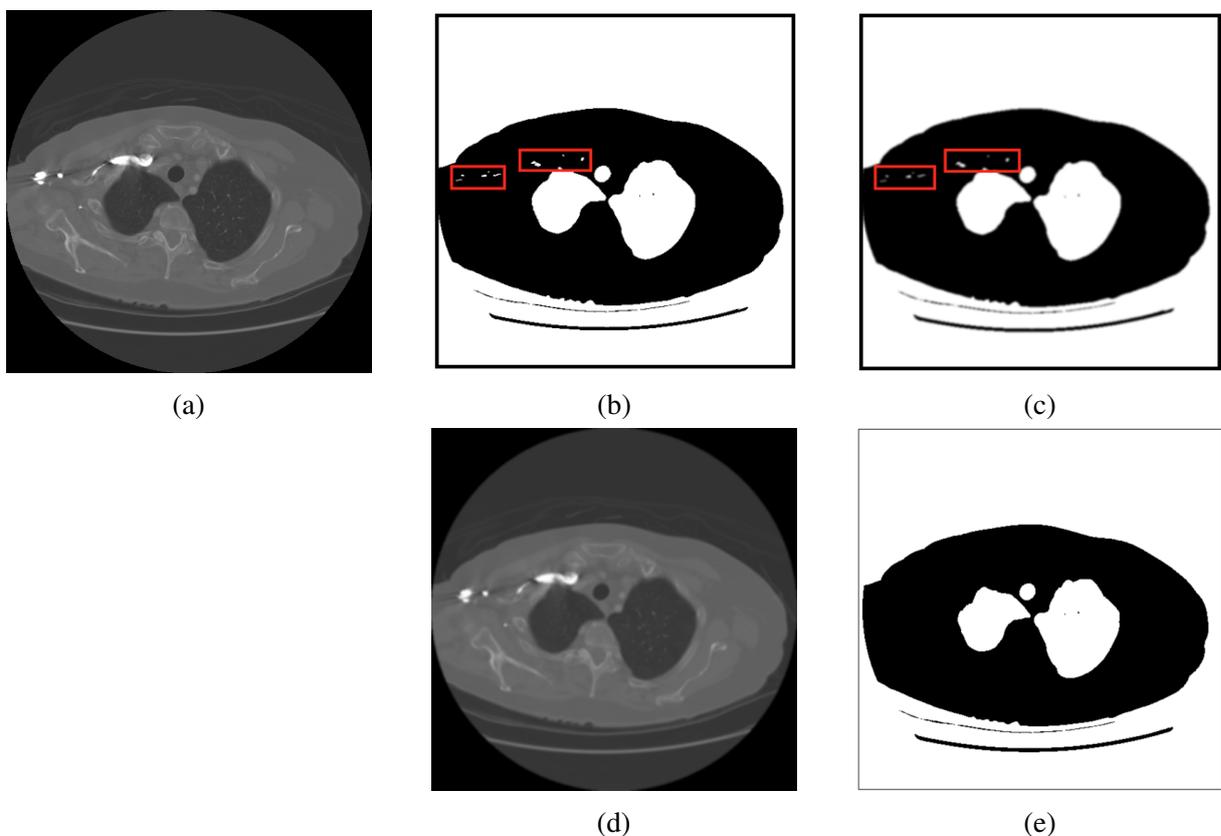


Figura 12 – Ilustração da aplicação da filtragem gaussiana após limiarização, (a) imagem original, (b) imagem limiarizada (binária), (c) resultado da filtragem gaussiana aplicada na imagem b, (d) aplicado filtro gaussiano em a, e (e) aplicado limiarização em d.

Nesta dissertação é utilizada uma limiarização automática 3D, em que o valor de limiar é calculado automaticamente em função dos valores de *voxels* encontrados no conjunto de imagens, ou fatias do exame.

Nesta etapa, por se tratar de uma limiarização 3D, o conjunto de imagens é tratado como um *array* tridimensional único que compõe todo o exame de TC. Conforme utilizado por Choi e Choi (2014), o procedimento é descrito da seguinte forma: primeiramente, é atribuído o valor de -1000 UH para os *voxels* de valor inferior a -1000 UH. Em seguida, é atribuído o valor inicial de -500 UH, pois a região pulmonar encontra-se entre -910 e -500 UH. Assim, em um processo iterativo, aplica-se a limiarização no conjunto de imagens, atualizando o valor de limiar baseado nas novas imagens geradas. A cada iteração o valor de limiar é atualizado segundo a equação:

$$T^{i+1} = \frac{\mu_0 + \mu_b}{2}, \quad (3.1)$$

em que T^{i+1} é o limiar da iteração atual, μ_0 é a média das densidades da região correspondente ao plano de frente na imagem original, e μ_b é média da região correspondente ao plano de fundo na imagem original. O processo se repete atualizando o valor limiar otimizado em cada iteração, até que não haja alteração entre os valores de limiar das iterações atual e anterior. De posse do conjunto de imagens binarizadas, segue-se a etapa de extração do volume pulmonar dentre os volumes presentes, utilizando análise de componentes conectados 3D.

O método de análise de componentes conectados 3D segmenta regiões distintas de um volume composto por conjunto de imagens de um dado exame de TC, permitindo a identificação das mesmas através de diferentes propriedades, tais como área, coordenadas, largura, altura, dentre outras. A Figura 13 apresenta alguns cortes de volumes encontrados ao longo de um dado exame, em que suas regiões são representadas por diferentes cores.

Concluído o processo de segmentação por análise de componentes conectados, alguns exames apresentam pulmões muito próximos um do outro, de modo que chegam a se unir, gerando apenas um volume. Isto gera um problema para as etapas subsequentes do processo de segmentação.

Para resolver essa dificuldade, é realizado um simples procedimento para promover a separação dos pulmões. Este é um processo 2D, portanto, é realizado em cada imagem do exame que obedecem ao critério de união, isto é, nas imagens em que há apenas um contorno presente, caracterizando que os dois pulmões estão unidos. Para cada uma dessas fatias do exame, a partir

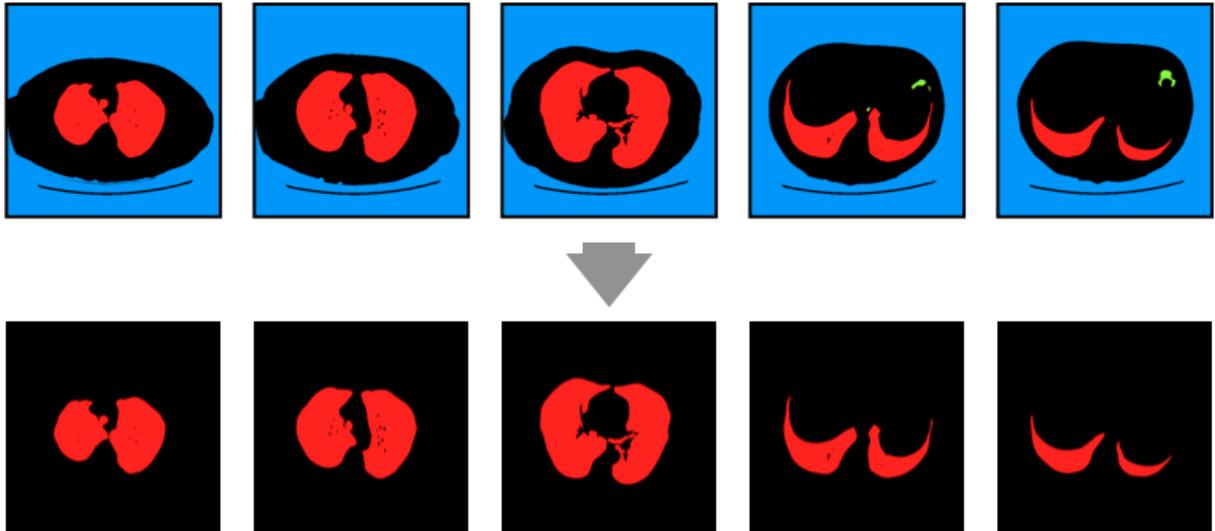


Figura 13 – Ilustração do resultado da aplicação da Análise de Componentes Conectados 3D na segmentação pulmonar.

das coordenadas que compõem o volume, encontram-se os pontos mínimo no eixo y e mínimo e máximo do eixo x . Em seguida, acrescenta-se uma margem fixa nos dois eixos, delimitando uma região de interesse onde se encontra a interseção dos pulmões.

De posse da região de interesse, aplica-se o método de abertura morfológica, resultando na separação da região conectada. Finalmente, a operação binária OR é realizada entre região de interesse e a imagem original, conforme é apresentado na Figura 14.

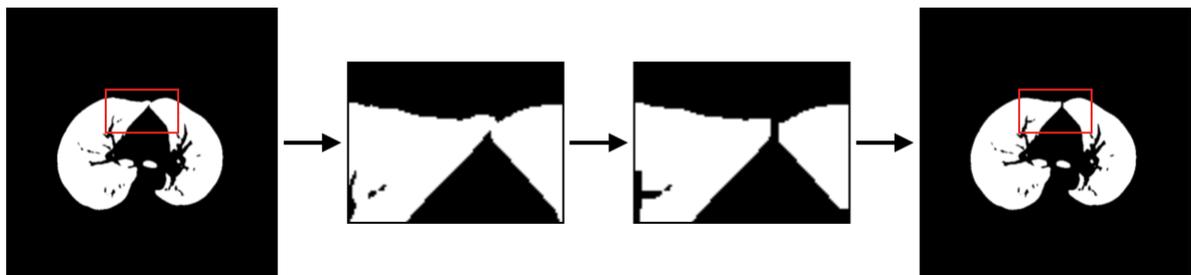


Figura 14 – Ilustração do processo de separação dos pulmões.

Após a separação dos pulmões, para incluir nódulos que possam eventualmente terem sido excluídos, é necessário fechar os espaços encontrados na região interna de cada pulmão. Para este tipo de problema, o operador de preenchimento de buracos morfológico é comumente utilizado. Todavia, nesta dissertação é executado um algoritmo diferente com o mesmo objetivo. Esta escolha foi feita em função da diminuição de possibilidade de erros na escolha do tamanho da máscara utilizada na operação morfológica, bem como para reduzir o custo computacional, no caso de se utilizar uma máscara de tamanho elevado e por simplicidade

de implementação.

