

UNIVERSIDADE ESTADUAL DE SANTA CRUZ

JORGE PAULO SOARES ROCHA FILHO

**ANÁLISE DE TÉCNICAS COMPUTACIONAIS PARA SEGMENTAÇÃO DE
NÓDULOS PULMONARES**

ILHÉUS – BAHIA

2017

JORGE PAULO SOARES ROCHA FILHO

**ANÁLISE DE TÉCNICAS COMPUTACIONAIS PARA SEGMENTAÇÃO DE
NÓDULOS PULMONARES**

Dissertação apresentada como exigência parcial para obtenção do título de Mestre em Modelagem Computacional em Ciência e Tecnologia da Universidade Estadual de Santa Cruz.

Orientador: Prof. Dr. Paulo Eduardo Ambrósio

ILHÉUS – BAHIA

2017

R672

Rocha Filho, Jorge Paulo Soares.

Análise de técnicas computacionais para segmentação de nódulos pulmonares / Jorge Paulo Soares Rocha Filho – Ilhéus, BA: UESC, 2017.
xiii, 56f. : il.

Orientador: Paulo Eduardo Ambrósio
Dissertação (Mestrado) – Universidade Estadual de Santa Cruz. Programa de Pós-Graduação em Modelagem computacional em Ciência e Tecnologia
Inclui referências.

1. Diagnóstico por imagem. 2. Pulmões – Câncer. 3. Tomografia. 4. Processamento de imagens – técnicas digitais. 5. Segmentação de imagens I. Título.

CDD 616.0754

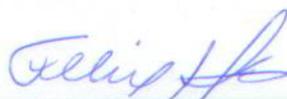
JORGE PAULO SOARES ROCHA FILHO

ANÁLISE DE TÉCNICAS COMPUTACIONAIS PARA SEGMENTAÇÃO DE
NÓDULOS PULMONARES

Ilhéus, 21/08/2017



Prof. Dr. Paulo Eduardo Ambrósio
UESC
(Orientador)



Prof. Dr. Felix Mas Milian
UESC
(Professor)



Profa. Dra. Ana Cláudia Martinez
UFU
(Professora)

Aos meus pais por todo o apoio e educação que sempre me deram e pelo incentivo que me dão até hoje para superar os obstáculos

AGRADECIMENTOS

Aos meus pais Jorge e Sonia, pelo amor e pelo apoio durante mais essa etapa da minha formação acadêmica.

Aos meus amigos pelas palavras de apoio nos momentos mais difíceis de toda essa jornada.

Aos meus irmãos Bernardo e Bruno, que sempre se preocupam com o meu sucesso e procuram me ajudar, quando necessário.

À minha sobrinha Thayla Rocha, por me trazer alegrias e calma quando na minha cabeça só existia preocupação e frustrações.

Ao meu orientador Paulo Ambrósio, pela oportunidade da realização deste trabalho, pela orientação, paciência e pelo incentivo.

Ao PPGMC pela oportunidade deste curso de mestrado e pela infraestrutura disponibilizada para a realização deste trabalho.

Ao NBCGIB pelos recursos e infraestrutura disponibilizados para a realização deste trabalho.

RESUMO

O índice de ocorrência de câncer no Brasil vem aumentando gradativamente a cada ano e a taxa de mortalidade pelo câncer de pulmão é alarmante. Sua detecção precoce está diretamente relacionada com a efetividade do tratamento e às chances de cura. São importantes, então, estudos na área de automatização do processo (CAD – Computer-aided diagnosis), para que a detecção e o diagnóstico da doença sejam feitos com mais agilidade, aumentando, portanto, as chances de cura do paciente. Este trabalho propõe a análise de técnicas computacionais utilizadas na segmentação de nódulos em tomografias computadorizadas a fim de determinar a escolha das técnicas mais apropriadas para o uso em pesquisas em CAD e auxiliar a segmentação de nódulos por especialistas, acrescentando a possibilidade do auxílio do computador. Foram avaliadas as técnicas de Contorno Ativo Geodésico, Modelo de Contorno Ativo de Chan-Vese e duas abordagens de Crescimento de Regiões. Estas foram escolhidas de maneira empírica, pois já estão implementadas e disponíveis junto com o pacote Matlab. Este trabalho apresenta quais técnicas obtiveram melhores resultados em relação às características dos nódulos pulmonares, destacadas por especialistas e presentes no banco de imagens utilizado. Foram relevantes para os resultados a sutileza dos nódulos, que tem um valor entre 1 e 5 e refere-se à dificuldade de detecção destes, onde 1 significa difícil detecção e 5 significa fácil detecção, e a malignidade dos nódulos, também com valor entre 1 e 5 e refere-se à probabilidade de o nódulo ser maligno considerando um paciente fumante do sexo masculino com 60 anos de idade. A técnica de Chan-Vese destacou-se por apresentar resultados próximos à segmentação manual em termos de perímetro e foi a técnica que menos apresentou resultados completamente disjuntos das regiões dos nódulos. Também foi a técnica mais efetiva em nódulos com valor de sutileza 3 em todas as métricas de comparação. Em todos os casos com nódulos de sutileza 5, a técnica de contorno ativo geodésico apresentou diferença absoluta de perímetro de menos de 40%. Todas as técnicas apresentaram, com poucas exceções, diferenças absolutas de mais de 40% nas métricas comparativas em imagens com nódulos de malignidade 3.

Palavras-chave: Diagnóstico auxiliado por computador. Câncer de pulmão. Tomografias computadorizadas. Segmentação de imagens.

ABSTRACT

The occurrence rate of cancer in Brasil has been gradually growing year after year and lung cancer's mortality rate is very concerning. Its early detection is directly related to the treatment's effectiveness and the chance of cure. Therefore, studies in the field of Computer Aided Diagnosis (CAD) are important to accelerate the cancer detection and its diagnosis in order to increase the patient's chances of cure. This work comes up with an analysis of different techniques used to segment nodules in CT-scans in order to make determine the choice of the most suitable method to CAD research and to aid nodule segmentation made by physicians adding the possibility of computational aid. The techniques analysed were Geodesic Active Contour, Chan-Vese Model and two approaches on Region Growth. These techniques were chosen empirically because they are already available on Matlab. This work shows which techniques were more successful with nodules with different characteristics. The characteristics that were important for the results were the subtlety of the nodules, that has a value between 1 and 5 and tells the how difficult it is to detect them, where 1 means that the detection is hard and 5 means that the detection is easy, and the malignancy of the nodules, also described by a value between 1 and 5 and tells the probability of the nodule being malignant considering a 60 year old male smoker. The Chan-Vese model stood out presenting results that were close to the values of the manual segmentation in terms of perimeter and it was the technique that showed the least number of results that were completely disjointed from the nodule regions. The Chan-Vese model was also the most effective technique in nodules with subtlety value 3 in all of the comparative metrics. In all of the cases with nodules with subtlety 5, the geodesic active contour presented absolute difference of perimeter of less than 40%. All of the studied techniques presented, with few exceptions, absolute differences of more than 40% in the comparative metrics regarding images with nodules with malignancy 3.

Keywords: Computer-aided diagnosis. Lung cancer. Computed tomography scans. Image segmentation.

LISTA DE FIGURAS

Figura 1 – CT revela excelentes detalhes anatômicos, como pode ser visto nas imagens (A) sagital, (B) coronal e (C) axial de uma CT de uma pelve abdominal. Em (D), uma angiografia. (E) demonstra um mapa com cores correspondente ao volume de sangue no paciente em avaliação por suspeita de acidente vascular cerebral. F. Processamento de imagens pode podruzir representações tridimensionais pseudocoloridas da anatomia da tomografia computadorizada.	21
Figura 2 – Passos fundamentais em processamento de imagens digitais	24
Figura 3 – Curva inicial para modelo de Chan-Vese	27
Figura 4 – Exemplo de imagem de tomografia computadorizada	32
Figura 5 – Nódulo presente na Figura 4 segmentado manualmente por especialistas	33
Figura 6 - Imagem de aplicação da técnica de contorno ativo geodésico. À esquerda, imagem com máscara escolhida, indicada pela seta, e à direita, borda da segmentação, indicada pela seta.	34
Figura 7 – Imagem com a máscara escolhida manualmente para a aplicação da técnica de Chan-Vese de contorno ativo em tomografia computadorizada	35
Figura 8 – Aplicação da técnica RGV com valor de tolerância 20. Em vermelho, o objeto detectado pela técnica de crescimento de regiões. Em azul, o nódulo que deveria ser identificado.	36
Figura 9 – Aplicação de técnica de crescimento de regiões. À esquerda, valor de tolerância estabelecido em 40. À direita, valor de tolerância padrão (32).	37
Figura 10 – Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por contorno ativo geodésico	37
Figura 11 - Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por modelo sem bordas de Chan-Vese .	38
Figura 12 - Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por RGF	38
Figura 13 - Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por RGV	39
Figura 14 – Imagem da segmentação manual feita por especialistas (à esquerda) colocada ao lado de resultado de segmentação por contorno ativo baseado em borda (à direita) respeitando as proporções dos tamanhos originais	40

Figura 15 – Segmentação manual de nódulo em tomografia computadorizada em níveis de cinza (à esquerda) ao lado de resultado de sua binarização (à direita)	41
Figura 16 – Exemplo de segmentação com modelo sem bordas de Chan-Vese e imagem com dimensão reduzida e nódulo centralizado pelo centróide	42
Figura 17 – Centralização do nódulo em imagem de segmentação manual	43
Figura 18 – Preenchimento de vazios em resultado de segmentação por crescimento de regiões.....	44
Figura 19 – Imagem da fatia de interesse de tomografia computadorizada de Rótulo 0014 com nódulo indicado pela seta	45
Figura 20 – Segmentação manual lado a lado com os resultados das técnicas de segmentação: A) Contorno Ativo baseado em borda; B) Contorno Ativo de Chan-Vese; C) Crescimento de Regiões com tolerância fixa; D) Crescimento de Regiões com tolerância variada	46
Figura 21 – Imagem da fatia de interesse de tomografia computadorizada de Rótulo 0039 com nódulo indicado pela seta	47
Figura 22 – Segmentação manual lado a lado com os resultados das técnicas de segmentação: A) Contorno Ativo baseado em borda; B) Contorno Ativo de Chan-Vese; C) Crescimento de Regiões com tolerância fixa; D) Crescimento de Regiões com tolerância variada	48
Figura 23 – Imagem da fatia de interesse de tomografia computadorizada de Rótulo 0005 com nódulo indicado pela seta	49
Figura 24 – Resultado da segmentação por contorno ativo geodésico na fatia de interesse do exame de rótulo 0005	50
Figura 25 - Resultados das segmentações por contorno ativo de Chan-Vese (à esquerda) e crescimento de regiões com tolerância fixa (à direita) na fatia de interesse do exame de rótulo 0005	50
Figura 26 – Região de interesse 0 (à esquerda) e região de interesse 1 (à direita) do exame de rótulo 0018, onde a região de interesse 1 tem nódulo mais bem definido	51

LISTA DE TABELAS

Tabela 1 – Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à fatia de interesse da tomografia computadorizada de rótulo 0014	46
Tabela 2 - Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à fatia de interesse da tomografia computadorizada de rótulo 0039	48
Tabela 4 - Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à fatia de interesse da tomografia computadorizada de rótulo 0005	51
Tabela 5 - Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à região de interesse 0 da tomografia computadorizada de rótulo 0018	52
Tabela 6 – Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à região de interesse 1 da tomografia computadorizada de rótulo 0018	52

LISTA DE QUADROS

Quadro 1 – Características dos nódulos da base de imagens	30
---	----

LISTA DE SIGLAS

CAD	Computer-aided diagnosis
LIDC-IDRI	Lung Image Database Consortium and Image Database Resource Initiative
CT	Computed tomography
PDI	Processamento de Imagens
ASM	Modelo Ativo de Formas
DICOM	Digital Imaging and Communications in Medicine

SUMÁRIO

1. INTRODUÇÃO	15
1.1. Objetivos Gerais	15
1.2. Objetivos Específicos	15
1.3. Tipificação do Problema	16
1.3.1. Patologia	16
1.3.1.1. Neoplasias Benignas e Malignas	17
1.3.1.1.1. Diferenciação e Anaplasia	18
1.3.1.1.2. Taxa de Crescimento	18
1.3.1.1.3. Invasão Local	19
1.3.1.1.4. Metástase	19
1.3.2. Tomografia Computadorizada	19
1.4. Estado da Arte	21
2. CONCEITOS DE PROCESSAMENTO DE IMAGENS	23
2.1. Segmentação de Imagens	24
2.2. Detecção de Bordas	24
2.3. Contorno Ativo	25
2.3.1. Snakes	26
2.3.2. Contorno Ativo Geodésico	26
2.3.3. Modelo sem Bordas de Chan-Vese	26
2.4. Crescimento de Regiões	27
3. MATERIAIS E MÉTODOS	29
3.1. Obtenção das Imagens	29
3.2. Segmentação dos Nódulos	31
3.2.1. Seleção das Informações Necessárias Para a Segmentação	31
3.2.2. Segmentação dos Nódulos	37
3.3. Obtenção e Comparação dos Resultados	39

3.3.1. Obtenção das Imagens Resultado.....	39
3.3.2. Análise Comparativa.....	44
4. RESULTADOS E DISCUSSÃO	45
5. CONCLUSÕES E TRABALHOS FUTUROS	54
6. REFERÊNCIAS	56

1. INTRODUÇÃO

Há muitos anos, o computador vem sendo utilizado na área da medicina. Dada a larga natureza digital de informação em imagens, vê-se bastante útil o uso do poder computacional na área de imagens médicas. A interpretação de imagens médicas envolve uma série complexa de tarefas que incluem detecção de anormalidade, descrição das características de uma lesão, diagnóstico de uma determinada doença e avaliação das dimensões da patologia para o auxílio do prognóstico. O uso de computadores para facilitar ou realizar algum desses processos de interpretação foi primeiro descrito nos anos 1960 e continua a crescer num ritmo acelerado. Esse campo de pesquisa é chamado *Computer Aided Diagnosis* (CAD) (KAGADIS; LANGER, 2012).

A princípio, pesquisas com CAD eram feitas para que sistemas CAD pudessem substituir o trabalho de um médico, mas foi reconhecido em seguida que o verdadeiro valor de CAD é a combinação da competência clínica de um médico especialista e a capacidade de consistência do computador, trazendo benefícios como a redução do tempo de leitura de imagens. Hoje, CAD é um objeto de estudo muito importante na área de imagens médicas (KAGADIS; LANGER, 2012).

O número de casos novos de câncer cresce a cada ano. No Brasil, entre 2012 e 2013, a ocorrência foi de mais de 500 mil casos novos. Em 2008, câncer foi a segunda maior causa de mortes na população. O câncer de pulmão é uma das maiores causas de morte por câncer no país (INCA, 2012). No Brasil, o câncer de pulmão foi responsável por 22.424 mortes em 2011. É um câncer altamente letal e a sobrevida média cumulativa total em cinco anos varia entre 13% e 21% em países desenvolvidos e entre 7% e 10% em países em desenvolvimento. (INCA, 2017)

1.1. Objetivos Gerais

Este trabalho tem como objetivo a análise de técnicas computacionais de processamento de imagens aplicadas em imagens de tomografia computadorizada de pulmão para segmentação de nódulos.

1.2. Objetivos Específicos

Este trabalho apresenta como objetivos específicos:

- a) Aplicar as técnicas computacionais de contorno ativo e crescimento de regiões para a detecção das bordas do nódulo e obter as coordenadas dessa borda;
- b) Comparar as coordenadas encontradas pela aplicação das técnicas utilizadas com as coordenadas presentes na base de imagens LIDC-IDRI para analisar a eficácia das mesmas.