Neste processo, a análise do exame é feita em 2D, isto é, fatia por fatia. Diante disto, de posse do resultado da separação de pulmões, é garantido que em cada imagem haja pelo menos dois contornos. No entanto, os outros contornos presentes correspondem a regiões menores que se encontram abertas dentro do pulmão, representando outras estruturas pulmonares como vias aéreas, vasos sanguíneos ou até mesmo nódulos isolados ou justa-vasculares. Desta forma, este processo pode ser descrito em três passos: extração dos contornos da imagem, filtragem dos dois maiores contornos e preenchimento das regiões internas dos contornos. Assim, os contornos menores são sobrepostos por serem internos aos dois contornos maiores, obtidos pelo critério de área. A Figura 15 ilustra esse processo.

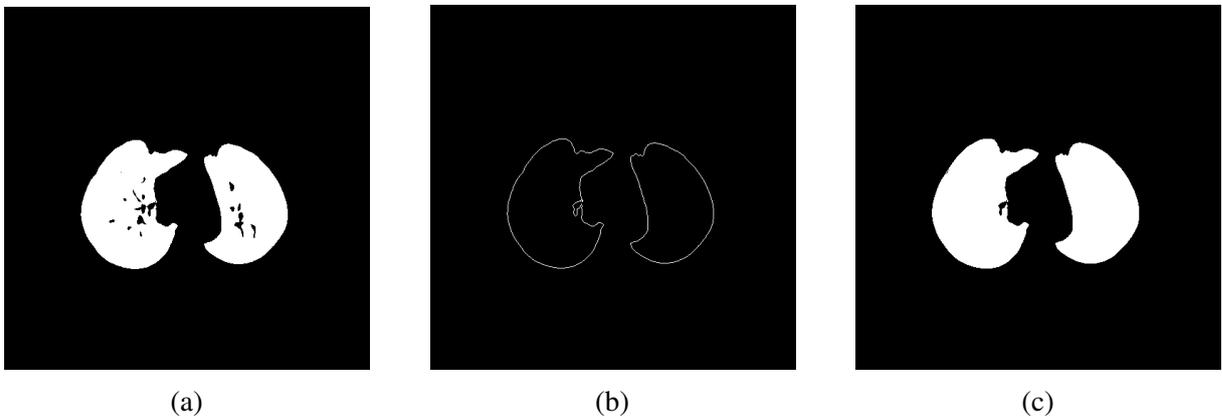


Figura 15 – Ilustração do processo de preenchimento de buracos, (a) pulmão segmentado, (b) dois maiores contornos e (c) buracos preenchidos.

Contudo, preencher os buracos internos aos pulmões não inclui os nódulos justa-pleurais, ou seja, os nódulos conectados a borda pulmonar, que devem ser incluídos na segmentação dos pulmões. Um exemplo de um desse nódulos está mostrado na Figura 16.



Figura 16 – Exemplo de nódulo justa-pleural.

3.2 Reinclusão de Nódulos

A reinclusão de nódulos justa-pleurais representa um grande desafio no processo de segmentação pulmonar. A dificuldade desta tarefa é decorrente da alta densidade dos nódulos, tornando-os indistinguíveis das regiões externas do pulmão. Desta forma, tenta-se corrigir as bordas do pulmão o máximo possível.

A região lateral dos pulmões possui um formato naturalmente convexo. Por outro lado, a região mediastínica é côncava. Essa diferença geométrica conduz a um problema mais difícil de ser resolvido a partir de uma solução única. Por esse motivo, as duas regiões são divididas em problemas menores. Todavia, ambas as soluções utilizam a mesma ideia central, o fecho convexo dos contornos. A primeira forma consiste em utilizar o fecho convexo do contorno para fechar as lacunas na região lateral dos pulmões e aplicar o preenchimento de buracos novamente. A segunda forma consiste de operações morfológicas para realizar o crescimento do contorno pulmonar de modo a extrapolar fecho convexo do mesmo e depois a remoção da porção extrapolada.

Os nódulos justa-pleurais que se encontram na região lateral, como o que está apresentado na Figura 16 podem gerar aberturas de diferentes tamanhos no contorno pulmonar. Por esse motivo, somente métodos morfológicos não são confiáveis para resolver esse problema, devido a dificuldade de parametrização dos elementos estruturantes, bem como custo computacional excessivo. Todavia, não havendo a abertura na região lateral, um simples algoritmo de preenchimento de buracos pode eficazmente reincluir nódulos justa-pleurais da região lateral.

O fecho convexo de um conjunto de pontos X é definido pelo menor conjunto de pontos que circunscreve X (GRÜNBAUM, 2003). Nesta dissertação, o fecho convexo dos pulmões é calculado através do método "força bruta", no qual os pontos mais externos dos contornos são ligados ao ponto mais próximo por retas.

Diante disso, para fechar as aberturas causadas pelos nódulos justa-pleurais, o fecho convexo calculado dos pulmões são adicionados aos mesmos para garantir o fechamento total dos contornos. Desse modo, o nódulo justa-pleural passa a ser tratado como um buraco, e assim, pode ser fechado através da aplicação do preenchimento de buracos. Todavia, o fecho convexo circunscreve todo o pulmão, e não apenas a região lateral. Assim, o algoritmo de preenchimento de buracos preencheria toda o fecho convexo do pulmão, gerando um resultado indesejado. Para evitar que isso ocorra, é realizado uma limitação do fecho convexo na região correspondente ao mediastino, dessa forma, tornando o preenchimento de buracos eficaz apenas para a região

lateral. A Figura 17 ilustra as etapas desse processo.

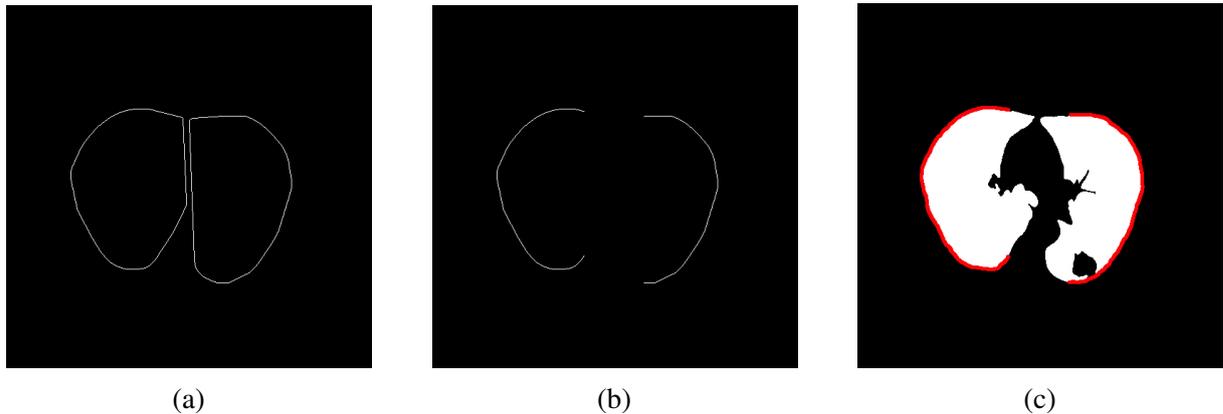


Figura 17 – Processamento para região lateral com fecho convexo, (a) fecho convexo dos pulmões, (b) fecho convexo reduzido, e (c) fecho convexo adicionado ao contorno pulmonar na imagem segmentada.

A principal ideia desta etapa consiste na aplicação de operações morfológicas aos volumes pulmonares, enquanto ao mesmo tempo impedindo o volume de crescer além dos limites das bordas pleurais. Diante disto, o fecho convexo do contorno é utilizado para delimitar até que ponto o volume pode crescer. Essa etapa é realizada em 2D.

Esse processo é realizado primeiro calculando-se a área convexa de cada pulmão, em seguida são aplicadas duas operações morfológicas com o objetivo de aumentar a área dos pulmões e reincluir os nódulos: a dilatação e o fechamento. Em seguida, o preenchimento de buracos é aplicado novamente, para garantir que novos buracos que possam surgir sejam fechados. Finalmente, multiplica-se o volume resultante pelo volume composto pelas áreas convexas dos pulmões, eliminando assim, as regiões que passaram dos limites da borda pleural. Esse processo é ilustrado detalhadamente na Figura 18.

A forma apresentada para reinclusão de nódulos justa-pleurais produz diferentes resultados para a região lateral e mediastínica do pulmão. Na região lateral, o objetivo é atingido sem distorções significativas na forma final atingida. Isso ocorre, porque, o formato dessa região é convexa, assemelhando-se a área convexa calculada. Por outro lado, na região mediastínica, por sua concavidade natural, há uma margem de erro gerada pela diferença entre essa região e a área convexa, resultando em uma deformação maior no resultado final da segmentação na parte central do pulmão.

Todavia, esse compromisso é necessário, pois, a nível de unidade de *Hounsfield*, os nódulos são muito semelhantes a região externa aos pulmões, tornando difícil a delimitação da região de interseção destas.