1.3. Tipificação do Problema

1.3.1. Patologia

Segundo o INCA (2012, p.17), “as células normais que formam o tecido do corpo humano são capazes de se multiplicar por meio de um processo contínuo que é natural”. A maioria das células normais cresce, multiplica-se e morre de maneira ordenada, porém, nem todas as células normais são iguais: algumas nunca se dividem, como os neurônios e outras, como as células do tecido epitelial, dividem-se de forma rápida e contínua. (INCA, 2012)

De acordo com o INCA (2012, p.17), “a ploriferação celular não implica necessariamente presença de malignidade, podendo simplesmente responder a necessidades específicas do corpo”. Diferente das células normais, as células cancerosas crescem de maneira diferente. Ao invés de morrerem, elas continuam crescendo incontrolavelmente, formando outras novas células anormais. Diversos organismos vivos podem apresentar, em algum momento da vida, anormalidade no crescimento celular, acarretando transtornos funcionais. O câncer é um desses transtornos. O câncer se caracteriza pela perda do controle da divisão celular e pela capacidade de invadir outras estruturas orgânicas. (INCA, 2012)

A proliferação celular pode ser controlada ou não controlada. Na proliferação controlada, as células são normais ou com pequenas alterações na sua forma e função, podendo ser iguais ou diferentes do tecido onde se instalam. O efeito é reversível após o término do estímulo que a provocaram. Já a proliferação não controlada, o crescimento celular é quase autônomo, só dependendo do hospedeiro para sua nutrição e suprimento vascular (KUMAR; ABBAS ; ASTER, 2015) e, dessa forma, persiste após o término dos estímulos que a provocaram. As neoplasias correspondem a essa forma não controlada de crescimento celular. (INCA, 2012)

Neoplasia literalmente significa “crescimento novo”, e o que cresceu recentemente é um “neoplasma”. O termo “tumor” foi originalmente aplicado ao crescimento causado pela inflamação. Os neoplasmas também podem induzir crescimentos, mas o uso não-neoplásico de “tumor” caiu no desuso. Hoje o termo “tumor” é sinônimo de neoplasma. Câncer é o termo comum para todos os tumores malignos. Um tumor disputa com as células e tecidos normais do corpo quanto ao fornecimento de energia e substrato nutricional. (KUMAR; ABBAS ; ASTER, 2015)

Câncer de pulmão é uma doença que consiste em células anormais que se unem e formam um tumor. Células cancerígenas podem ser transmitidas para o resto do corpo através do sangue ou da linfa, que é um fluido transparente que impregna o corpo, produzido quando o sangue atravessa os vasos capilares e passa para o corpo; Os póros dos capilares são pequenos e impedem a passagem dos glóbulos vermelhos permitindo apenas a passagem do plasma sanguíneo, contendo oxigênio, proteínas e glóbulos brancos. O câncer de pulmão normalmente se espalha para o centro do tórax porque o fluxo natural da linfa acontece nessa direção.

A taxa de mortalidade por câncer de pulmão é a maior entre todos os tipos de câncer e o número de mortes por câncer de pulmão aumenta gradativamente todos os anos. As chances de cura estão diretamente relacionadas ao tempo de descoberta da doença, portanto o paciente tem maior chance de cura se o câncer for detectado nos primeiros estágios.

O câncer de pulmão é dividido em dois grupos: câncer de pulmão de pequenas células e câncer de pulmão de não-pequenas células. Além disso, existe uma classificação em estágios, do I ao IV, baseado no tamanho dos tumores e a localização dos linfonodos.

Recentemente, mecanismos de processamento de imagens têm sido amplamente utilizados em diferentes áreas médicas para acelerar a detecção de doenças.

1.3.1.1. Neoplasias Benignas e Malignas

Na grande maioria dos casos, a diferenciação entre um tumor benigno e um maligno pode ser feita morfológicamente com considerável certeza. Algumas características anatômicas podem sugerir inofensividade enquanto outras apontam para um potencial canceroso. Os diagnósticos morfológicos são, então, subjetivos e

constituem uma previsão do curso futuro de um neoplasma. Podem existir, porém, falsos positivos e falsos negativos. Um aspecto morfológico que caracterizaria um tumor como inofensivo pode mascarar uma natureza ruim, porém na grande maioria dos casos, o diagnóstico morfológico prevê de maneira correta a natureza dos tumores. (KUMAR; ABBAS ; ASTER, 2015)

Os critérios utilizados para diferenciar os tumores benignos dos malignos são: diferenciação e anaplasia, taxa de crescimento, invasão local e metástase.

1.3.1.1.1. Diferenciação e Anaplasia

Diferenciação refere-se ao nível de semelhança entre as células neoplásicas e as células normais comparáveis tanto morfológica quanto funcionalmente. Tumores bem diferenciados são compostos de células que se assemelham a células normais maduras do tecido de origem do neoplasma. Tumores pouco diferenciados ou indiferenciados geralmente têm um aspecto primitivo de células indiferenciadas. Em geral, os tumores benignos são bem diferenciados. Os neoplasmas malignos compostos de células indiferenciadas são ditos anaplásicos e a anaplasia é considerada um marco da transformação maligna.

A anaplasia é marcada por alterações morfológicas e funcionais. As células e os núcleos apresentam uma variação de tamanho e forma, podendo ser muito maiores que suas vizinhas ou extremamente pequenas e de aspecto primitivo. Em comparação aos tumores benignos ou aos malignos bem diferenciados, os tumores indiferenciados em geral possuem um grande número de mitoses, refletindo maior atividade proliferativa, porém a presença de mitoses não necessariamente indica que um tumor seja maligno ou que o tecido é neoplásico. Outra característica da anaplasia é a formação de células tumorais gigantes. (KUMAR; ABBAS ; ASTER, 2015)

1.3.1.1.2. Taxa de Crescimento

Em geral, a maioria dos tumores benignos crescem lentamente durante um período de anos, enquanto maioria dos cânceres cresce rapidamente, às vezes a uma velocidade errática, eventualmente se espalhando e matando seus hospedeiros, porém essa característica não pode ser analisada tão simplificada. Alguns tumores benignos têm a taxa de crescimento maior do que os tumores malignos, além disso, a taxa de crescimento tanto dos neoplasmas

benignos quanto dos malignos pode não ser constante ao longo do tempo. Diversos fatores podem afetar no crescimento de um neoplasma.

Apesar de existirem neoplasmas benignos com taxas de crescimento maiores do que neoplasmas malignos, em geral, a taxa de crescimento de um tumor está correlacionada com seu nível de diferenciação, portanto tumores benignos, normalmente, tem taxa de crescimento menor do que tumores malignos. Também existem comportamentos variados no crescimento de neoplasmas, como por exemplo, ele crescer lentamente ao longo dos anos e ocasionalmente aumentarem de tamanho de modo notório.

1.3.1.1.3. Invasão Local

A maioria dos tumores benignos crescem como massas coesivas em expansão, permanecendo situadas em seu local de origem, sem a capacidade de se infiltrarem, invadirem ou metastatizarem para locais distantes, como os tumores malignos. Eles costumam desenvolver um envoltório de tecido conjuntivo comprimido, às vezes chamado de cápsula, que o separa do tecido hospedeiro.

O crescimento dos cânceres é acompanhado de infiltração progressiva, invasão e destruição do tecido vizinho.

1.3.1.1.4. Metástase

Os tumores malignos, exclusivamente, apresentam um comportamento que os difere dos tumores benignos. Eles apresentam implantes tumorais descontínuos em relação ao tumor primário e esses implantes são chamados de metástases. A invasividade dos cânceres permitem que eles penetrem em vasos sanguíneos, linfáticos e cavidades corpóreas, tendo assim a oportunidade de se espalharem. Com poucas exceções, todos os cânceres podem fazer metástases. As principais exceções são os neoplasmas mais malignos de células gliais no sistema nervoso central e os carcinomas (neoplasmas malignos originários de célula epitelial) de células basais da pele.

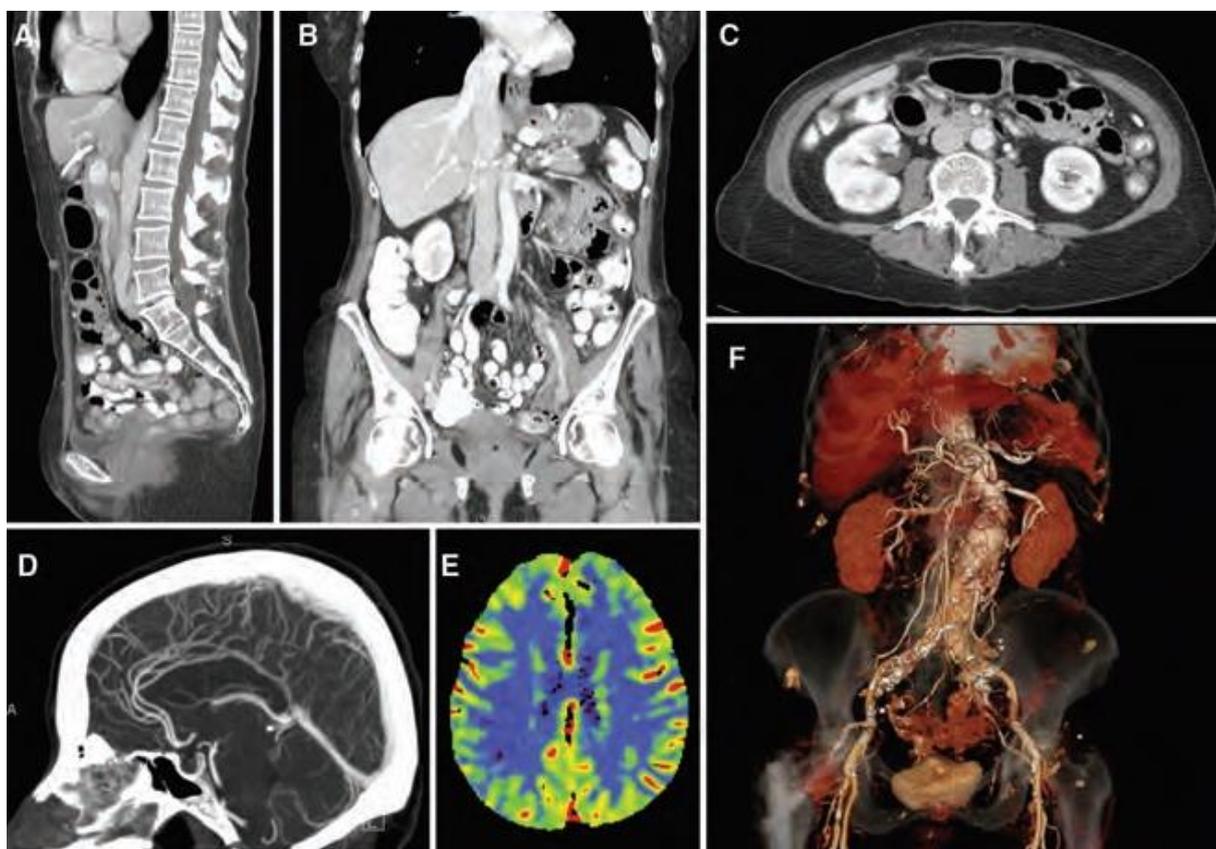
Em geral, quanto mais agressivo, de crescimento mais rápido e quanto maior o neoplasma primário, maior sua probabilidade de fazer metástase ou já ter feito.

1.3.2. Tomografia Computadorizada

A tomografia computadorizada (CT) se tornou disponível clinicamente na década de 1970 e é a primeira modalidade de imagens médicas feita por computador. Imagens de tomografia computadorizada são produzidas ao passar raios-X pelo corpo a um grande número de ângulos, rotacionando o tubo de raio-X em volta do corpo. Um vetor de detecção, oposto à fonte dos raios-X, coleta os dados de projeção transmitidos. Esses dados são sintetizados por um computador em imagens tomográficas do paciente. A vantagem das CT sobre radiografia é sua habilidade de mostrar fatias tridimensionais da anatomia de interesse, eliminando a sobreposição de estruturas anatômicas, gerando assim uma visão desobstruída da anatomia em detalhes (BUSHBERG et al., 2012).

Segundo Bushberg et al. (2012), “CT mudou a prática de medicina reduzindo a necessidade de cirurgias invasivas. Tomógrafos modernos conseguem obter imagens tomográficas de 0,5 a 0,62 milímetros de espessura de uma área do paciente de até 50cm de extensão em 5 segundos e revelar a presença de diversas patologias, incluindo o câncer”. A Figura 1 ilustra exemplos de imagens geradas com um tomógrafo.

Figura 1 – CT revela excelentes detalhes anatômicos, como pode ser visto nas imagens (A) sagital, (B) coronal e (C) axial de uma CT de uma pelve abdominal. Em (D), uma angiografia. (E) demonstra um mapa com cores correspondente ao volume de sangue no paciente em avaliação por suspeita de acidente vascular cerebral. F. Processamento de imagens pode podruzir representações tridimensionais pseudocoloridas da anatomia da tomografia computadorizada.



Fonte – Bushberg et al., 2012

1.4. Estado da Arte

(SHARMA; JINDAL, 2011) – Apresenta um sistema que propõe o diagnóstico automático do câncer de pulmão através do uso de técnicas de processamento de imagens. Primeiramente, o sistema proposto aplica técnicas de processamento de imagens na tomografia computadorizada para determinar a área correspondente ao pulmão. As técnicas aplicadas são Erosão, Filtro da Mediana, Dilatação, Contorno e Extração de Bordas. Em seguida o algoritmo de segmentação é aplicado para detectar os nódulos nas imagens do pulmão que foram extraídas. Por fim são utilizadas um conjunto de regras de diagnóstico para classificar os nódulos identificados como benignos ou malignos e o conjunto de regras é atualizado a partir das características obtidas a partir da análise dos resultados.

(KUMAR et al., 2016) – Utiliza diferentes métodos para detectar células cancerígenas de um pulmão utilizando tomografias computadorizadas. Os métodos utilizados foram as técnicas de pré-processamento Filtro de Gabor, segmentação de imagens por Watershed e extração de características.

(KANITKAR; THOMBARE; LOKHANDE, 2015) – Propõe um método para detectar as células cancerígenas efetivamente a partir de imagens de tomografias computadorizadas do pulmão. O sistema proposto, primeiramente, faz o pré-processamento das imagens para suavizar e aprimorar as imagens e em seguida é feita a segmentação dessas imagens. As técnicas utilizadas foram o Filtro de Gauss para suavização, Filtro de Gabor para o aprimoramento e as técnicas de thresholding e Watershed controlado por marcadores para a segmentação das imagens.

(AL-TARAWNEH, 2012) – Apresenta um trabalho que propõe uma detecção de características para uma comparação precisa de imagens como porcentagem de pixels e *mask labelling*. Primeiramente, o trabalho do autor faz um aprimoramento das imagens com o objetivo de aprimorar a interpretabilidade ou percepção de informações incluídas nas imagens para a visão humana ou fornecer melhor entrada para outras técnicas automáticas de processamento de imagens. Os métodos utilizados nessa etapa foram o filtro de Gabor, que, de acordo com o autor, obteve melhores resultados, e a Transformada de Fourier, que obteve piores resultados. Em seguida, houve uma etapa de segmentação das imagens. Nessa etapa, foram utilizados os métodos de *Thresholding*, que obteve piores resultados, e Watershed controlado por marcadores, que obteve melhores resultados. A última etapa do trabalho consistiu na extração das características, feita através de binarização e *Masking Approach*.

2. CONCEITOS DE PROCESSAMENTO DE IMAGENS

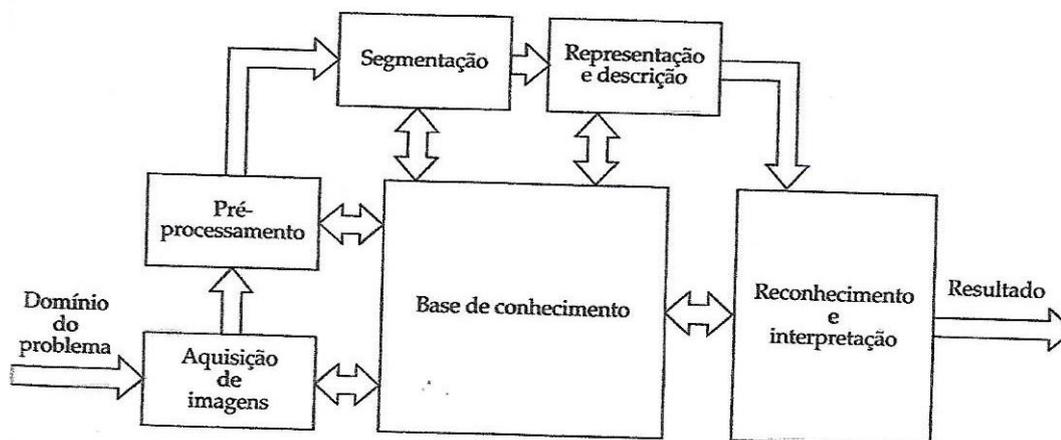
O termo imagem monocromática, ou simplesmente imagem, refere-se à função bidimensional de intensidade da luz $f(x,y)$ onde x e y denotam as coordenadas espaciais e o valor de f em qualquer ponto (x,y) é proporcional ao brilho (ou níveis de cinza) da imagem naquele ponto (GONZALEZ; WOODS, 2011). Uma imagem pode ser considerada uma matriz onde as linhas representam a coordenada x e as colunas, a coordenada y . Cada ponto representado pelo par ordenado (x,y) é chamado de pixel. Neste trabalho, são usadas imagens de tomografias computadorizadas representadas da maneira descrita. Processamento Digital de Imagens (PDI) refere-se à manipulação de uma imagem digital para a obtenção de algum resultado específico. Um sistema de PDI geralmente é formado por 5 elementos: Aquisição, armazenamento, processamento, comunicação e exibição; mas PDI normalmente diz respeito à etapa de processamento de fato.

Como mostrado na Figura 2, o primeiro passo no processo é a aquisição da imagem. Basicamente, a aquisição de imagem consta no uso de um sensor para produzir um sinal e a capacidade de digitalizá-lo. Após a obtenção de uma imagem digital, o próximo passo é o pré-processamento dessas imagens. A função principal do pré-processamento é melhorar a imagem com o objetivo de aumentar as chances de sucesso dos processos seguintes (GONZALEZ; WOODS, 2011).

O próximo estágio é a segmentação que, basicamente, divide uma imagem de entrada em partes ou objetos constituintes. Em geral, a segmentação autônoma é uma das tarefas mais difíceis em processamento de imagens e esse passo determina o eventual sucesso ou fracasso na análise de imagens. Com os resultados de uma segmentação é feito então o próximo passo, que é a representação e descrição. A escolha de uma representação é apenas parte de uma solução para transformar os dados iniciais numa forma adequada para o próximo processo computacional, a descrição. Esse processo procura extrair características que resultem em alguma informação quantitativa de interesse. Por exemplo, para reconhecer caracteres, descritores como buracos e concavidades são características poderosas que auxiliam na diferenciação desses caracteres. O último estágio envolve reconhecimento, que é o processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor, e a interpretação, que diz

respeito à atribuição de significado a um conjunto de objetos reconhecidos (GONZALEZ; WOODS, 2011).

Figura 2 – Passos fundamentais em processamento de imagens digitais



Fonte – Gonzalez; Woods, 2011

Em se tratando do processamento propriamente dito, este pode ser dividido em duas grandes áreas: Pré-processamento e Análise de Imagens.

2.1. Segmentação de Imagens

A segmentação de imagens faz parte da área de Análise de Imagens, que diz respeito à área do PDI onde são extraídas informações de uma imagem digital. Basicamente, segmentar uma imagem significa dividir a imagem em partes diferentes com o propósito de isolar uma região do interesse, que depende do problema a ser resolvido (GONZALEZ; WOODS, 2011).

Algoritmos de segmentação em imagens monocromáticas são geralmente baseados em descontinuidade ou similaridade nos valores de cinza. Algoritmos baseados em descontinuidade consistem em procurar mudanças bruscas nos níveis de cinza que, normalmente, representam o limite de um objeto na imagem digital. Essa categoria de algoritmos de segmentação de imagens é utilizada normalmente para a detecção de pontos isolados e linhas ou bordas nas imagens. Já os algoritmos baseados em similaridade visam abordagens relacionadas à limiarização, crescimento de regiões e divisão e fusão de regiões (GONZALEZ; WOODS, 2011).

2.2. Detecção de Bordas

A detecção de bordas é a abordagem mais habitualmente utilizada entre as segmentações baseadas em detecção de descontinuidades significantes nos níveis de cinza, pois apresenta maior utilidade em aplicações práticas.

Uma borda é o limite entre duas regiões com propriedades relativamente distintas de nível de cinza. Basicamente, a ideia por trás da maioria das técnicas para a detecção de bordas é a computação de um operador local diferencial. A magnitude da primeira derivada pode ser usada na detecção da presença de uma borda em uma imagem e o sinal da segunda derivada pode ser usado para determinar se um pixel da borda localiza-se no lado escuro ou claro da mesma. Os valores da primeira e segunda derivadas em algum ponto da imagem podem ser encontrados utilizando a magnitude do gradiente naquele ponto e o laplaciano, respectivamente (GONZALEZ; WOODS, 2011). Além dos operadores de gradiente e laplaciano, existem outros métodos para a detecção de bordas em uma imagem digital. Neste trabalho foram analisadas técnicas de Contorno Ativo e Crescimento de Regiões.

2.3. Contorno Ativo

A ideia básica em modelos de contorno ativo é envolver uma curva para detectar objetos em determinada imagem. Por exemplo, começando com uma curva em volta do objeto a ser detectado, a curva se move em direção à sua normal interior e deve parar na borda do objeto (CHAN; VESE, 2001).

Abordagens por contorno ativo fazem uso efetivo de informações prévias específicas dos objetos e isso torna os algoritmos intrinsecamente eficientes. Além disso, algoritmos de contorno ativo são aplicados em regiões específicas da imagem ao invés de serem aplicados na imagem inteira, o que faz a sua eficiência ser ainda maior.

Uma das abordagens de contorno ativo é o Modelo Ativo de Formas (ASM). Alguns dos métodos que aplicam o ASM são os Templates Deformáveis, Snake e Contornos Dinâmicos.

Snakes são um mecanismo para trazer um certo grau de conhecimento prévio para lidar com interpretação de imagens de baixo nível. Ao invés de esperar propriedades como continuidade e suavidade emergirem dos dados da imagem, essas propriedades são impostas desde o início. Em suma, um modelo elástico e

curvo é imposto na imagem e se ajusta para combinar com um objeto. Dessa forma, o impacto das informações prévias pode ser controlado alterando os parâmetros de elasticidade. A modelagem prévia pode ser mais específica para gerar resultados mais precisos se for construído um conjunto de curvas flexíveis e os respectivos parâmetros que controlam variáveis cinemáticas como o tamanho de cada curva, o ângulo com que ela é posicionada, etc. Esse modelo é o modelo de Templates Deformáveis.

2.3.1. Snakes

Processos de baixo nível para a detecção de características são efetivos para situações onde não é necessária a detecção de um objeto inteiro em uma imagem. O modelo Snake constitui uma nova abordagem para lidar com esse tipo de situações que os processos de baixo nível não conseguem lidar. A ideia essencial do snake é usar um mapa de características $M(r)$ e tratar $(-M(r))$ como um panorama pelo qual a snake, que é como é chamada a curva deformável, pode se envolver. Imagens com maiores contrastes e boa definição dos objetos, mudança brusca de níveis de cinza nas bordas, vão fazer a snake ser atraída a se envolver nas bordas desse objeto.

2.3.2. Contorno Ativo Geodésico

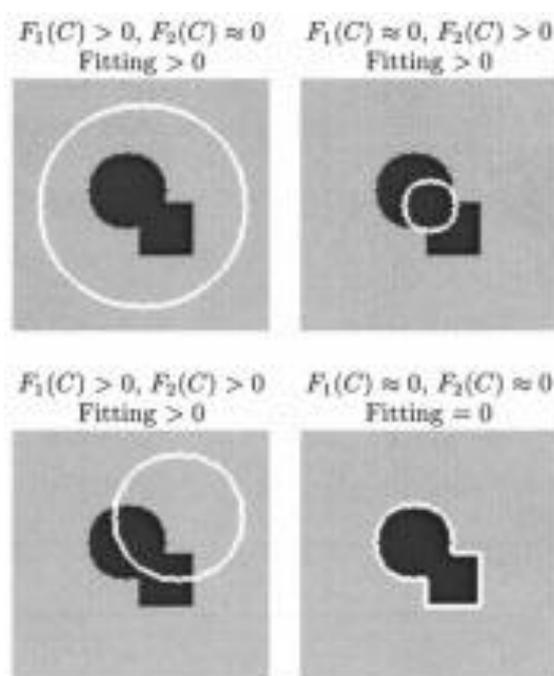
O modelo de Contorno Ativo Geodésico baseia-se na teoria de evolução de curvas e fluxos geométricos. Nesse modelo de contorno ativo, a curva inicial é deformada por meios de uma velocidade que contém dois termos, um relacionado à regularidade da curva e outro expande ou encolhe em direção aos limites de um objeto. A partir de uma determinada equação diferencial parcial, o modelo de contorno ativo geodésico propõe um aperfeiçoamento de modelos mais antigos de evolução de curvas (CASELLES et al, 1997).

2.3.3. Modelo sem Bordas de Chan-Vese

O método de Chan-Vese é uma minimização de uma segmentação baseada em energia. Como os modelos clássicos de contorno ativo dependem de uma função de borda, contando com o gradiente da imagem para interromper a evolução da curva, esses modelos limitam-se a detectar objetos com bordas definidas por gradiente. O modelo de Chan-Vese propõe uma diferente abordagem, sem uma

função de interrupção por borda. Ao invés disso, o termo para interrupção do método é baseado em técnicas de segmentação de Mumford-Shah. Além disso, o modelo de Chan-Vese é capaz de fazer a detecção de objetos sem que a curva inicial esteja necessariamente em volta do objeto a ser detectado (CHAN; VESE, 2001). A Figura 3 apresenta um exemplo de aplicação do modelo de Chan-Vese com diferentes curvas iniciais

Figura 3 – Curva inicial para modelo de Chan-Vese



Fonte – Chan; Vese, 2001

2.4. Crescimento de Regiões

As técnicas de crescimento de regiões consistem basicamente em agrupar pixels ou semi-regiões em regiões maiores. Segundo Gonzalez e Woods (2000), a mais simples dessas abordagens é a agregação de pixels, que começa com um conjunto de pontos semente e, a partir deles, cresce as regiões anexando a cada ponto semente aqueles pixels que possuam propriedades similares, como nível de cinza. Os critérios utilizados para a segmentação por agregação de pixels dependem do problema e do tipo da imagem utilizada. Com as tomografias computadorizadas, serão utilizados os níveis de cinza, pois as imagens são monocromáticas e nelas, os níveis de cinza são característica suficiente para determinar uma região. Com essa

técnica de crescimento de regiões, é necessário haver uma condição de parada, mas basicamente, a técnica agrega pixels à região até que não hajam pixels vizinhos que possuam as propriedades similares que são determinadas no início da aplicação dessa técnica.

3. MATERIAIS E MÉTODOS

Esta seção apresenta a descrição do conjunto de passos utilizados para a obtenção dos resultados deste trabalho. Esses passos consistem da obtenção e seleção das imagens usadas no trabalho, utilização das técnicas computacionais para a segmentação dos nódulos nessas imagens e as comparações realizadas entre os resultados obtidos por esses métodos.

A linguagem de programação utilizada nesse trabalho foi o Matlab¹ devido a quantidade de métodos oferecidos pelo pacote para a aplicação das técnicas computacionais selecionadas para análise neste trabalho.

As imagens de tomografias computadorizadas utilizadas para análise neste trabalho estão no padrão DICOM² com dimensão de 512x512 pixels e as segmentações manuais feitas por especialistas estão em formato PNG, são monocromáticas e tem profundidade de 8 bits, ou seja, cada pixel é representado por um valor de cinza entre 0 e 255.

3.1. Obtenção das Imagens

Para o desenvolvimento deste trabalho foi utilizada a base de imagens disponibilizada pelo Lung Image Database Consortium e Image Database Resource Initiative (LIDC-IDRI). O LIDC-IDRI é um recurso internacional acessível online para o desenvolvimento, treinamento e avaliação de sistemas CAD para detecção e diagnóstico do câncer de pulmão (ARMATO et al., 2011).

As imagens tomográficas disponíveis na base LIDC-IDRI contam com a anotação de diagnóstico e segmentação manual de nódulos pulmonares realizada por especialistas. Para o desenvolvimento do trabalho foram selecionadas as imagens com indicação confirmada de nódulos, visando a adequada análise e validação das técnicas propostas e posterior comparação e integração em ambiente de apoio ao diagnóstico (FERREIRA-JUNIOR et al., 2016). Ferreira-Junior et al (2016) integraram os dados da coleção LIDC-IDRI mais caracterização da textura dos nódulos numa única base de dados baseada em nuvem. MongoDB foi o Sistema de Gerenciamento de Banco de Dados utilizado por eles para armazenar a

¹ Matlab é uma linguagem de programação de alta performance voltada para o cálculo numérico e diferencia-se de outras linguagens por trabalhar com matrizes e vetores inteiros ao invés de cada número de uma vez.

² DICOM é um padrão para armazenar e transmitir imagens médicas num formato eletrônico e permite que imagens médicas e informações associadas sejam trocadas entre equipamentos de diagnóstico geradores de imagens, computadores e hospitais.

base de dados devido a seu alto poder de processamento paralelo, alta performance em recuperação de dados e pela sua capacidade de armazenar imagens.

A base de imagens contém imagem com objetos classificados em nódulos iguais ou maiores que 3mm de diâmetro, nódulos menores que 3mm de diâmetro e não-nódulos iguais ou maiores que 3mm de diâmetro. Para esse trabalho, foram utilizados os nódulos iguais ou maiores que 3mm de diâmetro, pois apenas estes contém informações da borda e características relacionadas a eles, produto de anotações de especialistas. Cada um dos nódulos presentes no banco de imagens é apresentado em diferentes regiões de interesse. No total, o banco conta com 19 casos com objetos identificados como nódulos. Cada caso possui um ou mais nódulos e cada nódulo possui uma ou mais regiões de interesse. Para a realização desse trabalho, foram utilizados 15 diferentes nódulos e, no total 19 regiões de interesse. O Quadro 1 mostra as características dos nódulos anotadas no banco de dados e o significado do número atribuído por especialistas correspondente a cada uma delas.