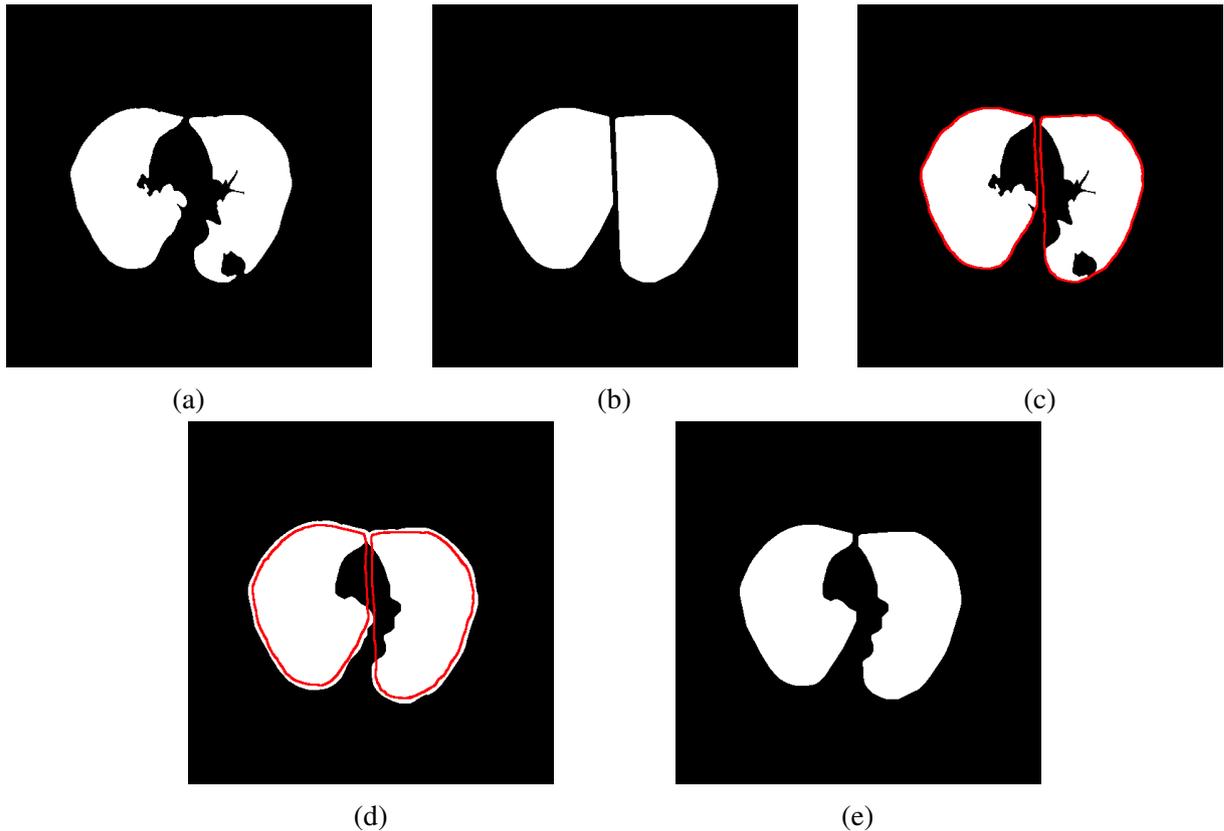


Figura 18 – Reinclusão de nódulos, (a) segmentação após fechamento de buracos, (b) fecho convexo de (a), (c) fecho convexo sobreposto em (a) para ilustração, (d) dilatação e fechamento, (e) multiplicação binária entre (b) e (d) excluído o fecho convexo.

A avaliação da abordagem apresentada é realizada através da comparação dos resultados com o padrão ouro, gerado manualmente sob a supervisão de especialistas, cujas métricas de semelhança são descritas a seguir.

As métricas de avaliação utilizadas são: Ajuste de Forma, *Dice Similarity Coefficient*, Segmentação Excessiva e Segmentação Insuficiente. Tais medidas são selecionadas em decorrência de sua representatividade quanto à comparação da semelhança medida entre a imagem de referência R e a imagem segmentada S , quando sobrepostas (CAVALCANTE, 2016).

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

$$Fit_F = 1 - \frac{(R \cap S)}{(R \cup S)}. \quad (3.2)$$

Esta medida varia entre 0 e 1. Quando tende a 1, indica que há uma concordância na sobreposição das regiões de ambas as imagens.

Dice Similarity Coefficient (DSC) - o DSC é uma medida de consistência entre a

imagem segmentada e a imagem de referência quanto à classificação binária dos *pixels* e é dada por (DAI *et al.*, 2015):

$$DSC = 2 * \frac{S \cap R}{|S| + |R|}. \quad (3.3)$$

Além das métricas apresentadas, são realizadas duas medidas adicionais: segmentação excessiva (*over segmentation*) e segmentação insuficiente (*under segmentation*). Essas medidas objetivam calcular o conteúdo excedente e ausente nas regiões da imagem segmentada em relação a imagem de referência (SHEN *et al.*, 2015).

Segmentação Excessiva (*Over Segmentation*) - seja A_{seg} a área total das regiões da imagem segmentada e A_{ref} o correspondente à imagem de referência, a segmentação excessiva é dada por

$$SE = \left| \frac{A_{seg} \setminus A_{ref}}{A_{ref}} \right|, \quad (3.4)$$

em que $A_{seg} \setminus A_{ref}$ representa o complemento relativo de A_{seg} em A_{ref} . Essa medida representa o percentual da máscara de referência encontrado em excesso na imagem segmentada.

Segmentação Insuficiente (*Under Segmentation*) - analogamente à medida de segmentação anterior, seja A_{seg} a área total das regiões da imagem segmentada e A_{ref} o correspondente à imagem de referência, a segmentação excessiva é dada por

$$SI = \left| \frac{A_{ref} \setminus A_{seg}}{A_{ref}} \right|, \quad (3.5)$$

em que $A_{ref} \setminus A_{seg}$ representa o complemento relativo de A_{ref} em A_{seg} . Essa medida representa o percentual de tecido pulmonar presente na imagem de referência e ausente na imagem segmentada.

Diante destas métricas e métodos descritos, os mesmos devem ser aplicados na obtenção dos resultados. Além disso, discussões relevantes devem ser realizadas visando alcançar os objetivos desta dissertação.

4 RESULTADOS

Neste capítulo são apresentados e discutidos os resultados obtidos pela segmentação dos pulmões em exames de TC do tórax, aplicados ao banco de exames LIDC-IDRI. Os testes são realizados com o intuito de avaliar o desempenho da abordagem proposta, tanto do ponto de vista de custo computacional quanto da qualidade da segmentação final obtida, considerando-se a quantidade de nódulos reincluídos. Desta forma, os resultados são divididos em três partes: qualidade de segmentação final, contagem de nódulos excluídos e custo computacional.

Para a avaliação da qualidade da segmentação, a abordagem proposta é comparada com métodos e abordagens encontradas na literatura, bem como um algoritmo de segmentação extensamente utilizado e conhecido em problemas de visão computacional: o crescimento de regiões 3D (CR3D). Além do CR3D, o método de Shen *et al.* (2015) é comparado.

A contagem de nódulos é baseada no padrão ouro apresentado na Seção 4.1. Nesta contagem um limiar do percentual da área do nódulo é adotado como critério de inclusão para considerá-lo detectado corretamente. Essa medida é detalhada neste capítulo.

Finalmente, o custo computacional é avaliado com base no tempo de processamento isolado de toda abordagem de segmentação aplicada a cada um dos 1018 exames. Essa medida é representada pela comparação da abordagem proposta e o CR3D, bem como uma estimativa de valores encontrados na literatura, visto que não há muitas referências aplicadas neste banco de exames. Além disso, as diferentes configurações de sistema podem afetar a representatividade dessa medida.

4.1 Banco de Imagens

A nova abordagem proposta é avaliada usando o banco de imagens, o *Lung Image Database Consortium* (LIDC). Este banco consiste em uma coleção de TCs do tórax com marcações de lesões pulmonares, realizadas por médicos especializados. O LIDC está disponível online, e é um recurso internacional para desenvolvimento, treinamento e avaliação de métodos de diagnóstico assistido por computador (*Computer Assisted Diagnosis - CAD*). Esta base de dados foi criada pelo *National Institute of Cancer* (NCI), desenvolvido pela *Foundation of the National Institutes of Health* (FNIH) e aprovado pela *Food and Drug Administration* (FDA) (ARMATO *et al.*, 2011).

A criação do LIDC foi realizada em sete centros acadêmicos e oito empresas de

produtos de imageamento médico em colaboração. O banco possui 1018 casos, em que cada caso inclui imagens de TC do tórax associado a um arquivo XML que registra o resultado do processo de marcação de lesões realizados por quatro radiologistas torácicos experientes em um processo de dois passos. O primeiro passo é uma fase de teste-cego, em que cada radiologista analisa as imagens e marca os nódulos encontrados na faixa de 3 a 30 mm de diâmetro. O segundo passo consiste em cada especialista revisar suas próprias marcações, juntamente com as marcações anônimas dos outros três radiologistas, a fim de gerar uma opinião final. O objetivo desse processo é identificar da melhor forma possível todos os nódulos presentes em cada um dos exames de forma mais imparcial possível (SHEN *et al.*, 2015).

4.2 Especificação de Parâmetros

Esta seção é dedicada a listar os parâmetros utilizados em cada etapa da abordagem apresentada nesta dissertação.

A maioria dos parâmetros apresentados nesta seção foi definida a partir de testes empíricos, considerando-se o resultado produzido, bem como desempenho computacional.

Filtragem Gaussiana 3D - a filtragem gaussiana 3D, referenciada na Figura 12, foi realizada com uma máscara de tamanho $7 \times 7 \times 7$, e desvio padrão σ calculado de acordo com o tamanho da máscara, segundo a equação (OPENCV, 2014):

$$\sigma = 0,3 * ((k_{size} - 1) * 0,5 - 1) + 0,8, \quad (4.1)$$

em que k_{size} é a dimensão da máscara. A escolha desses valores é realizada considerando-se o compromisso entre o tamanho mínimo necessário para remoção de ruídos sem comprometer a integridade do exame original e custo computacional, visto que quando aplicado em 3D, a dimensão da máscara pode aumentar consideravelmente o tempo de processamento.

Análise de Componentes Conectados 3D - nessa etapa, ilustrada na Figura 13, as propriedades dos volumes encontrados devem ser criteriosamente selecionadas com a finalidade de isolar o volume desejado. Deste modo, através de numerosos testes, os seguintes critérios de seleção de volumes foram definidos:

- São eliminados todos os volumes menores que 1/4 do maior volume encontrado.
- São eliminados os volumes que tem as coordenadas muito próximas da borda da imagem.

- São conservados os volumes com altura média ($y_i + h/2$) maior que 10% e menor que 90% altura da imagem.

em que y_i corresponde ao ponto inicial do volume no eixo y e h a sua altura.

Separação dos Pulmões - a separação dos pulmões, ilustrada na Figura 14, é realizada apenas nas fatias em que são identificadas com pulmões unidos. Para verificar a união dos pulmões, dois critérios são utilizados: se há apenas um volume na fatia e se o contorno desse volume é maior do que 400 *voxels*. O segundo critério é utilizado, pois em casos raros, o paciente pode possuir apenas um pulmão, tornando o primeiro critério insuficiente.

Nas fatias do exame em que foi detectada a união dos pulmões, as coordenadas da região de interesse são definidas em função das coordenadas dos pulmões, como o acréscimo de alguns valores fixos, encontrados empiricamente. Primeiramente são encontrados as coordenadas mínimas e máximas no eixo x e mínima no y . Em seguida, uma margem de 250 *pixels* é adicionada ao eixo y é adicionada ao eixo y , e 100 *pixels* são removidos às coordenadas encontradas no eixo x , estreitando a largura da região de interesse.