Quadro 1 – Características dos nódulos da base de imagens

Característica	Definição	Escala de Valores
Sutileza	Refere-se à dificuldade de detecção	1-5
Estrutura Interna	Composição interna do nódulo	1-4 (1 = Tecido Macio, 2 = Fluido, 3 = Gordura, 4 = Ar)
Calcificação	Padrão de calcificação, se presente	1-6 (1 = Pipoca, 2 = Laminado, 3 = Sólido, 4 = Não-Central, 5 = Central, 6 = Ausente)
Esfericidade	O formato em três dimensões do nódulo em termos de sua circularidade	1, 3 ou 5 (1 = linear, 3 = ovóide, 5 = redondo)
Margem	Descrição de quão bem definidas são as bordas do	1 ou 5 (1 = Pobremente Definida,

Característica	Definição	Escala de Valores
	nódulo	5 = Acentuada)
Espiculação	Refere-se ao nível de espiculação presente no nódulo	1-5
Textura	Textura interna ou composição do nódulo em termos de componentes sólidos ou translúcidos	1, 3 ou 5 (1 = Não Sólida ou Translúcida, 3 = Parcialmente Sólida, 5 = Sólida)
Malignidade	Avaliação subjetiva dos especialistas da probabilidade de malignidade do nódulo, assumindo um fumante do sexo masculino de 60 anos de idade	1-5

Fonte – Baseado em Ferreira-Junior et al., 2016

3.2. Segmentação dos Nódulos

Como descrito na seção 3.1, a base de imagens disponibiliza anotações de diagnóstico, inclusive a segmentação manual de nódulos pulmonares realizadas por especialistas em cada caso apresentado. Utilizando-se desses dados, foram selecionados registros da base que representam casos com lesões classificadas como nódulos. Para a segmentação dos nódulos presentes nas imagens selecionadas, foram implementados duas versões de Contorno Ativo e duas versões de Crescimento de Regiões.

Para este trabalho, foram utilizados dois métodos de contorno ativo: o modelo geodésico e o modelo sem bordas de Chan-Vese; e uma abordagem de crescimento de regiões de duas maneiras: uma com tolerância fixa e outra com tolerância variada. Essas técnicas foram escolhidas empiricamente por já estarem implementadas e disponíveis no pacote do Matlab.

3.2.1. Seleção das Informações Necessárias Para a Segmentação

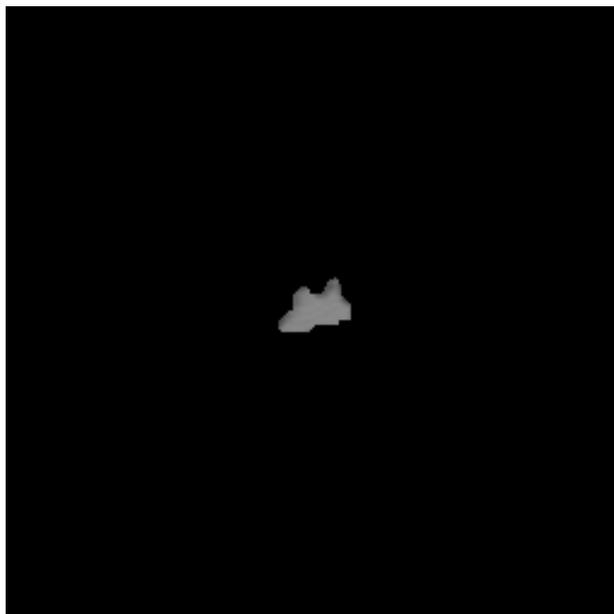
Cada imagem presente na base LIDC-IDRI possui uma série de informações correspondentes como textura, malignidade, esfericidade, entre outras, e além dessas características, elas contêm também um mapeamento da borda da segmentação manual feita por especialistas. Para a segmentação das imagens selecionadas, foram utilizadas as informações da descrição manual da borda dos nódulos, para selecionar os valores de entrada de cada uma das técnicas.

A Figura 4 é um exemplo de imagem da base LIDC-IDRI. Ela representa uma fatia de uma tomografia computadorizada com a presença de um nódulo, que foi manualmente segmentado e está descrito na Figura 5.

Figura 4 – Exemplo de imagem de tomografia computadorizada

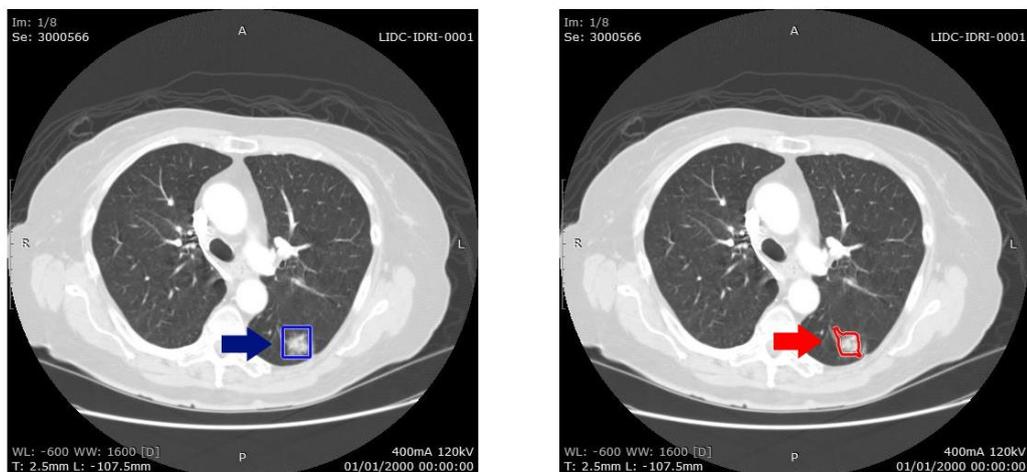


Figura 5 – Nódulo presente na Figura 4 segmentado manualmente por especialistas



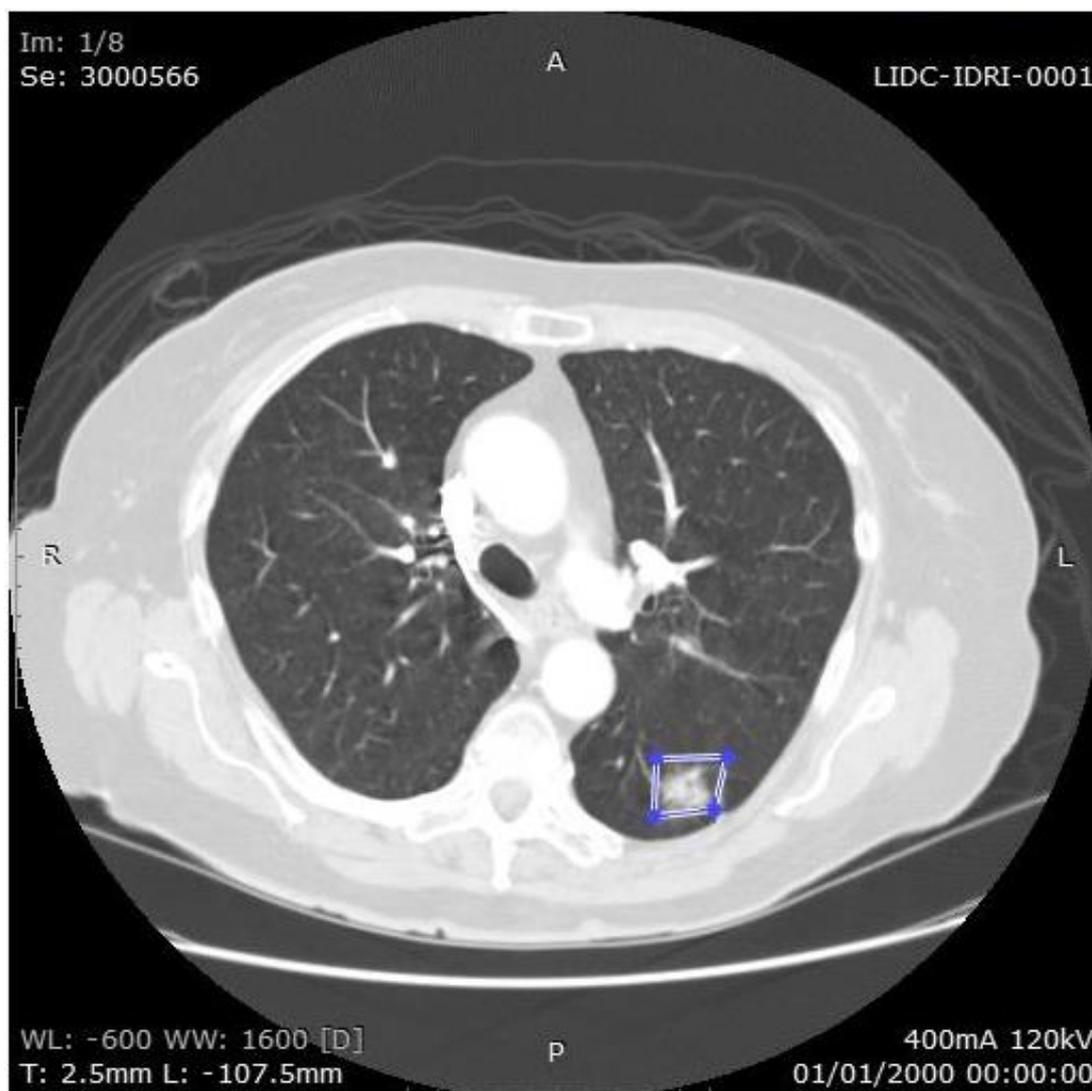
Após a seleção das imagens, foram aplicadas as técnicas escolhidas para a segmentação dos nódulos. Para a aplicação das técnicas de Chan-Vese e do modelo geodésico, foi necessária a seleção de máscaras, que são regiões maiores que contém o objeto de interesse em questão, nesse caso os nódulos. Para a técnica de contorno ativo baseada em bordas, essas regiões foram definidas por um retângulo, cujas dimensões foram escolhidas através das informações presentes no base LIDC-IDRI organizadas no banco de dados MongoDB do Ferreira-Junior et al, entre elas o mapeamento das bordas da segmentação manual feita por especialistas e a imagem dessa segmentação. Com essas informações, o nódulo foi identificado visualmente na imagem original e então as dimensões do retângulo utilizado como máscara foram definidas, como mostrado na Figura 6.

Figura 6 - Imagem de aplicação da técnica de contorno ativo geodésico. À esquerda, imagem com máscara escolhida, indicada pela seta, e à direita, borda da segmentação, indicada pela seta.



Para a aplicação da técnica de Chan-Vese foi feita uma seleção manual da área que compõe a máscara usada na segmentação. Utilizando as informações da borda da segmentação feita manualmente por especialistas, contidas no banco do MongoDB, foram identificados visualmente o nódulo em cada imagem e a área para a máscara foi então selecionada. A Figura 7 mostra um exemplo de seleção manual da máscara para segmentação com o modelo sem bordas de Chan-Vese.

Figura 7 – Imagem com a máscara escolhida manualmente para a aplicação da técnica de Chan-Vese de contorno ativo em tomografia computadorizada



Além das técnicas de contorno ativo, foram implementadas duas versões de crescimento de regiões. Para essas implementações foi necessário escolher um pixel semente. Para a escolha desse pixel também foram utilizadas as coordenadas da segmentação manual contida no banco do MongoDB. Essas informações, junto com a imagem da segmentação manual, foram utilizadas para identificar um pixel adequado para servir como entrada para as técnicas de crescimento de regiões. A diferença das duas abordagens é que uma tem 32 como valor padrão de tolerância da técnica disponível do pacote do Matlab para os níveis de cinza que fazem parte do mesmo objeto e a outra recebe como entrada, além do pixel semente, um valor de tolerância para determinar quais pixels fazem parte do mesmo objeto na imagem,

que será escolhido de acordo com os níveis de cinza presentes no nódulo, mostrado na segmentação manual. Em alguns casos, outros objetos na imagem podem estar próximos do nódulo e ter características semelhantes. Nesses casos, se o valor de tolerância não for bem escolhido, os resultados podem ser comprometidos, já que o método vai considerar os objetos adjacentes como sendo parte do nódulo, o que pode ser visto na Figura 8. Para diferenciar as duas abordagens por crescimento de regiões, chamamos a abordagem com tolerância fixa de RGF e a abordagem com tolerância variável de RGV.

A Figura 9 mostra um exemplo da aplicação dos dois métodos de crescimento de regiões com o mesmo pixel semente e diferentes valores de tolerância.

Figura 8 – Aplicação da técnica RGV com valor de tolerância 20. Em vermelho, o objeto detectado pela técnica de crescimento de regiões. Em azul, o nódulo que deveria ser identificado.

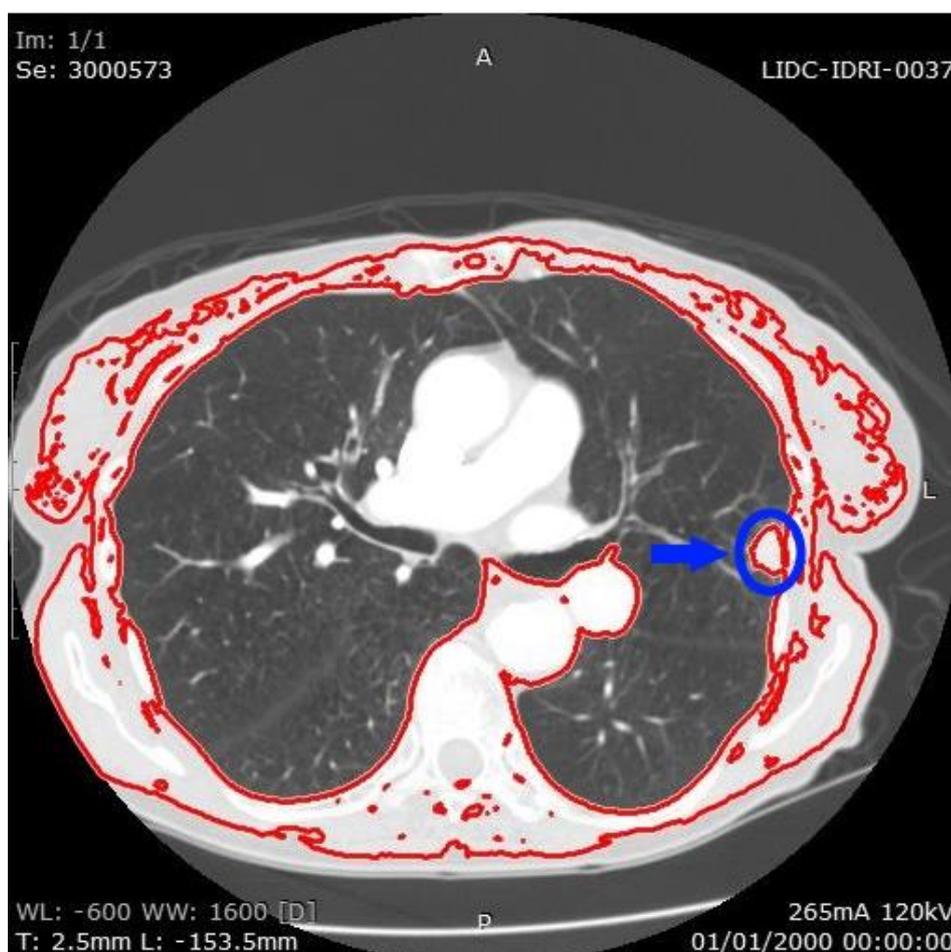
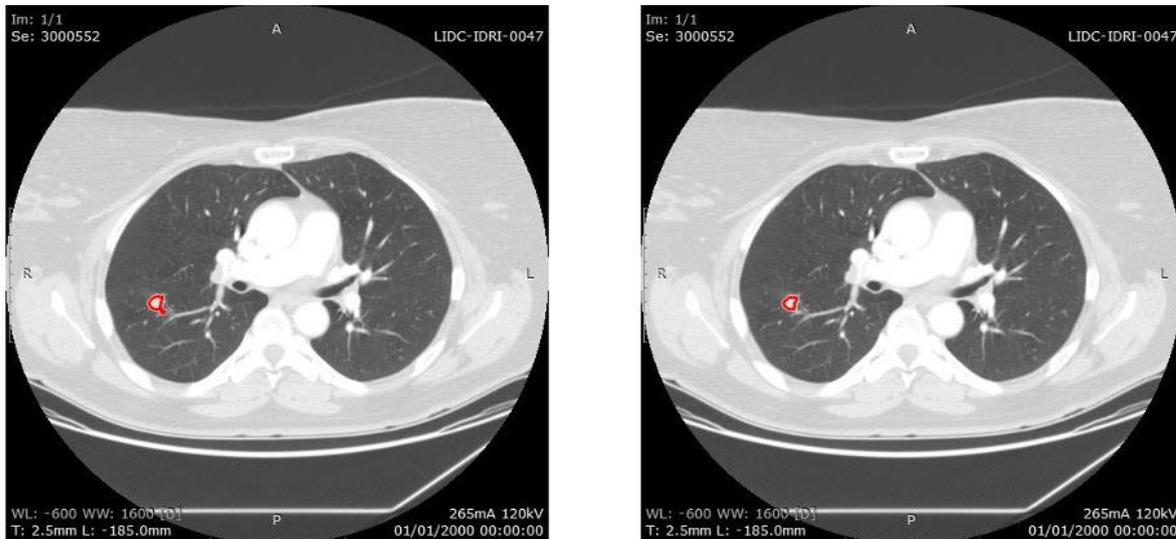


Figura 9 – Aplicação de técnica de crescimento de regiões. À esquerda, valor de tolerância estabelecido em 40. À direita, valor de tolerância padrão (32).



3.2.2. Segmentação dos Nódulos

Com a aplicação das técnicas de segmentação escolhidas para a análise neste trabalho, utilizando como entrada as informações coletadas na etapa anterior, então, são geradas as imagens segmentadas. As Figuras 10, 11, 12 e 13 mostram exemplos dos resultados das segmentações.

Figura 10 – Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por contorno ativo geodésico

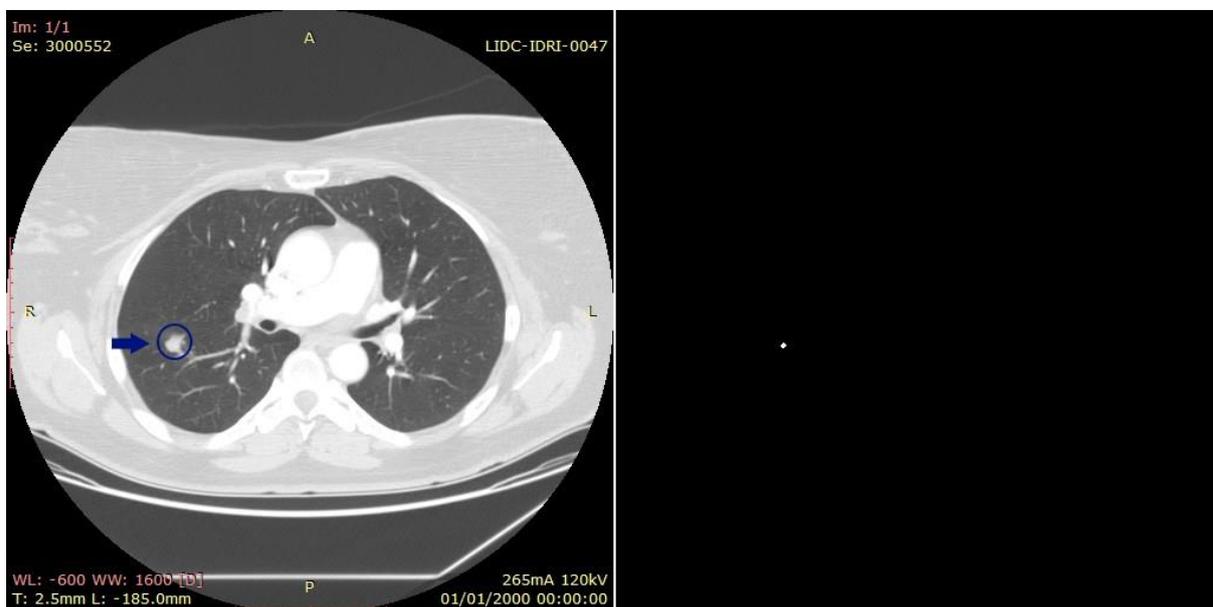


Figura 11 - Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por modelo sem bordas de Chan-Vese

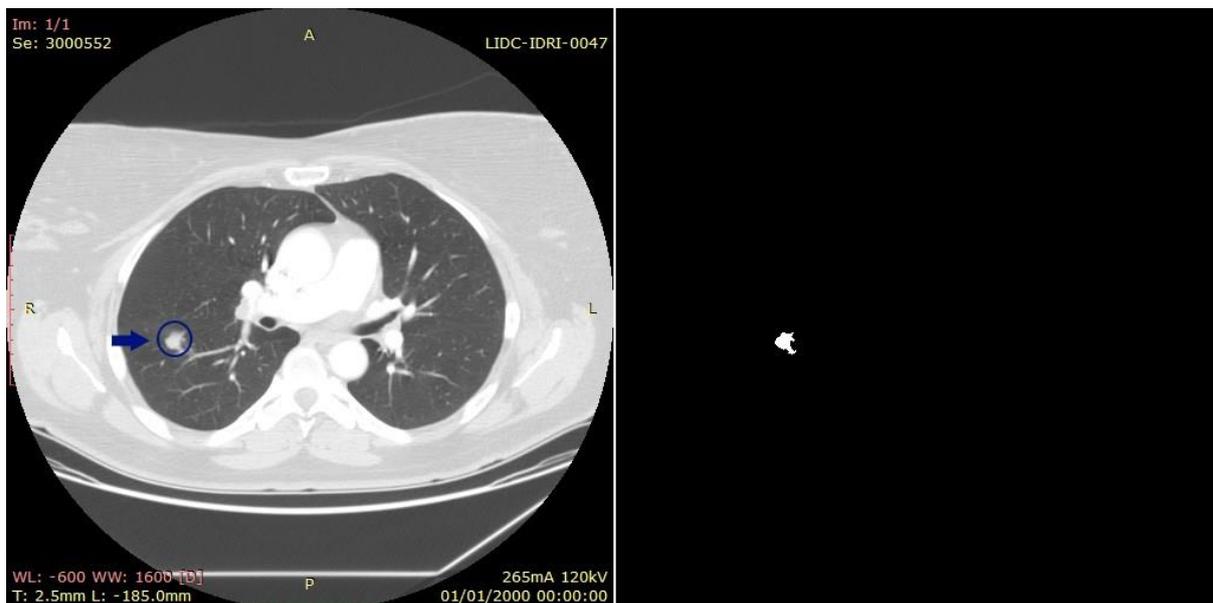


Figura 12 - Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por RGF

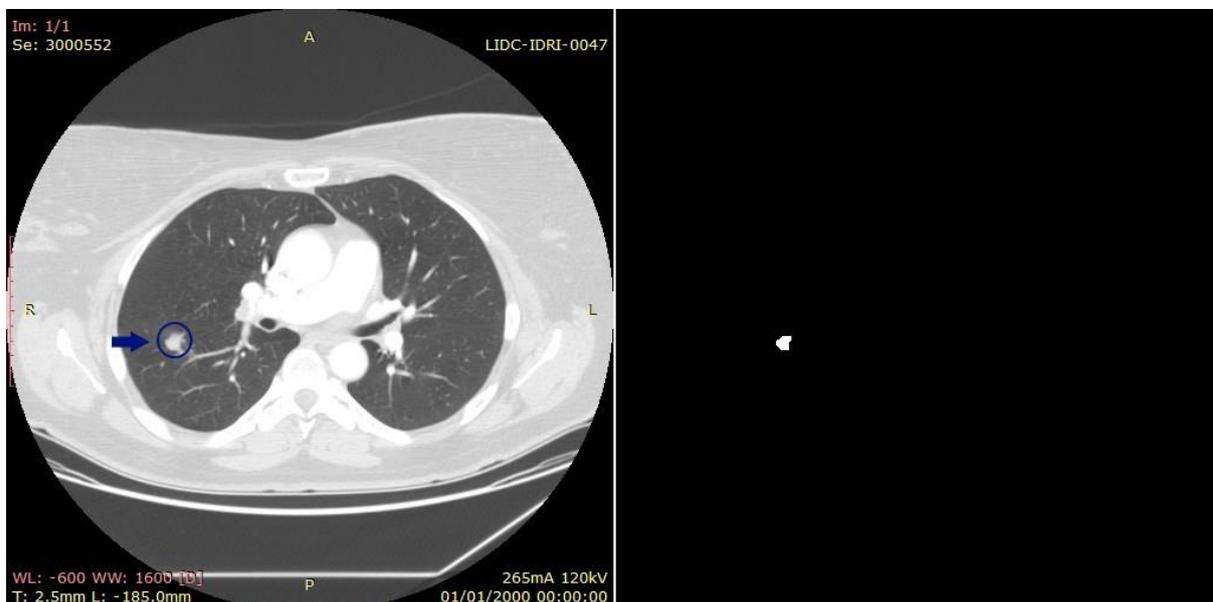
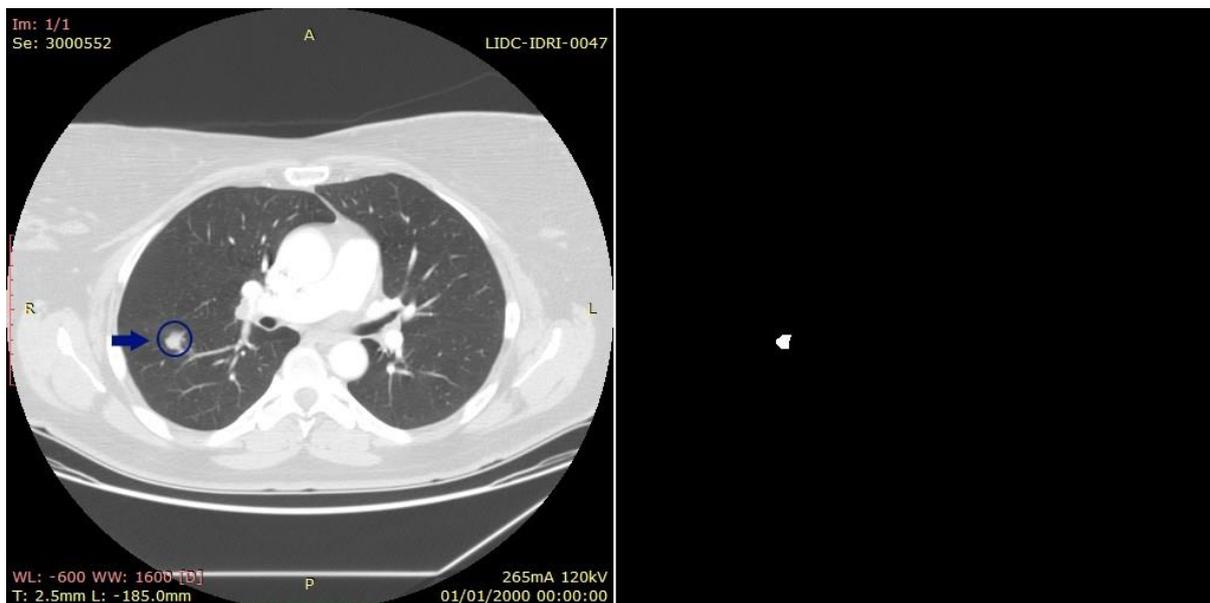


Figura 13 - Imagem de interesse de exame de rótulo 0047 com nódulo indicado pela seta e ao lado, resultado da segmentação por RGV



3.3. Obtenção e Comparação dos Resultados

Após feita a segmentação das imagens com os métodos computacionais de segmentação escolhidos para análise neste trabalho, foram obtidas imagens contendo apenas as áreas segmentadas correspondentes a cada um dos métodos utilizados. Feito isso, essas imagens foram comparadas para identificar qual delas obteve melhores resultados.

3.3.1. Obtenção das Imagens Resultado

Como mencionado anteriormente, o banco contém imagens da segmentação manual dos nódulos presentes nas tomografias computadorizadas. Essas imagens são a base para as análises comparativas que foram feitas nesse trabalho, mas antes que isso possa ser feito, é preciso uma série de processos para que as imagens de resultado da aplicação das técnicas possam ser comparadas com a segmentação manual.

A Figura 14 mostra a comparação visual entre uma segmentação manual contida na base de dados LIDC-IDRI e o resultado de uma das técnicas aplicadas na imagem original referente a essa segmentação.

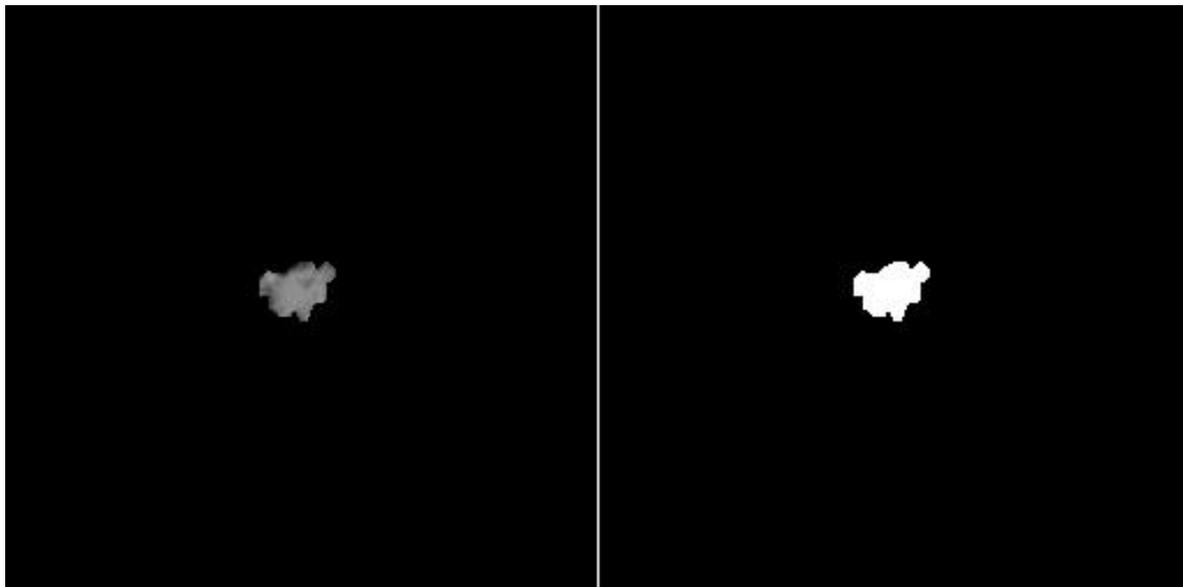
Figura 14 – Imagem da segmentação manual feita por especialistas (à esquerda) colocada ao lado de resultado de segmentação por contorno ativo baseado em borda (à direita) respeitando as proporções dos tamanhos originais



Como pode-se observar na Figura 14, existe uma discrepância entre os tamanhos das imagens e, além disso, a segmentação manual está em níveis de cinza e o resultado da técnica de segmentação aplicada neste trabalho é uma imagem binária. Para que essas imagens pudessem ser comparadas, foi preciso lidar com essas divergências antes que as comparações pudessem ser feitas e as análises dos resultados realizadas.