A operação morfológica de abertura foi realizada com máscara de tamanho 9×9 . Neste caso, poucas fatias são processadas, de modo que o tamanho da máscara não terá um grande efeito no custo computacional total da segmentação.

Reinclusão de Nódulos - nesta etapa, Figura 18, algumas operações morfológicas são utilizadas para realizar a dilatação e fechamento das regiões mediastínica dos pulmões. Os operadores foram aplicados com máscara de dimensões 7×7 . Neste caso, é necessário ter-se cautela quanto ao tamanho da máscara por dois motivos: o custo computacional pode ser considerável, visto que é realizado em todas as fatias do exame, e o crescimento elevado da região mediastínica pode comprometer o contorno pulmonar além do limite aceitável na região mediastínica. Esse crescimento não é preocupante na região lateral, pois o mesmo é limitado pelo fecho convexo do contorno.

4.3 Qualidade de Segmentação

A qualidade da segmentação é avaliada através da comparação entre a segmentação de uma amostra dos exames com seu padrão ouro respectivo. O padrão ouro é gerado a partir da seleção aleatória de 10 exames e segmentação manual sob a supervisão de médicos especialistas. Os resultados da segmentação dos exames são gerados por duas abordagens diferentes: a abordagem baseada em morfologia proposta por este trabalho e o CR3D. A comparação entre as

Tabela 1 – Mapeamento de índices LIDC-IDRI

	Índices LIDC
1	47
2	62
3	74
4	105
5	128
6	229
7	270
8	782
9	865
10	910

duas abordagens é realizada com base nas métricas apresentadas no Capítulo 3. Os resultados de Shen *et al.* (2015) são incluídos na comparação.

Como está descrito na Seção 4.1, o banco LIDC-IDRI possui 1018 exames, 10 dos quais foram selecionados aleatoriamente para serem segmentados manualmente com supervisão de médicos especialistas. Assim, para facilitar a leitura dos dados, os índices que representam cada exame no banco são mapeados sequencialmente de 1 a 10 de acordo com a Tabela 1. Desse modo, os exames originais utilizados podem ser referenciados em trabalhos futuros.

Os primeiros resultados obtidos com base na medida ajuste de forma indicam semelhança entre os objetos da imagem quanto à superposição de áreas. O cálculo dessa métrica é realizado nos exames do padrão ouro em relação com seus correspondentes resultados obtidos na segmentação pelas abordagens. A Figura 19 apresenta os valores obtidos pelas duas abordagens para o ajuste de forma.

Como pode ser visto, os valores observados apontam para um resultado superior, em todos os exames, em relação a abordagem CR3D. A medida do ajuste de forma relaciona a interseção e união das áreas segmentadas e de referência entre si. Embora seja superior ao CR3D, a abordagem proposta, os casos em que o valor de ajuste de forma são mais baixos deve-se a região mediastínica dos pulmões, visto que esta pode extrapolar a região existente na imagem de referência devido ao fechamento morfológico, eliminando as pequenas entradas existentes nessa região do pulmão. Por outro lado, o CR3D não processa as regiões internas dos pulmões, deixando pequenos buracos que podem conter nódulos internos. Isto afeta consideravelmente o seus valores de ajuste de forma.

Para demonstrar as diferenças entre as duas abordagens e o padrão ouro, segmentado manualmente por médicos especialistas, os resultados destes casos são apresentados a seguir. A

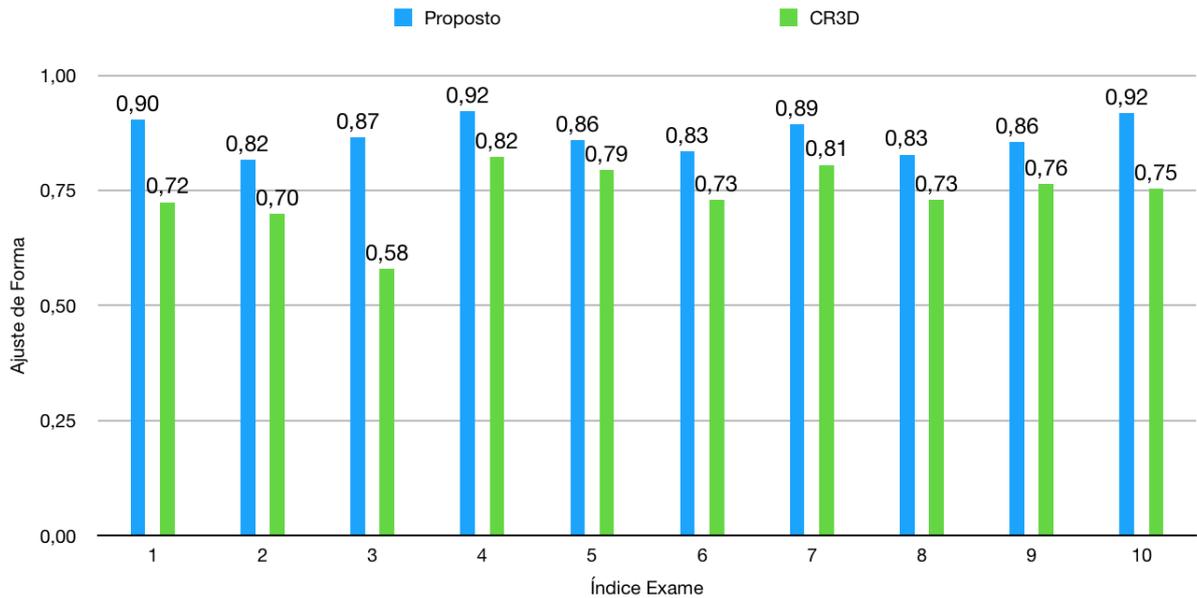


Figura 19 – Comparação da medida ajuste de forma entre a abordagem proposta e CR3D.



Figura 20 – Uma fatia típica de um exame. (a) imagem original; (b) segmentação padrão ouro; (c) segmentação obtida pela abordagem proposta; (d) segmentação obtida pelo CR3D.

Figura 20 apresenta imagens da segmentação das duas abordagens, bem como o padrão ouro. Na Figura 20c é possível ver que uma região externa do pulmão fechada está sendo incluída ao pulmão. É importante notar que essa abordagem permite que nódulos encontrados nessa região possam ser incluídos, sob pena de eventualmente aumentar a taxa de falsos positivos na classificação de *pixels* pulmonares. Já na Figura 20d pode ser visto que as regiões abertas dentro do pulmão são suficientes para afetar severamente o ajuste de forma em relação ao padrão ouro. Ainda nessa Figura, embora o contorno da borda pulmonar possa parecer exato, muitos nódulos internos podem ser perdidos por essa abordagem. Além disso, em pacientes acometidos por doenças que afetam consideravelmente o tecido pulmonar, como fibrose, apresentaram uma diferença estrutural que tornam a abordagem CR3D ainda mais imprecisa na segmentação pulmonar.

Uma forma de avaliar a segmentação é tratar como um problema de classificação binária, de modo que os *voxels* são classificados em pulmão e plano de fundo. Para esse tipo

de problema a medida *Dice Similarity Coefficient (DSC)* é comumente utilizada por representar bem a acurácia de testes binários (POWERS, 2011).

De forma semelhante ao gráfico de ajuste de forma apresentado, a Figura 21 contém os resultados obtidos dos valores *DSC* para as mesmas abordagens mostradas anteriormente.

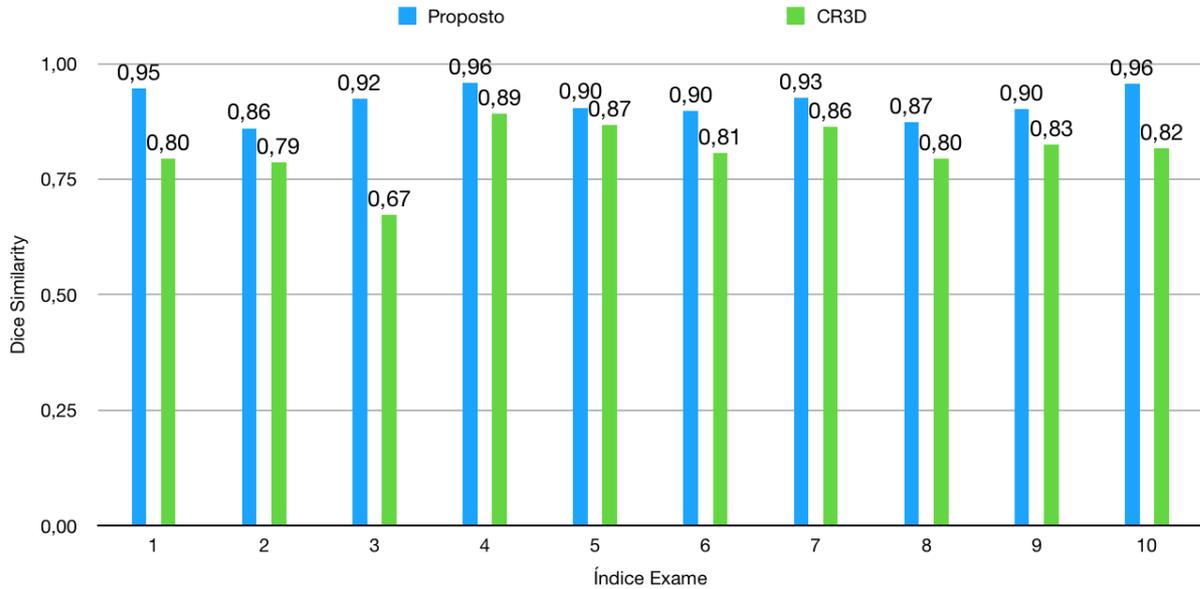


Figura 21 – Comparação da medida *dice similarity* entre a abordagem proposta e CR3D.

A abordagem proposta apresenta valores de DSC superiores em relação ao CR3D para todos os exames. Caso seja analisada uma classificação binária de *pixels* há uma taxa de acerto também superior. Isto mostra como os valores obtidos para os valores de DSC as taxas de verdadeiro positivo são fatores de maior importância, pois os *pixels* classificados como pulmão corretamente estão em maior quantidade na abordagem proposta. Isso é justificado pela natureza da abordagem proposta, na qual os limites da borda do pulmão são extrapolados com facilidade, incluindo assim uma maior quantidade de tecido pulmonar possível e, portanto, regiões não pertencentes ao pulmão, causando uma elevação dos falsos negativos.

Por outro lado a abordagem CR3D apresenta valores de DSC mais baixos, embora ainda maior do que o ajuste de forma, pelo mesmo motivo da medida anterior, pois as lacunas presentes na região interna do pulmão diminuem a taxa de verdadeiros positivos, e consequentemente os valores de DSC.

Outras medidas presentes na avaliação de algoritmos de segmentação pulmonar são as segmentações excessiva (*SE*) e insuficiente (*SI*). Essas medidas têm o objetivo de medir a área de segmentação que extrapola os limites das bordas do objeto a ser segmentado, e a área de segmentação que não atinge os limites das bordas do objeto, portanto, quanto menores seus

valores, melhor (SHEN *et al.*, 2015). As Figuras 22 e 23 apresentam os resultados obtidos para estas duas medidas para cada uma das abordagens.

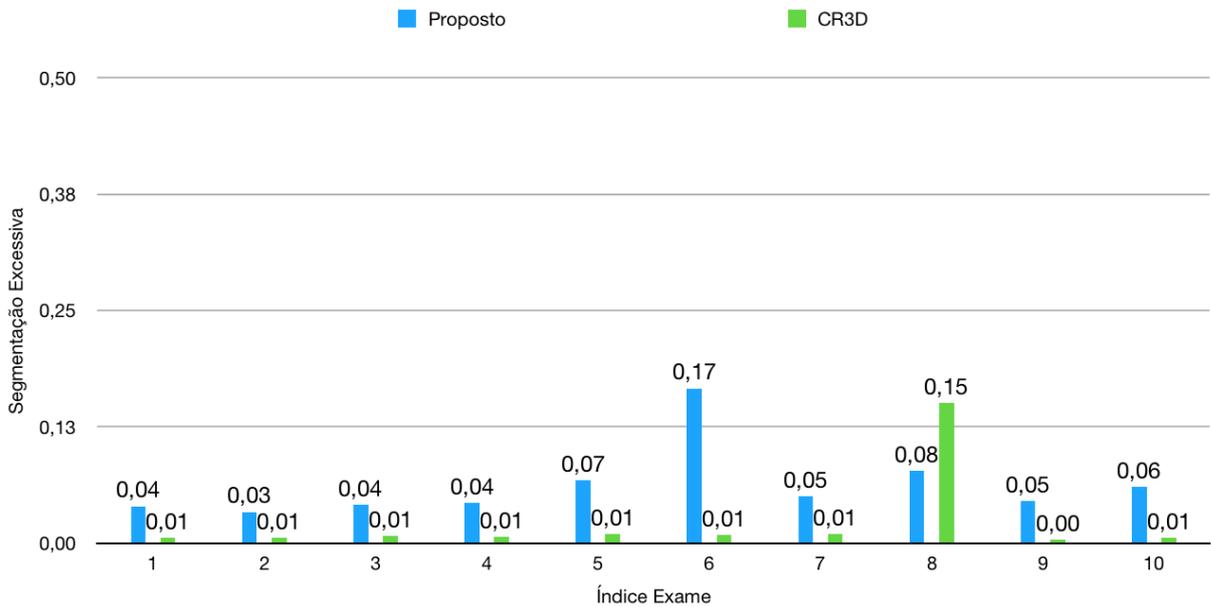


Figura 22 – Comparação da medida de segmentação excessiva entre a abordagem proposta e CR3D.

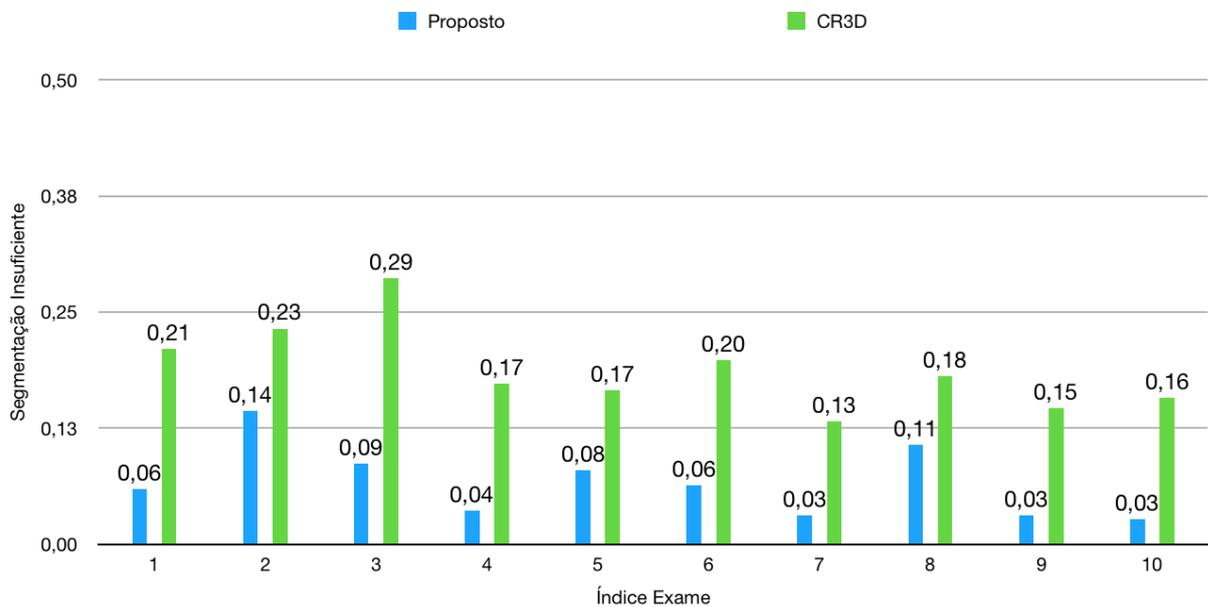


Figura 23 – Comparação da medida de segmentação insuficiente entre a abordagem proposta e CR3D.

A abordagem proposta obtém taxas SE e SI reduzidas. As taxas SE obtidas pelo CR3D são baixas, pois, é improvável que o crescimento supere as bordas dos pulmões, fazendo com que não haja uma grande quantidade de tecido segmentado fora dos pulmões. Todavia, a

Tabela 2 – Comparação dos resultados obtidos com Shen *et al.* (2015)

Abordagem	SE média	SI média	Ajuste de Forma
Proposto	6,3%	6,7%	87,0%
CR3D	2,2%	18,8%	74,0%
(SHEN <i>et al.</i> , 2015)	0,3%	2,4%	97,3%

abordagem proposta está sujeita a obter taxas de SE maiores justamente por realizar o fechamento na região mediastínica.

Por outro lado, as taxas de SI são consideravelmente maiores no CR3D. Isso pode ser justificado pelas regiões internas do pulmão não serem segmentadas, restando uma grande quantidade de conteúdo presente na imagem de referência e ausente na segmentação.

Shen *et al.* (2015) utilizaram código de cadeia para corrigir regiões abertas das bordas pulmonares, onde se encontram os nódulos justa-pleurais. Seus resultados obtidos utilizam as algumas métricas apresentadas nesta dissertação, a saber, ajuste de forma, SE e SI. A Tabela 2 contém os valores obtidos pelas abordagens para estas medidas. Entretanto, são mostradas as médias das métricas calculadas, visto que se tratam de exames distintos. Tais métricas se referem a segmentação pulmonar, todavia o principal objetivo do trabalho de Shen *et al.* (2015) é aumentar reinclusão de nódulos pulmonares.

O resultados apresentados mostram que a qualidade da segmentação proposta possui níveis compatíveis para uma segmentação viável, em comparação com o estado da arte neste quesito.

Tais métricas se referem à segmentação pulmonar, todavia o principal objetivo do trabalho de Shen *et al.* (2015) é aumentar reinclusão de nódulos pulmonares.

4.4 Contagem de Nódulos

Nesta seção são apresentados os resultados obtidos da contagem de nódulos perdidos pelas abordagens: proposta, CR3D e Shen *et al.* (2015).

Conforme descrito, o banco LIDC-IDRI possui 2663 nódulos no universo de exames do banco. Dessa forma, o cálculo da quantidade de nódulos perdidos é realizada com base em um critério de inclusão. Esse critério de inclusão se trata de um limiar do percentual da área do nódulo presente no contorno pulmonar gerado pela segmentações, em que os limiares variam de 50% a 100% da área do nódulo presente, com passo de 10%.

Essa variedade de valores para o limiar de inclusão dos nódulos é importante devido a presença de nódulos extra-pleurais. Esses nódulos são caracterizados por terem uma parte de

sua massa fora dos contornos pulmonares, em que a região extra-pleural não é reincluída nos contornos pulmonares. Dessa forma, é insensato considerar que um nódulo não é corretamente incluído na segmentação pulmonar por apresentar uma parte insignificante de sua massa fora do pulmão. Assim, utilizar uma faixa de valores para o limiar de inclusão tem o objetivo de aumentar a representatividade dos resultados. A Figura 24 ilustra uma amostra de segmentação típica no qual um nódulo extra-pleural excede extensivamente as bordas pulmonares (destaque em vermelho).

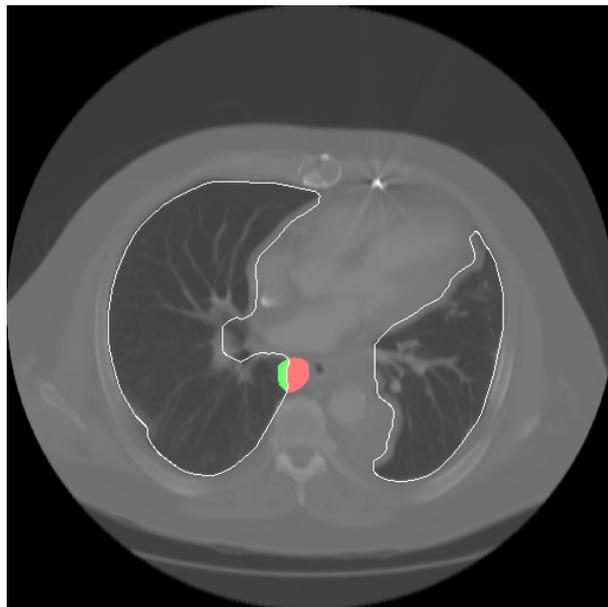


Figura 24 – Exemplo de nódulo extra-pleural.