Para resolver o problema de níveis de cinza, simplesmente foi considerado que, já que os especialistas fizeram a marcação das bordas dos nódulos envolvendo toda aquela área, tudo que estivesse na imagem e que fizesse parte da segmentação, é considerado parte do nódulo. Para este trabalho, os diferentes níveis de cinza presentes no objeto segmentado não são relevantes, portanto foi aplicado um filtro de binarização nas imagens das segmentações manuais.

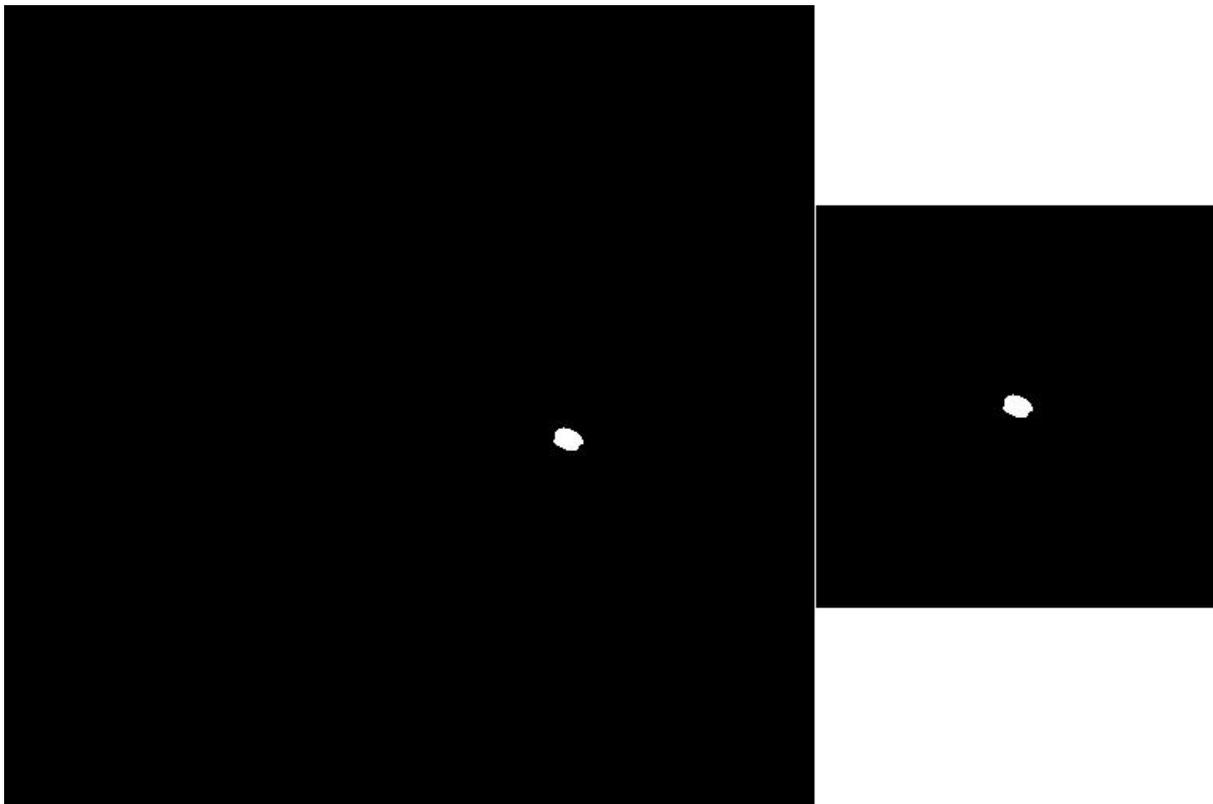
Figura 15 – Segmentação manual de nódulo em tomografia computadorizada em níveis de cinza (à esquerda) ao lado de resultado de sua binarização (à direita)



Feita a binarização das imagens das segmentações manuais, foi necessário também resolver o impasse da diferença de proporção. Essa etapa demanda um pouco mais de esforço, visto que além da diferença de tamanho das imagens, existe também uma divergência na localização geográfica da massa nelas.

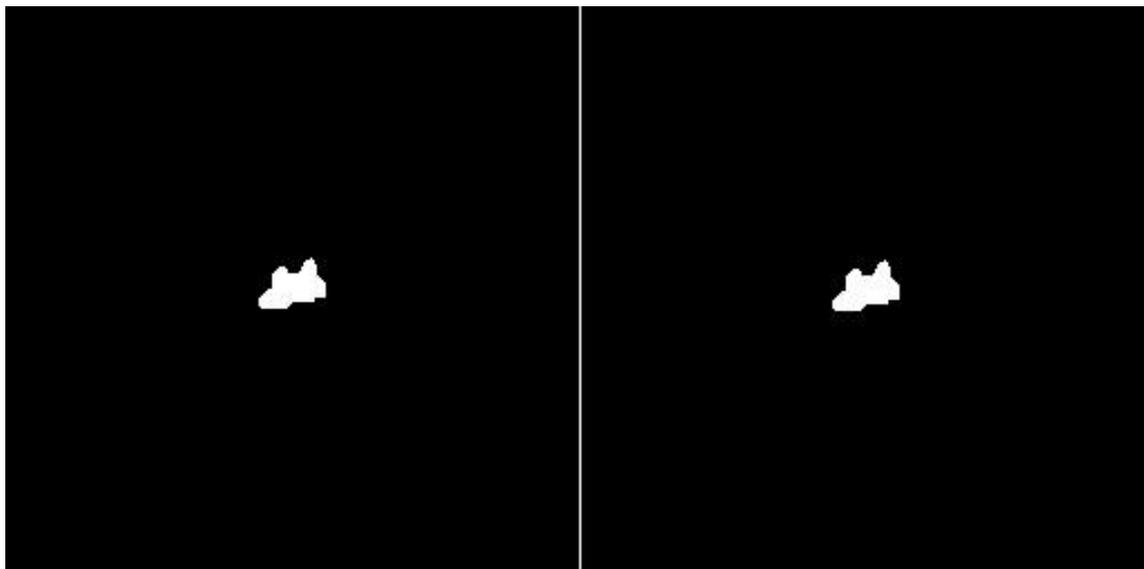
Todas as imagens das segmentações manuais contidas no banco de imagens tem dimensão de 256x256 pixels e as imagens originais das tomografias computadorizadas tem dimensão de 512x512 pixels, gerando resultados das segmentações de mesmo tamanho. Porém as segmentações manuais não tem diferença de proporção com as imagens originais; Elas são apenas cortes das imagens originais correspondentes. Foi preciso, então, transferir os pixels dos nódulos das imagens resultadas da aplicação das técnicas utilizadas no trabalho para outras imagens com dimensão de 256x256 pixels. Para fazer isso, foi encontrado o centro da massa dessas imagens para que o nódulo pudesse estar centralizado na imagem de menor dimensão. Como não há divergência de proporção, a informação dos nódulos foi passada na íntegra, não comprometendo os resultados obtidos. A Figura 16 mostra a redução de dimensão da imagem do resultado da aplicação do modelo sem bordas de Chan-Vese assim como a centralização do nódulo.

Figura 16 – Exemplo de segmentação com modelo sem bordas de Chan-Vese e imagem com dimensão reduzida e nódulo centralizado pelo centróide



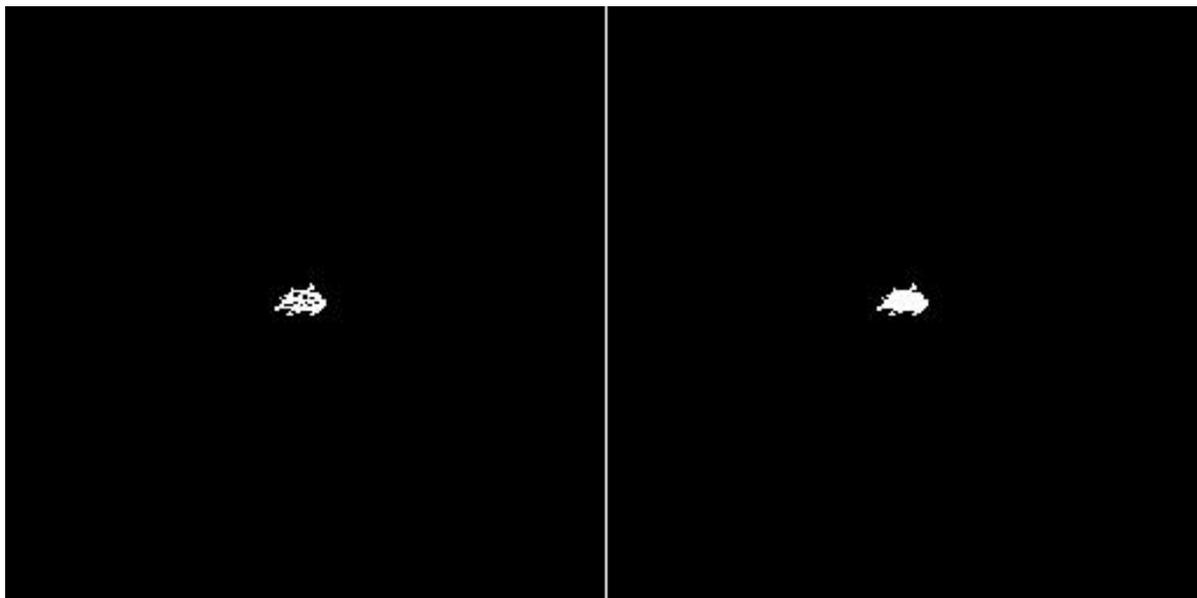
Após a redução da dimensão dos resultados das segmentações, o problema da divergência de dimensão das imagens foi solucionado, no entanto, ainda não é garantido que o problema da localização dos nódulos tenha sido resolvido, portanto, além desse pré-tratamento realizado nos resultados da aplicação das técnicas de segmentação, também foi necessário um pré-tratamento nas segmentações manuais. Para essas imagens, foi aplicado o mesmo processo de centralização dos nódulos baseado no centro da massa da imagem. A Figura 17 apresenta o resultado desse pré-tratamento em uma segmentação manual.

Figura 17 – Centralização do nódulo em imagem de segmentação manual



Resolvidos os problemas de divergência na localização do nódulo na imagem bem como a dimensão da imagem para a comparação, uma última etapa de pré-tratamento das imagens foi realizada. Essa etapa consistiu em preencher possíveis buracos presentes no nódulo segmentado com as técnicas com o objetivo de diminuir possíveis falsos resultados onde vazios num objeto corretamente segmentado sejam refletidos nas análises comparativas afetando-as negativamente. O preenchimento desses vazios foi feito utilizando a função *imfill* disponível no pacote do matlab, que preenche espaços vazios dentro de uma região segmentada. A Figura 18 mostra um exemplo de aplicação dessa etapa de preenchimento de espaços vazios.

Figura 18 – Preenchimento de vazios em resultado de segmentação por crescimento de regiões



Com todas as etapas de pré-tratamento concluídas, a próxima fase é a análise comparativa dos resultados em relação à segmentação manual correspondente.

3.3.2. Análise Comparativa

Após o tratamento tanto das imagens de resultado da aplicação dos métodos de segmentação escolhidos para o estudo nesse trabalho quanto das imagens da segmentação manual feita por especialistas, foi enfim possível fazer a análise comparativa dos resultados. As métricas escolhidas para realizar tal análise foram perímetro, área e número de pixels correspondentes nas imagens e, utilizando essas métricas, foram realizados testes em 19 imagens.

Para cada um dos resultados provenientes das técnicas computacionais utilizadas na segmentação das imagens foram feitas comparações com a segmentação manual feita por especialistas utilizando as métricas escolhidas. Todas essas comparações foram quantificadas em um valor percentual que corresponde à diferença entre o resultado da segmentação computacional e a segmentação manual.

4. RESULTADOS E DISCUSSÃO

Nesta seção serão apresentados os resultados obtidos com o desenvolvimento desse trabalho da forma descrita na seção 3 e esses resultados serão discutidos e analisados. As técnicas computacionais de segmentação utilizadas para análise nesse trabalho foram aplicadas em 19 imagens, sendo elas diferentes regiões de interesse de diversos nódulos.

Com a aplicação das técnicas escolhidas, foi possível observar diferentes resultados e situações que demandam atenção. A Figura 19 mostra o exemplo de uma imagem de tomografia computadorizada e a Figura 20 mostra as imagens resultado das técnicas de segmentação aplicadas na imagem da Figura 19, bem como a segmentação manual feita por especialistas. A Tabela 1 mostra os resultados da análise comparativa referente a esse caso.

Figura 19 – Imagem da fatia de interesse de tomografia computadorizada de Rótulo 0014 com nódulo indicado pela seta

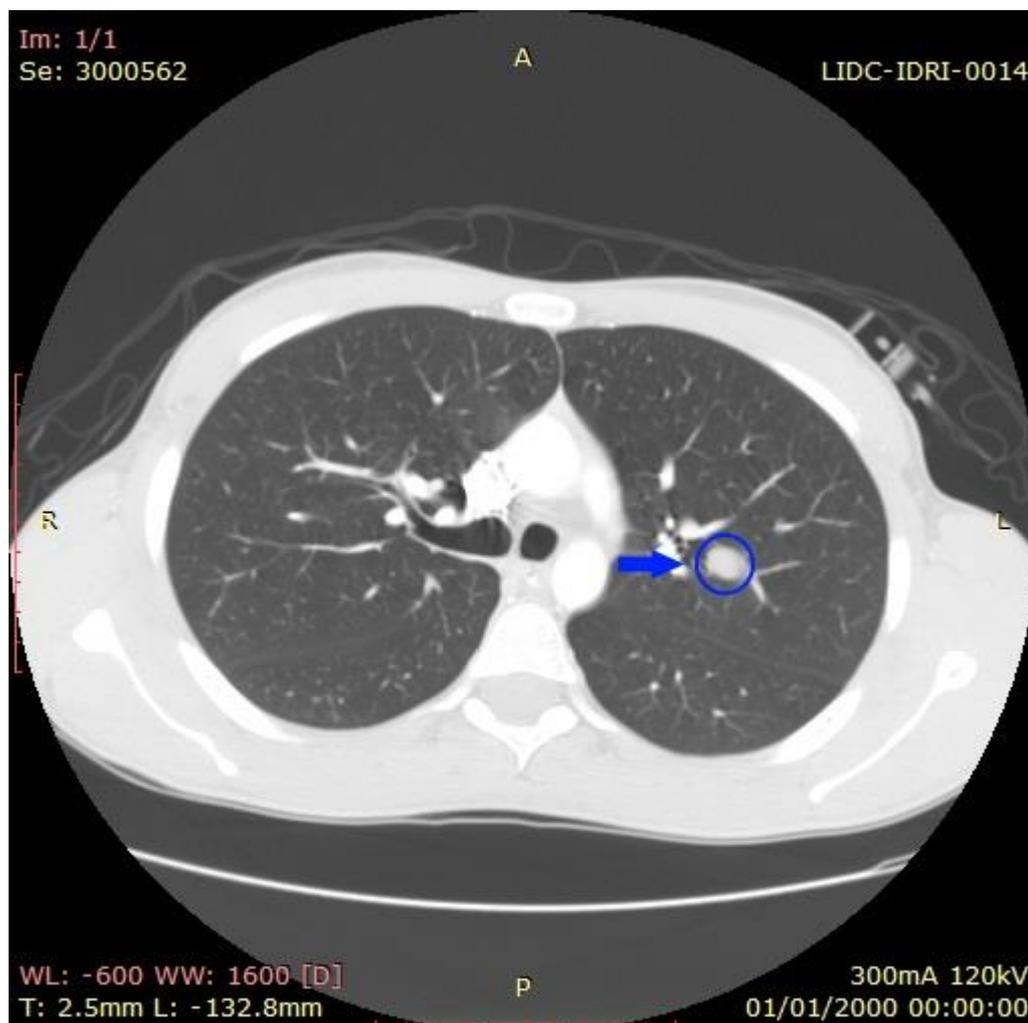


Figura 20 – Segmentação manual lado a lado com os resultados das técnicas de segmentação: A) Contorno Ativo baseado em borda; B) Contorno Ativo de Chan-Vese; C) Crescimento de Regiões com tolerância fixa; D) Crescimento de Regiões com tolerância variada