Diante disto, a Figura 25 contém os resultados obtidos quanto à quantidade de nódulos perdidos pelas abordagens. É possível observar a considerável diferença de desempenho entre as duas abordagens. Quando é possível uma margem de erro maior quanto o percentual do nódulo incluso na pleura, a abordagem proposta perde apenas 1,9% dos nódulos. Todavia, esse valor cresce para 19,2% se considerado a reinclusão do nódulo apenas se estiver completamente dentro da pleura.

Por outro lado, o CR3D apresenta um desempenho menor do que a abordagem proposta quando há a necessidade de reinclusão dos nódulos pulmonares.

Shen *et al.* (2015) apresenta essa medida em seu trabalho. No entanto, os resultados obtidos em seu trabalho para a contagem de nódulos é de 406 nódulos justa-pleurais em um universo de 233 exames. Além disso, em seu trabalho não consta um limiar de reinclusão do nódulo. Considerando-se as diferenças entre as metodologias de obtenção de resultados, a Tabela 3 mostra a comparação entre as abordagens quanto a contagem de nódulos perdidos. Neste caso,

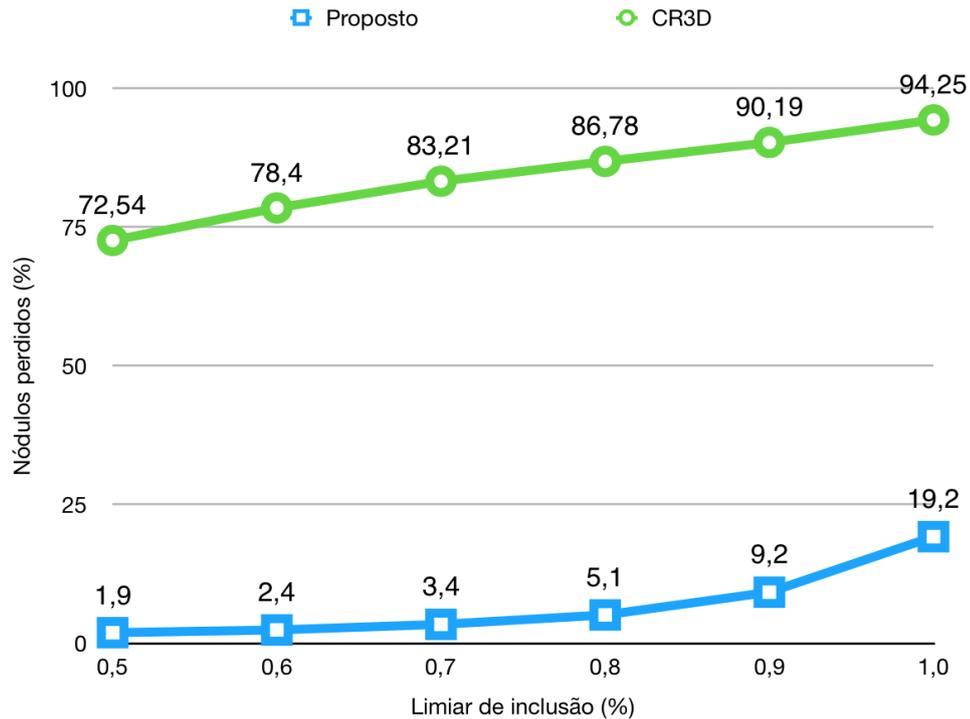


Figura 25 – Percentual de nódulos perdidos com base no limiar de inclusão com passo 0.1.

Tabela 3 – Comparação de contagem de nódulos perdidos.

Abordagem	Nódulos perdidos
Proposto	1,9%
CR3D	72,54%
(SHEN <i>et al.</i> , 2015)	7,4%

a abordagem proposta se comporta de forma superior às demais.

4.5 Tempo de Processamento

Esta seção apresenta os resultados obtidos quanto ao tempo de processamento de cada abordagem. O tempo de processamento necessário para realizar a segmentação é alvo importante desta dissertação, visto que se trata de uma variável relevante quanto à viabilidade clínica da aplicação. Dessa forma, o tempo de processamento é calculado para cada um dos 1018 exames do banco, considerando-se a quantidade de imagens de cada exame, bem como a configuração do hardware do sistema utilizado.

O sistema foi desenvolvido e executado em um processador Intel Core i7-2600K de 3.40 Ghz, com 8 GB de memória RAM. A linguagem predominante foi Python e suas bibliotecas externas de processamento de imagens e computação numérica.

Outro fator importante que deve ser considerado no tempo de processamento diz respeito a uma das contribuições desta dissertação, o algoritmo utilizado para o preenchimento

Tabela 4 – Comparação tempo de processamento preenchimento de buracos.

Abordagem	Tempo médio (s)
Proposto	0,25
Morfológico (3x3x3)	4,0
Morfológico (5x5x5x)	10,0
Morfológico (7x7x7)	25,0
Morfológico (9x9x9)	52,0
Morfológico (11x11x11)	93,0

de buracos, em comparação com o método morfológico. O algoritmo desenvolvido apresentou ganhos que podem chegar a centenas de vezes mais rápidos do que a tradicional morfologia matemática, dependendo das dimensões do elemento estruturante. A Tabela 4 ilustra como varia o tempo de processamento do preenchimento de buracos usando morfologia matemática em função das dimensões do elemento estruturante. Essas medições foram repetidas 10 vezes para cada caso, calculando a média do tempo observado.

Esse resultado é apresentado para diferentes dimensões, pois as dimensões do elemento estruturante devem variar de acordo com o tamanho dos buracos que se deseja preencher. Dessa forma, o algoritmo proposto apresenta uma clara vantagem, não dependendo de parâmetros externos para preenchimento de buracos de qualquer tamanho, além de ser consideravelmente mais rápido do que as alternativas morfológicas.

Tendo em vista que há um ganho considerável de tempo para a segmentação proposta durante a etapa de preenchimento de buracos, a seguir são apresentados os tempos de processamento observados para cada um dos exames do banco. Para melhor visualização e representatividade dos dados, são calculadas as médias de tempo de processamento a cada 100 exames, dividindo o banco de imagens em 10 partes. A Figura 26 ilustra o tempo de processamento para segmentação pelas duas abordagens, ao longo do banco de imagens.

Os resultados apontam uma diferença considerável entre as duas abordagens. A abordagem proposta realiza a segmentação completa aproximadamente 10 vezes mais rápido do que o CR3D. Além disso, possui tempo médio total de 19,4 segundos por exame, um tempo que pode ser considerado viável clinicamente. A Figura 27 contém a relação do tempo de processamento com a média da quantidade de imagens a cada 100 exames.

Esse gráfico mostra que o tempo de processamento da abordagem proposta cresce com a quantidade de imagens do exame processado. Por outro lado, o CR3D apresenta um comportamento imprevisível, isso porque há uma variação do tamanho dos pulmões em diferentes pacientes, tornando o objeto a ser segmentado maior. O CR3D é um algoritmo que tem seu custo

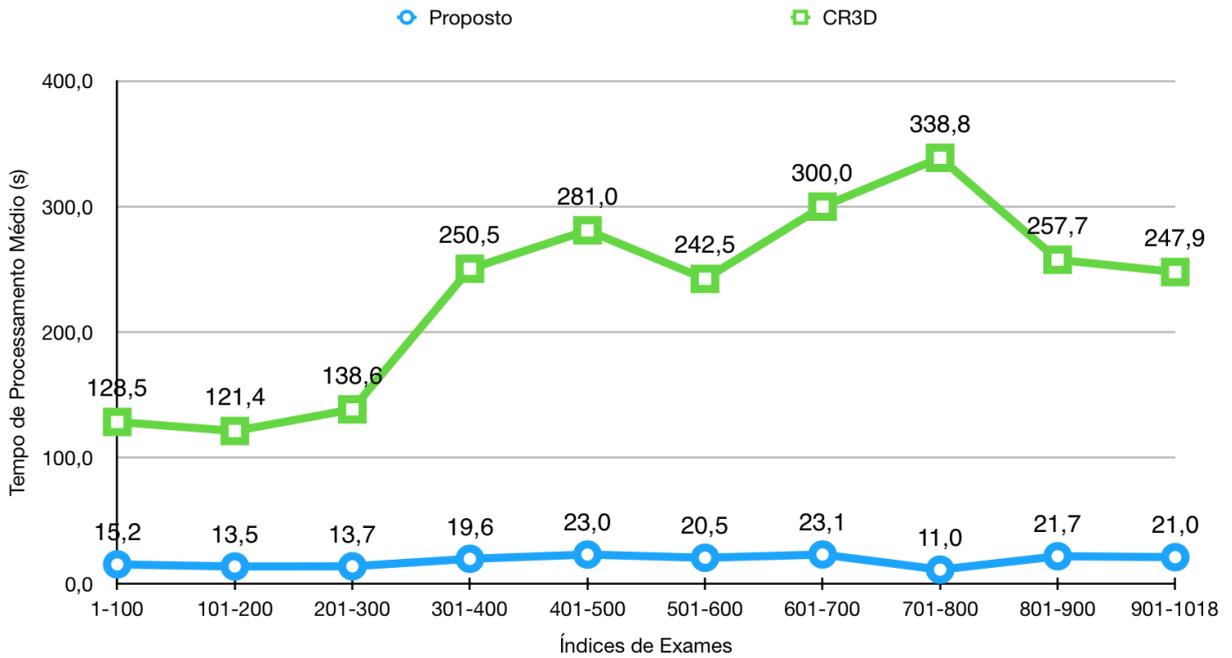


Figura 26 – Tempo de processamento médio a cada 100 exames.

computacional relacionado com o tamanho do objeto a ser segmentado devido a quantidade de pontos de verificação. Assim, exames com a mesma quantidade de imagens de pacientes diferentes podem afetar o tempo de processamento do CR3D.

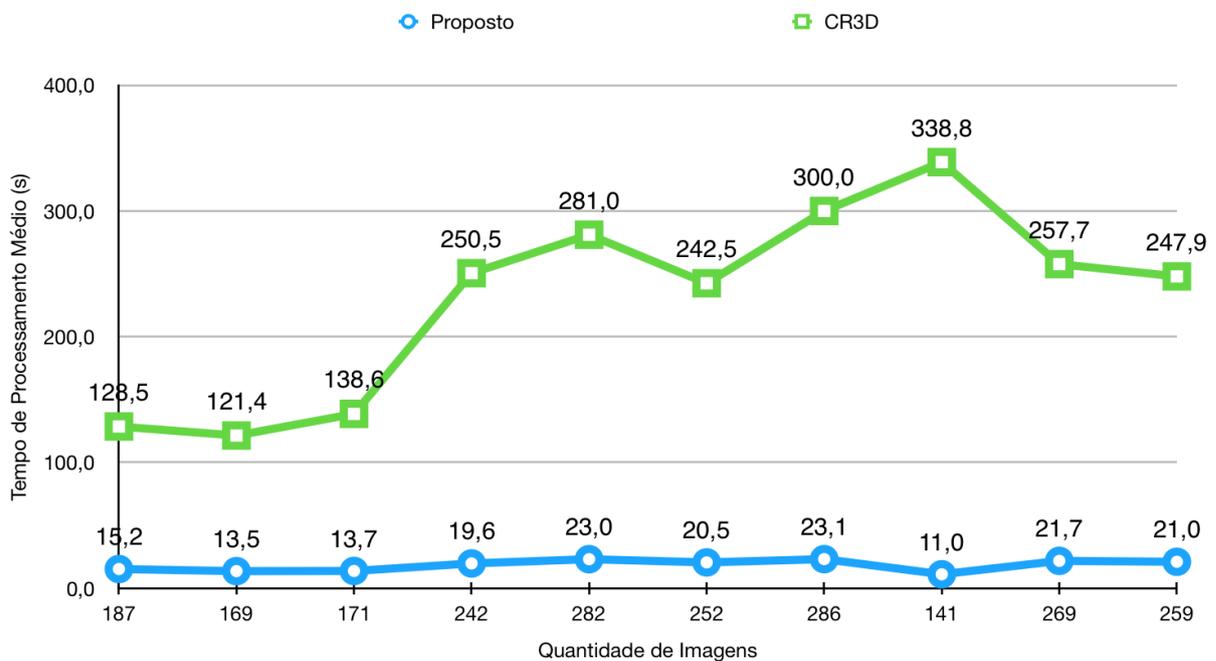


Figura 27 – Tempo de processamento em função da quantidade de imagens por exame.

Shen *et al.* (2015), em seu trabalho, relatam que o tempo médio de processamento de seu método é de 0,53s por fatia de TC. Além disso, sua abordagem é implementada no MATLAB,

Tabela 5 – Comparação do tempo de processamento obtidos com Shen *et al.* (2015)

Abordagem	Tempo médio (s)	Ambiente
Proposto	19,4	Python
CR3D	223,0	Python
(SHEN <i>et al.</i> , 2015)	144,0	MATLAB

em um sistema de configurações semelhantes ao desta dissertação, portanto, os valores de seu trabalho serão estimados para efeito de comparação com esta dissertação. Considerando-se que a linguagem de implementação do sistema tem um papel considerável no tempo de processamento do sistema e usando a média de 240 imagens por exame presentes no banco LIDC-IDRI, a Tabela 5 mostra a comparação do tempo médio de processamento estimado das três abordagens.

Desta forma, é possível atestar que a segmentação proposta nesta dissertação possui um desempenho e eficiência aceitáveis. Além disso, a segmentação apresenta qualidade, preservando toda a estrutura interna dos pulmões, incluindo nódulos de todos os tipos, em tempo clinicamente viável.

5 CONCLUSÕES, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Nesta dissertação é proposta uma nova abordagem para segmentação pulmonar, buscando atingir níveis de viabilidade clínica para qualidade de segmentação, reinclusão de nódulos e tempo de processamento.

Considerando os resultados obtidos, pode-se concluir que é possível uma abordagem de segmentação pulmonar com resultados compatíveis com uma situação favorável de qualidade da segmentação, preservação de integridade das estruturas internas, bem como nódulos pulmonares de todos os tipos, em tempo de processamento viável para uma realidade clínica.

Para cumprir esses objetivos, esta abordagem propõe um caminho pragmático e eficaz, através do uso de filtragem de ruídos e métodos morfológicos empiricamente montados. Sua validade é atestada pela comparação com um algoritmo de segmentação no estado da arte, bem como métodos presentes em outros trabalhos através de métricas extensivamente usadas na literatura.

A qualidade da segmentação é verificada comparando o resultado com o padrão ouro através de métricas comumente utilizadas para esse propósito. O ajuste de forma médio resultante foi de 87,5%, apresentando um resultado superior ao CR3D, que obtém 81,2% da mesma medida. É possível concluir que esse resultado foi consideravelmente afetado pelo fechamento morfológico, que une a região mediastínica dos pulmões, acrescentando conteúdo externo à segmentação. Por outro lado, as lacunas não tratadas pelo CR3D na região interna do pulmão, bem como os nódulos justa-pleurais não segmentados justificam sua baixa taxa de ajuste de forma. Além disso, esse resultado foi comparado com Shen *et al.* (2015), que por sua vez apresentam resultados superiores quanto a qualidade da segmentação, obtendo 97,3%.

Diante dos resultados obtidos pela abordagem proposta, destaca-se a superioridade em relação aos valores encontradas na literatura. Ressalta-se o valor de apenas 1,9% de nódulos perdidos em um total 2663 nódulos em 1018 exames. Já o CR3D mostrou um desempenho totalmente insatisfatório nesse quesito, perdendo 72,52% dos nódulos totais, enquanto o método proposto por Shen *et al.* (2015) perdeu 7,4%.

Finalmente, o tempo de processamento é um parâmetro relevante na determinação da viabilidade clínica da abordagem, tendo como uma das contribuições desta dissertação a implementação de uma nova abordagem alternativa para o preenchimento de buracos morfológico, que é responsável por um considerável ganho no custo computacional da abordagem proposta.

Para avaliar o tempo de processamento, foram computados o tempo total de segmen-

tação para cada um dos exames no banco de imagens. Além disso, foi mostrado que este trabalho propõe uma abordagem que tem relação linear com a quantidade de imagens em cada exame. Por outro lado, o CR3D tem uma variação diferente em seu custo computacional devido ao tamanho do pulmão real ser traduzido em um objeto maior a ser segmentando, que por sua vez resulta em uma maior quantidade de comparações realizadas pelo algoritmo, tornando o mais lento.

A abordagem proposta apresentou resultados aproximadamente 10 vezes mais rápidos que o CR3D. O tempo de processamento médio observado foi de 19,4 segundos. Esse valor pode ser argumentado como satisfatório em sua viabilidade clínica.

O trabalho de Shen *et al.* (2015) relatou demorar 0,54 segundos por fatia, portanto, considerando 240 imagens por exame, observa-se o tempo médio de 144 segundos por exame. No entanto, o ambiente de desenvolvimento utilizado por ele foi o MATLAB, enquanto a abordagem proposta foi implementada em Python e suas bibliotecas de processamento de imagens e computação numérica.

A abordagem utilizada para alcançar os resultados de reinclusão de nódulos configura a principal contribuição desta dissertação. Além disso, o algoritmo de preenchimento de buracos implementado para redução de custo computacional, o uso dos bancos de imagens mais completo quanto a análise de nódulos pulmonares, bem como a implementação de *frameworks* para processamento e análise de imagens de TC configuram outras contribuições desta dissertação.

Os resultados obtidos nos testes comprovam os objetivos propostos neste trabalho foram cumpridos. A abordagem proposta apresenta uma segmentação de qualidade, com redução máxima de perda de nódulos, em tempo satisfatório para viabilização de aplicações clínicas.

A partir desta dissertação, outros trabalhos podem ser realizados para investigar: uma análise específica do efeito de variadas doenças pulmonares na segmentação, redução de custo computacional através de análise de complexidade na implementação dos métodos. Além disso, trabalhos futuros podem focar, principalmente, no aumento de qualidade de segmentação através da aplicação de testes mais extensos dos parâmetros morfológicos utilizados, bem como métodos de correção de contorno de forma complementar.

REFERÊNCIAS

- ARMATO, S. G.; MCLENNAN, G.; BIDAUT, L.; MCNITT-GRAY, M. F.; MEYER, C. R.; REEVES, A. P.; ZHAO, B.; ABERLE, D. R.; HENSCHKE, C. I.; HOFFMAN, E. A. *et al.* The lung image database consortium (lidc) and image database resource initiative (idri): a completed reference database of lung nodules on ct scans. **Medical physics**, Wiley Online Library, v. 38, n. 2, p. 915–931, 2011.
- BANON, G. J. F.; BARRERA, J. **Bases da Morfologia Matemática para a análise de imagens binárias**. [S.l.]: UFPE-DI, 1994.
- BARBOSA, D.; HEYDE, B.; CIKES, M.; DIETENBECK, T.; CLAUS, P.; FRIBOULET, D.; BERNARD, O.; D’HOOGE, J. Real-time 3d interactive segmentation of echocardiographic data through user-based deformation of b-spline explicit active surfaces. **Computerized medical imaging and graphics**, Elsevier, v. 38, n. 1, p. 57–67, 2014.
- BI, L.; KIM, J.; WEN, L.; FENG, D. D. Automatic descending aorta segmentation in whole-body pet-ct studies for percost-based thresholding. In: IEEE. **Digital Image Computing Techniques and Applications (DICTA), 2012 International Conference on**. [S.l.], 2012. p. 1–6.
- BIRKFELLNER, W. **Applied medical image processing: a basic course**. [S.l.]: CRC Press, 2015.
- BOING, A. F.; ROSSI, T. F. Tendência temporal e distribuição espacial da mortalidade por câncer de pulmão no brasil entre 1979 e 2004: magnitude, padrões regionais e diferenças entre sexos. **Jornal Brasileiro de Pneumologia**, *Jornal Brasileiro de Pneumologia*, v. 33, n. 5, p. 544–551, 2007.
- BONTRAGER, K. L. **Tratado de técnica radiográfica e base anatômica**. [S.l.]: Guanabara Koogan, 2008.
- CAVALCANTE, T. d. S. **Método de superfícies ativas usando local binary patterns (LBP) aplicado na segmentação de lobos pulmonares em imagens de tomografia computadorizada do tórax**. Tese (Doutorado), 2016.
- CAVALCANTI NETO, E. **SFPT Neural: Nova Técnica de Segmentação de Fissuras Pulmonares Baseada em Texturas em Imagens de Tomografia Computadorizadas do Tórax**. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2014.
- CHO, Z.; JONES, J.; SINGH, M. **Fundamentals of medical imaging**. [S.l.]: Wiley, 1993.
- CHOI, W.-J.; CHOI, T.-S. Genetic programming-based feature transform and classification for the automatic detection of pulmonary nodules on computed tomography images. **Information Sciences**, Elsevier, v. 212, p. 57–78, 2012.
- CHOI, W.-J.; CHOI, T.-S. Automated pulmonary nodule detection based on three-dimensional shape-based feature descriptor. **Computer Methods and Programs in Biomedicine**, v. 113, n. 1, p. 37 – 54, 2014. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260713002940>>.
- DAI, S.; LU, K.; DONG, J.; ZHANG, Y.; CHEN, Y. A novel approach of lung segmentation on chest ct images using graph cuts. **Neurocomputing**, Elsevier, v. 168, p. 799–807, 2015.