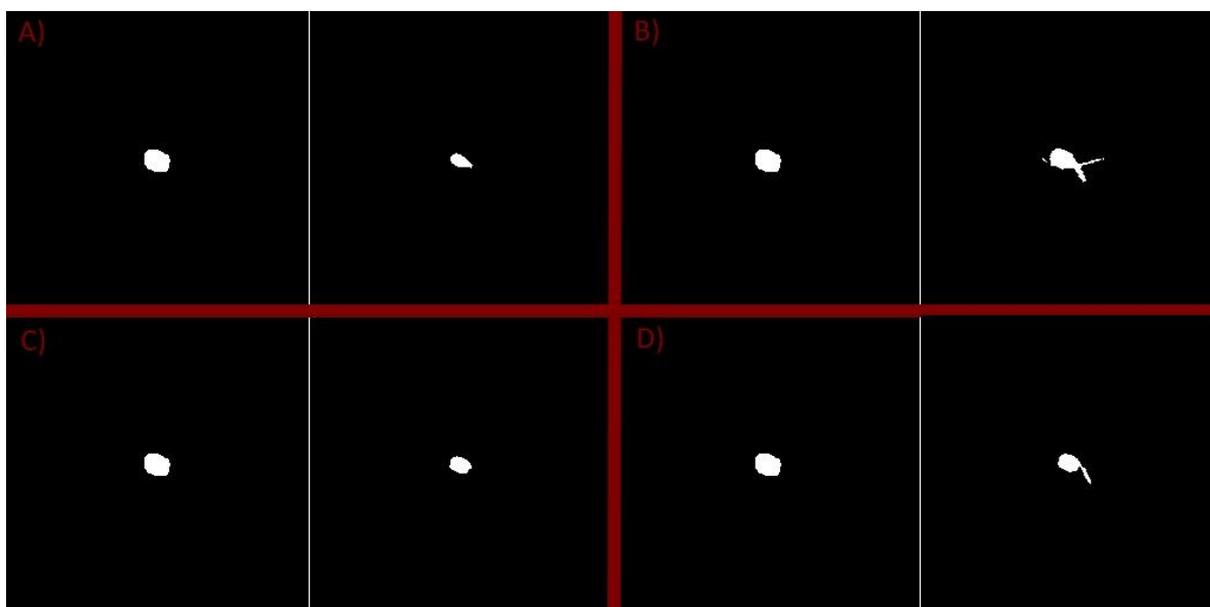


Tabela 1 – Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à fatia de interesse da tomografia computadorizada de rótulo 0014

	Perímetro	Área	Número de Pixels
Contorno ativo baseado em borda	-25,64%	-57,13%	-57,56%
Contorno ativo de Chan-Vese	+106,41%	+21,38%	-57,71%
Crescimento de Regiões com Tolerância Fixa	-19,23%	-41,82%	-42,15%
Crescimento de Regiões com Tolerância Variada	+39,74%	-22,72%	-41,51%

A Figura 21 apresenta mais um exemplo de imagem de tomografia computadorizada e a Figura 22 mostra o resultado da aplicação das técnicas de segmentação comparadas com a segmentação manual seguido da análise comparativa, apresentada pela Tabela 2. Nessa fatia do exame, a imagem contém

menos ruídos, o que influencia na acurácia das técnicas de segmentação, já que os objetos ficam, conseqüentemente, mais bem definidos.

Figura 21 – Imagem da fatia de interesse de tomografia computadorizada de Rótulo 0039 com nódulo indicado pela seta

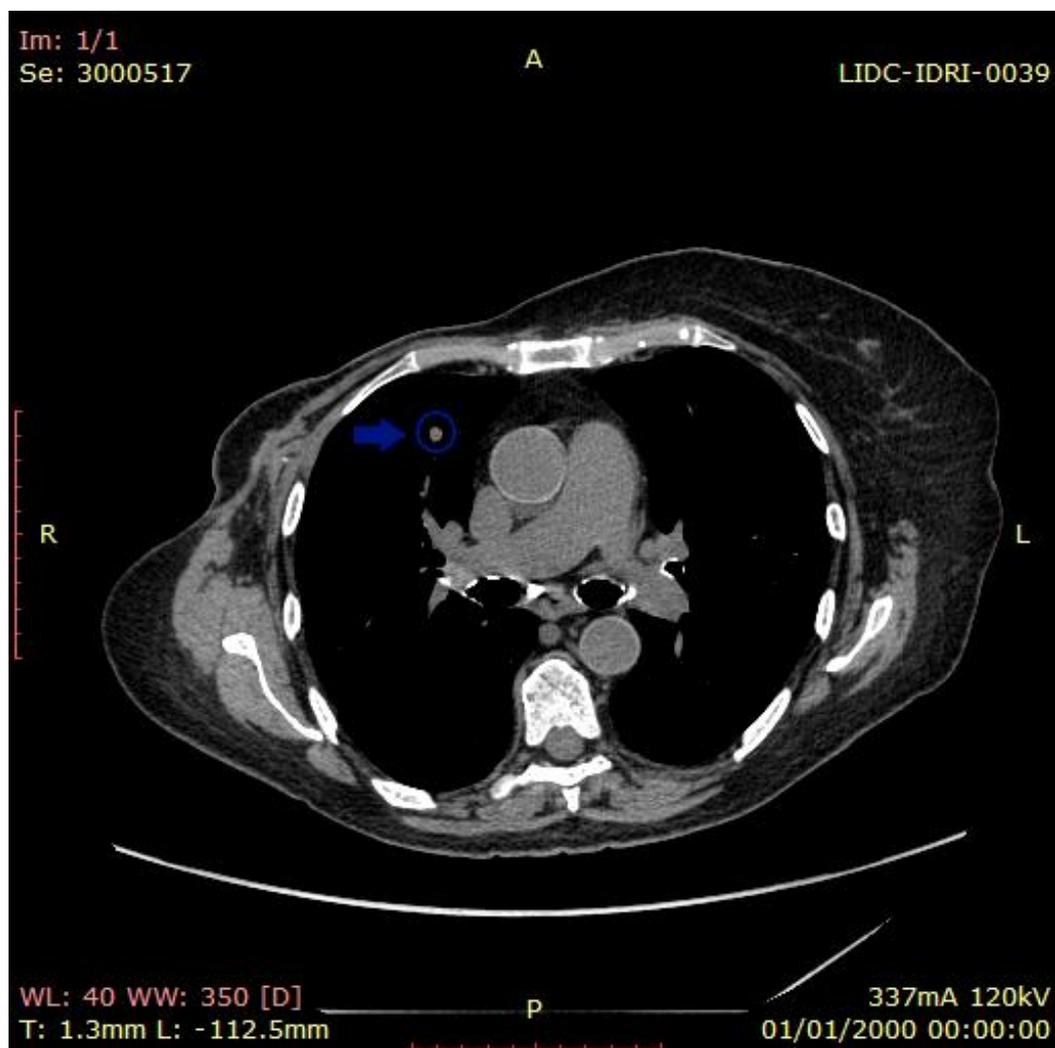


Figura 22 – Segmentação manual lado a lado com os resultados das técnicas de segmentação: A) Contorno Ativo baseado em borda; B) Contorno Ativo de Chan-Vese; C) Crescimento de Regiões com tolerância fixa; D) Crescimento de Regiões com tolerância variada

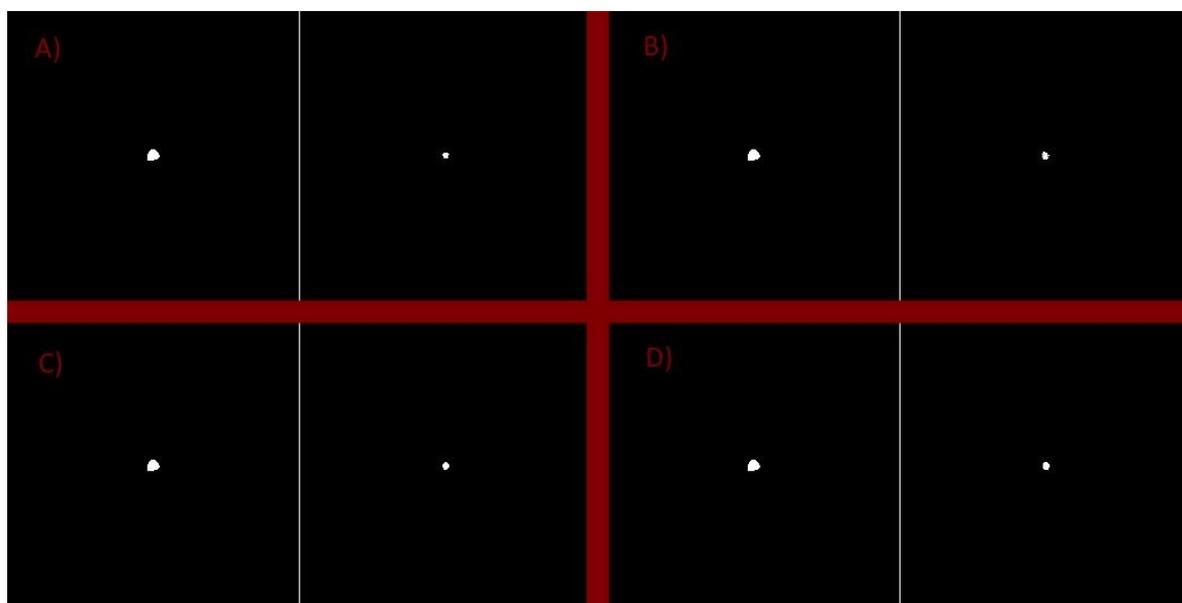
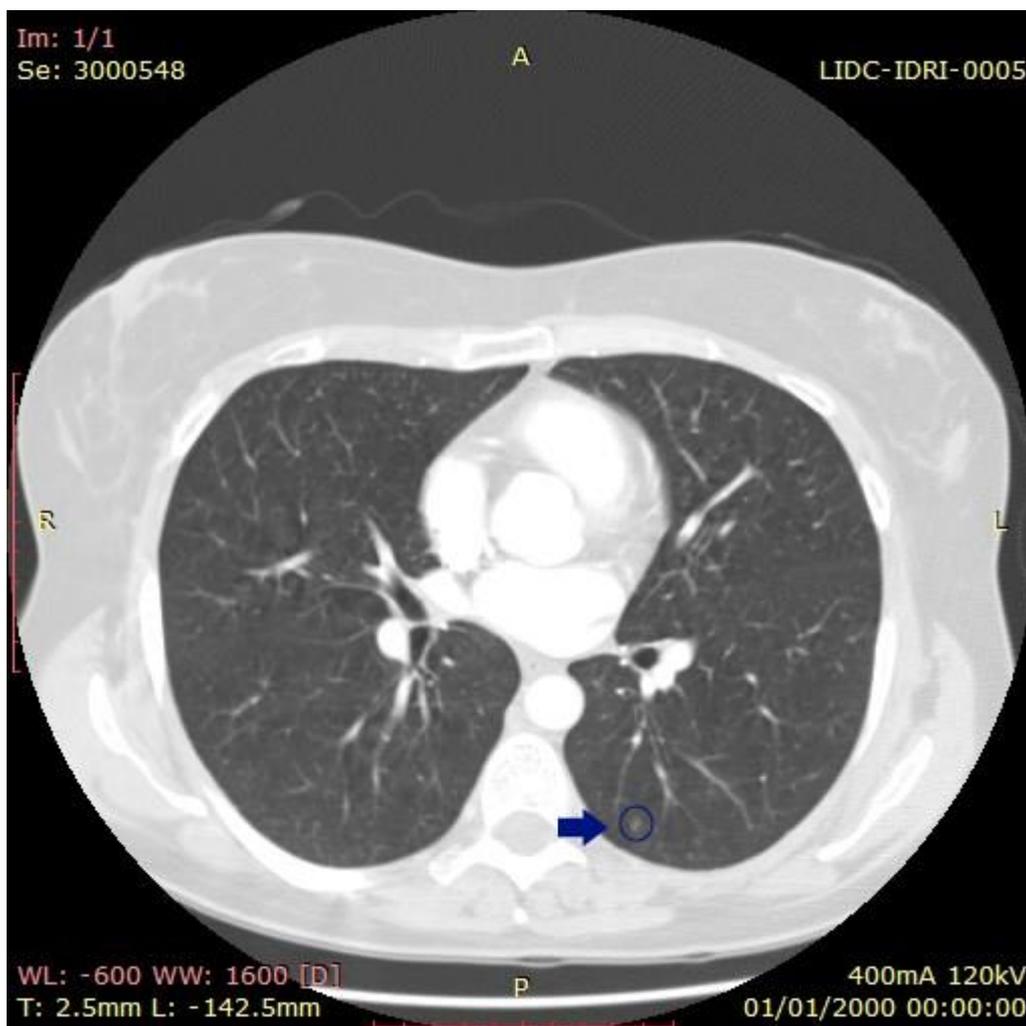


Tabela 2 - Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à fatia de interesse da tomografia computadorizada de rótulo 0039

	Perímetro	Área	Número de Pixels
Contorno ativo baseado em borda	-55,26%	-72,43%	-72,62%
Contorno ativo de Chan-Vese	-39,47%	-62,32%	-63,10%
Crescimento de Regiões com Tolerância Fixa	-42,11%	-62,61%	-63,10%
Crescimento de Regiões com Tolerância Variada	-42,11%	-58,21%	-58,33%

Ambos os exemplos mostrados até agora se tratavam de nódulos bem definidos, com pouca variação de níveis de cinza e tamanho razoável, contudo nem todos os casos apresentam essas características. A Figura 23 apresenta o caso de rótulo 0005.

Figura 23 – Imagem da fatia de interesse de tomografia computadorizada de Rótulo 0005 com nódulo indicado pela seta



Nesse caso, o tamanho do nódulo e sua falta de definição foram fatores que impediram o sucesso na segmentação pelos métodos de contorno ativo de Chan-Vese e crescimento de regiões com limiar fixo. As Figuras 24 e 25 mostram resultados da aplicação das técnicas de segmentação computadorizada do nódulo.