DAS, M.; MÜHLENBRUCH, G.; MAHNKEN, A. H.; FLOHR, T. G.; GÜNDEL, L.; STANZEL, S.; KRAUS, T.; GÜNTHER, R. W.; WILDBERGER, J. E. Small pulmonary nodules: Effect of two computer-aided detection systems on radiologist performance 1. **Radiology**, Radiological Society of North America, v. 241, n. 2, p. 564–571, 2006.

DATASSUS. **Mortalidade de Neoplasia maligna dos brônquios e pulmões**. 2015. Disponível em: <<http://tabnet.datasus.gov.br/cgi/tabcgi.exe?sim/cnv/obt10uf.def>>.

DELIBASIS, K. K.; ASVESTAS, P. A.; KECHRINIOTIS, A. I.; MATSOPOULOS, G. K. An implicit evolution scheme for active contours and surfaces based on iir filtering. **Computers in biology and medicine**, Elsevier, v. 48, p. 42–54, 2014.

DEMNER-FUSHMAN, D.; ANTANI, S.; KALPATHY-CRAMER, J.; MÜLLER, H. A decade of community-wide efforts in advancing medical image understanding and retrieval. **Computerized Medical Imaging and Graphics**, Elsevier, v. 39, p. 1–2, 2015.

DOUGHERTY, G. **Digital image processing for medical applications**. [S.l.]: Cambridge University Press, 2009.

ELLIS, S. M.; FLOWER, C. **The WHO manual of diagnostic imaging: radiographic anatomy and interpretation of the chest and the pulmonary system**. [S.l.]: World Health Organization, 2006.

GEVENOIS, P.-A.; YERNAULT, J. C. Can computed tomography quantify pulmonary emphysema? **European Respiratory Journal**, Eur Respiratory Soc, v. 8, n. 5, p. 843–848, 1995.

GLASBEY, C. A. An analysis of histogram-based thresholding algorithms. **CVGIP: Graphical models and image processing**, Elsevier, v. 55, n. 6, p. 532–537, 1993.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. [S.l.]: Upper Saddle River, NJ: Prentice Hall, 2012.

GRÜNBAUM, B. **Convex polytopes, volume 221 of Graduate Texts in Mathematics**. [S.l.]: Springer-Verlag, New York, 2003.

HE, L.; PENG, Z.; EVERDING, B.; WANG, X.; HAN, C. Y.; WEISS, K. L.; WEE, W. G. A comparative study of deformable contour methods on medical image segmentation. **Image and Vision Computing**, Elsevier, v. 26, n. 2, p. 141–163, 2008.

HEDLUND, L.; ANDERSON, R. F.; GOULDING, P.; BECK, J.; EFFMANN, E. L.; PUTMAN, C. Two methods for isolating the lung area of a ct scan for density information. **Radiology**, v. 144, n. 2, p. 353–357, 1982.

HEIMANN, T.; MEINZER, H.-P. Statistical shape models for 3d medical image segmentation: a review. **Medical image analysis**, Elsevier, v. 13, n. 4, p. 543–563, 2009.

HOLLER, M.; DIAZ, A.; GUIZAR-SICAIROS, M.; KARVINEN, P.; FÄRM, E.; HÄRKÖNEN, E.; RITALA, M.; MENZEL, A.; RAABE, J.; BUNK, O. X-ray ptychographic computed tomography at 16 nm isotropic 3d resolution. **Scientific reports**, Nature Publishing Group, v. 4, p. 3857, 2014.

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

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

IASLC, I. A. for the Study of L. C. **LUNG CANCER FACTS AND STATISTICS**. 2017. IASLC 18th World Conference on Lung Cancer and Lung Cancer Facts and Statistics. Disponível em: <<http://wclc2017.iaslc.org/wp-content/uploads/2017/09/2017-WCLC-Fact-Sheet-Lung-Cancer-Final.pdf>>.

INCA. INSTITUTO NACIONAL DO CÂNCER. Ministério da Saúde, 2016.

JACOBS, C.; SÁNCHEZ, C. I.; SAUR, S. C.; TWELLMANN, T.; JONG, P. A. de; GINNEKEN, B. van. Computer-aided detection of ground glass nodules in thoracic ct images using shape, intensity and context features. In: SPRINGER. **International Conference on Medical Image Computing and Computer-Assisted Intervention**. [S.l.], 2011. p. 207–214.

JAIN, A. K. Fundamentals of digital image processing. Prentic-Hall International, 1989.

KALENDER, W. A. X-ray computed tomography. **Physics in Medicine and Biology**, v. 51, n. 13, p. R29, 2006. Disponível em: <<http://stacks.iop.org/0031-9155/51/i=13/a=R03>>.

KIM, D.-Y.; KIM, J.-H.; NOH, S.-M.; PARK, J.-W. Pulmonary nodule detection using chest ct images. **Acta Radiologica**, Wiley Online Library, v. 44, n. 3, p. 252–257, 2003.

MARCHAND-MAILLET, S.; SHARAIHA, Y. M. **Binary digital image processing: a discrete approach**. [S.l.]: Academic Press, 1999.

MARTEN, K.; ENGELKE, C.; SEYFARTH, T.; GRILLHÖSL, A.; OBENAUER, S.; RUMMENY, E. Computer-aided detection of pulmonary nodules: influence of nodule characteristics on detection performance. **Clinical radiology**, Elsevier, v. 60, n. 2, p. 196–206, 2005.

MCANDREW, A. An introduction to digital image processing with matlab notes for scm2511 image processing. **School of Computer Science and Mathematics, Victoria University of Technology**, p. 1–264, 2004.

NARASIMHAN, R. S.; VENGADARAJAN, A.; RAMAKRISHNAN, K. R. Design of connected component analysis based clustering of cfar image in pulse doppler radars. In: **2017 IEEE Aerospace Conference**. [S.l.: s.n.], 2017. p. 1–6.

OMS, W. H. O. **Fact Sheet**. World Health Organization, 2018. Disponível em: <<http://www.who.int/mediacentre/factsheets/fs297/en/>>.

OPENCV. **OpenCV API Reference**. [S.l.], 2014. Disponível em: <<https://tinyurl.com/y8rddel3>>. Acesso em: 16 Mai 2018.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on systems, man, and cybernetics**, IEEE, v. 9, n. 1, p. 62–66, 1979.

POWERS, D. M. Evaluation: from precision, recall and f-measure to roc, informedness, markedness and correlation. Bioinfo Publications, 2011.

PRATT, W. Digital image processing. 1991.

PU, J.; ZHENG, B.; LEADER, J. K.; WANG, X.-H.; GUR, D. An automated ct based lung nodule detection scheme using geometric analysis of signed distance field. **Medical Physics**, American Association of Physicists in Medicine, v. 35, n. 8, p. 3453–3461, 2008. ISSN 2473-4209. Disponível em: <<http://dx.doi.org/10.1118/1.2948349>>.

RETICO, A.; DELOGU, P.; FANTACCI, M. E.; GORI, I.; MARTINEZ, A. P. Lung nodule detection in low-dose and thin-slice computed tomography. **Computers in biology and medicine**, Elsevier, v. 38, n. 4, p. 525–534, 2008.

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

RUBIN, G. D.; LYO, J. K.; PAIK, D. S.; SHERBONDY, A. J.; CHOW, L. C.; LEUNG, A. N.; MINDELZUN, R.; SCHRAEDLEY-DESMOND, P. K.; ZINCK, S. E.; NAIDICH, D. P.; NAPEL, S. Pulmonary nodules on multi-detector row ct scans: Performance comparison of radiologists and computer-aided detection. **Radiology**, v. 234, n. 1, p. 274–283, 2005. PMID: 15537839. Disponível em: <<http://dx.doi.org/10.1148/radiol.2341040589>>.

SHAPIRO, L.; STOCKMAN, G. C. Computer vision. 2001. ed: **Prentice Hall**, 2001.

SHEN, S.; BUI, A. A.; CONG, J.; HSU, W. An automated lung segmentation approach using bidirectional chain codes to improve nodule detection accuracy. **Computers in biology and medicine**, Elsevier, v. 57, p. 139–149, 2015.

SIEMENS. **Computed Tomography: Its History and Technology**. 2004. Disponível em: <<https://www.healthcare.siemens.com>>.

SLUIMER, I.; PROKOP, M.; GINNEKEN, B. V. Toward automated segmentation of the pathological lung in ct. **IEEE transactions on medical imaging**, IEEE, v. 24, n. 8, p. 1025–1038, 2005.

STRZELECKI, M.; SZCZYPINSKI, P.; MATERKA, A.; KLEPACZKO, A. A software tool for automatic classification and segmentation of 2d/3d medical images. **Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment**, Elsevier, v. 702, p. 137–140, 2013.

SUN, X.; ZHANG, H.; DUAN, H. 3d computerized segmentation of lung volume with computed tomography. **Academic radiology**, Elsevier, v. 13, n. 6, p. 670–677, 2006.

TORRE, L. A.; BRAY, F.; SIEGEL, R. L.; FERLAY, J.; LORTET-TIEULENT, J.; JEMAL, A. Global cancer statistics, 2012. **CA: a cancer journal for clinicians**, Wiley Online Library, v. 65, n. 2, p. 87–108, 2015.

VALENTE, I. R. S.; CORTEZ, P. C.; CAVALCANTE, T. da S.; ANSELMO, F. J. M.; NETO, E. C.; RIBEIRO, A. B. N.; FILHO, V. E. R. da S.; HOLANDA, M. A. Lisa - lung image system analysis. VII SIIM - Simpósio de Instrumentação e Imagens Médicas, 2016.

YE, X.; LIN, X.; DEHMESHKI, J.; SLABAUGH, G.; BEDDOE, G. Shape-based computer-aided detection of lung nodules in thoracic ct images. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 56, n. 7, p. 1810–1820, 2009.