Figura 24 – Resultado da segmentação por contorno ativo geodésico na fatia de interesse do exame de rótulo 0005

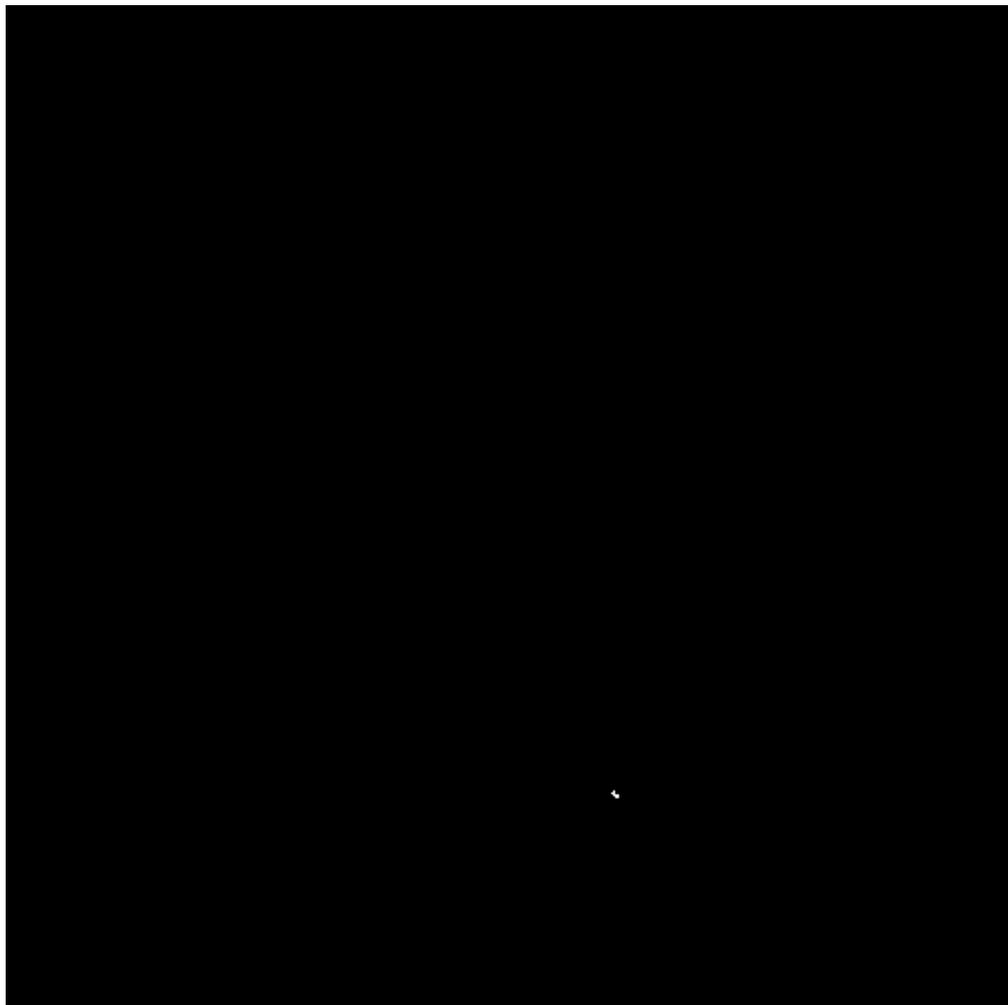
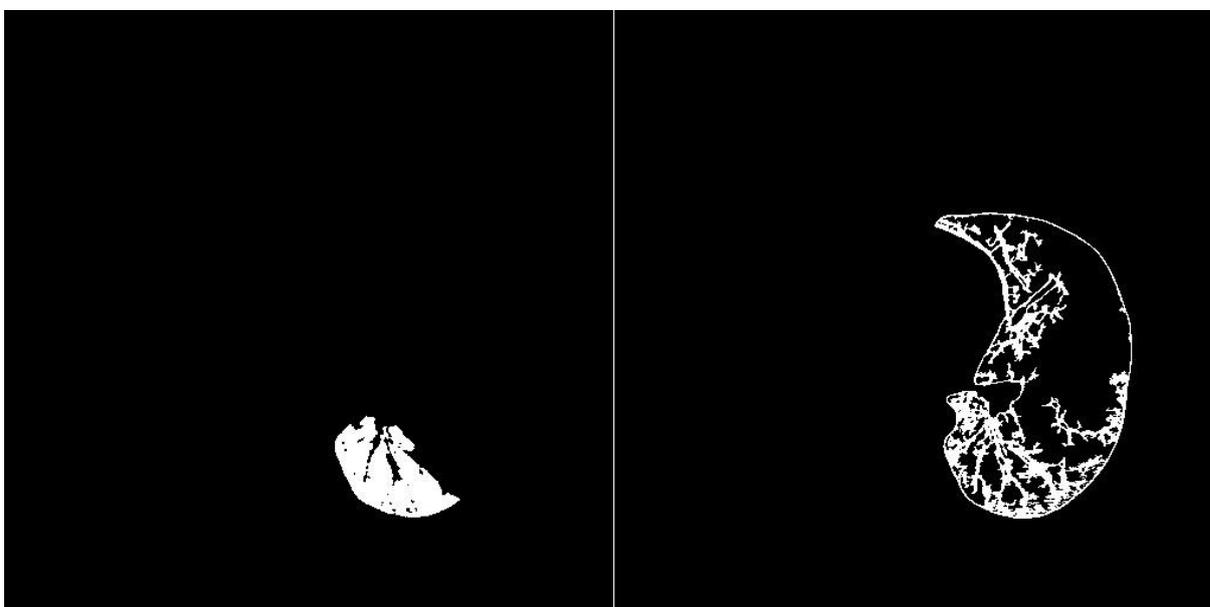


Figura 25 - Resultados das segmentações por contorno ativo de Chan-Vese (à esquerda) e crescimento de regiões com tolerância fixa (à direita) na fatia de interesse do exame de rótulo 0005



Para esse caso só foram comparados com a segmentação manual, o resultado dos métodos que detectaram de fato o nódulo presente na imagem. A Tabela 4 mostra os valores da análise dessas técnicas.

Tabela 3 - Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à fatia de interesse da tomografia computadorizada de rótulo 0005

	Perímetro	Área	Número de Pixels
Contorno ativo baseado em borda	-66,67%	-78,14%	-78,95%
Crescimento de Regiões com Tolerância Variável	-33,33%	-47,59%	-47,37%

Além de nódulos muito pequenos também existem imagens de fatias de interesse que contém nódulos não tão bem definidos e com baixa esfericidade. Em alguns desses casos, é possível que exista uma região de interesse com melhor definição e esfericidade, o que pode acrescentar eficácia para a segmentação. A Figura 26 mostra um nódulo do exame de rótulo 0018 em duas regiões de interesse diferentes e as Tabelas 5 e 6 apresentam a análise dos resultados para cada uma dessas regiões.

Figura 26 – Região de interesse 0 (à esquerda) e região de interesse 1 (à direita) do exame de rótulo 0018, onde a região de interesse 1 tem nódulo mais bem definido

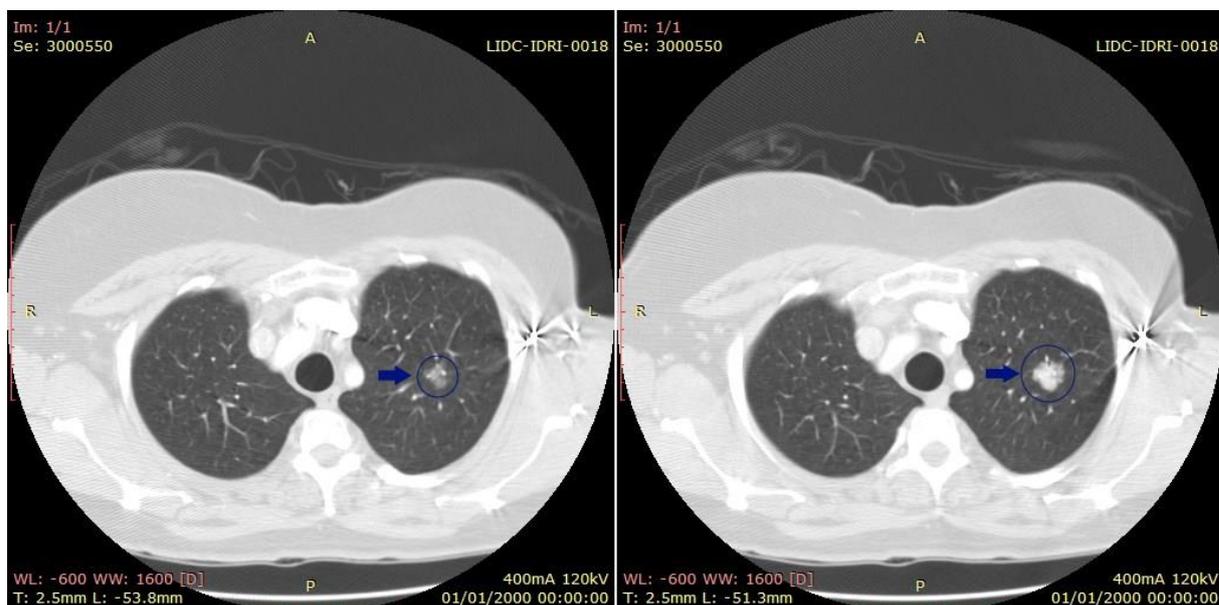


Tabela 4 - Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à região de interesse 0 da tomografia computadorizada de rótulo 0018

	Perímetro	Área	Número de Pixels
Contorno ativo baseado em borda	-33,33%	-58,50%	-66,67%
Contorno ativo de Chan-Vese	-12,50%	-34,93%	-48,52%
Crescimento de Regiões com Tolerância Fixa	-22,92%	-51,59%	-61,20%
Crescimento de Regiões com Tolerância Variada	-10,42%	-38,59%	-49,16%

Tabela 5 – Resultados da análise comparativa das segmentações computadorizadas com a segmentação manual referente à região de interesse 1 da tomografia computadorizada de rótulo 0018

	Perímetro	Área	Número de Pixels
Contorno ativo baseado em borda	12,12%	24,14%	-32,66%
Contorno ativo de Chan-Vese	-9,85%	-33,39%	-38,37%
Crescimento de Regiões com Tolerância Fixa	-40,15%	-60,36%	-61,42%
Crescimento de Regiões com Tolerância Variada	-27,27%	-54,06%	-55,28%

Nesse caso mostrado pelas Tabelas 5 e 6 foi possível notar que os métodos de contorno ativo tiveram comportamento melhor na região de interesse com nódulo mais bem definido, gerando menores valores absolutos de diferença entre o resultado dessas segmentações computadorizadas e a segmentação manual.

Com a aplicação das técnicas computacionais em 18 regiões de interesse de tomografias computadorizadas com presença de nódulos, pôde-se perceber que, de maneira geral, as técnicas de contorno ativo apresentaram melhores aproximações das segmentações manuais do que as técnicas de crescimento de regiões. A técnica de Chan-Vese se destacou por apresentar resultados muito próximos das segmentações manuais em perímetro e, em geral, foi uma das técnicas mais consistentes, não apresentando resultados completamente disjuntos das regiões dos nódulos, exceto nos casos onde o nódulo estava em contato com a parede torácica, dificultando a segmentação computacional. A técnica de contorno ativo geodésico, por sua vez, apresentou em 100% dos casos testados que tinham o valor 5 descrevendo a característica sutileza, o que significa que os nódulos eram menos sutis e mais óbvios nas imagens, diferença absoluta de perímetro de menos de 40%, o que é um resultado interessante, levando em consideração que as outras técnicas utilizadas não tiveram a mesma eficácia para esse tipo de imagens. Nas imagens com sutileza 3, a técnica de Chan-Vese se destacou obtendo resultados melhores, em geral, em todas as métricas em comparação às demais técnicas. Por outro lado, nos nódulos com malignidade definida como 3, que quer dizer que a probabilidade de o tumor representar um câncer é indeterminada, as técnicas, em geral, obtiveram resultados com diferença de métricas maior que 40%, com algumas exceções, inclusive, em algumas situações, não obtendo resultado algum, principalmente a técnica de contorno ativo geodésico. No entanto, nesse tipo de nódulos, o contorno ativo de Chan-Vese mostrou-se mais efetivo que os demais, de maneira geral, apresentando inclusive alguns resultados que mostram diferença de métricas de menos de 30%.

5. CONCLUSÕES E TRABALHOS FUTUROS

No presente trabalho foram analisadas técnicas computacionais de segmentação de imagens para que pudesse ser feita uma comparação da eficácia dessas diferentes técnicas aplicadas para a segmentação de nódulos em tomografias computadorizadas. A base de imagens apresenta, além nódulos presentes nas imagens nas quais as técnicas foram aplicadas, características que os classificam, marcadas por especialistas, bem como uma segmentação manual desses nódulos em cada região de interesse. As técnicas escolhidas para a análise comparativa feita nesse trabalho foram o modelo de Contorno Ativo de Chan-Vese, Contorno Ativo Geodésico e duas abordagens de Crescimento de Regiões.

Com as imagens de interesse selecionadas e as técnicas computacionais de segmentação escolhidas, este trabalho fez a aplicação dessas técnicas em cada uma das imagens de interesse para que pudesse ser feita a segmentação dos nódulos presentes nessas imagens. Com os resultados das segmentações pelas diferentes técnicas, as imagens então foram padronizadas para que pudesse ser feita a comparação com a segmentação manual feita por especialistas. Essas comparações foram feitas a partir de três métricas: Perímetro, Área e Número de Pixels correspondentes.

A base de imagens utilizadas contém 19 casos com objetos de interesse classificados como nódulos. No total são 40 nódulos e cada nódulo contém uma ou mais regiões de interesse. Nesse trabalho foram utilizados 15 diferentes nódulos e no total 19 regiões de interesse. Após a aplicação das técnicas nessas regiões, identificou-se que a técnica de Chan-Vese apresentou resultados próximos da segmentação manual em termos de perímetro e, em geral, foi uma das técnicas mais consistentes. A técnica de Contorno Ativo Geodésico apresentou diferença absoluta de perímetro de menos de 40% em todos os casos onde a característica sutileza tinha valor 5. Nos casos com sutileza 3 a técnica de Chan-Vese mostrou-se mais eficiente que as outras, em geral. Nos nódulos com malignidade 3, as técnicas em geral apresentaram diferenças absolutas da segmentação manual de mais de 40% no que diz respeito a todas as métricas de comparação utilizadas. Nesse último tipo de nódulos, a técnica de Chan-Vese mostrou-se mais efetiva que as demais e conseguiu até mesmo diferença absoluta de menos que 30% em alguns casos.

Com o desenvolvimento desse trabalho foi possível notar algumas características das técnicas computacionais avaliadas e alguns comportamentos diferentes em relação aos diferentes tipos de nódulos segmentados nas imagens de tomografias computadorizadas. Todavia, nem todas as técnicas em questão demonstraram padrões em seus comportamentos. No futuro, seria interessante uma análise com uma outra base de imagens e também técnicas diferentes para expandir esse estudo a um leque mais extenso de técnicas computacionais para que seja possível a segmentação de nódulos da forma mais automatizada e eficaz possível.

6. REFERÊNCIAS

- AL-TARAWNEH, M. S.. Lung Cancer Detection Using Image Processing Techniques. **Leonardo Electronic Journal Of Practices And Technologies**, Cluj- napoca, v. 11, n. 20, p.147-158, jan. 2012.
- ARMATO, S.G. III 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*, 38: 915-931. 2011
- BUSHBERG, J. T. et al. **The Essential Physics of Medical Imaging**. [s.l.]: Lippincott Williams & Wilkins, 2012.
- CAPOBIANCO, J.; JASINOWODOLINSKI, D.; SZARF, G.. Detection of pulmonary nodules by computer-aided diagnosis in multidetector computed tomography: preliminary study of 24 cases. **J. Bras. Pneumol.**, Brasília, v. 34, n. 1, p.27-33, jan. 2008.
- CASELLES, V.; KIMMEL, R.; SAPIRO, G.. Geodesic Active Contours. **International Journal Of Computer Vision**. Dordrecht, p. 61-79. fev. 1997.
- CHAN, T. F.; VESE, L. A.. Active Contour Without Edges. **IEEE Transactions on Image Processing** v. 10, p. 266-277, fev. 2001
- FERREIRA-JUNIOR, J. R.; OLIVEIRA, M. C.; AZEVEDO-MARQUES, P. M.. Cloud-Based NoSQL Open Database of Pulmonary Nodules for Computer-Aided Lung Cancer Diagnosis and Reproducible Research. **Journal Of Digital Imaging**. p. 716-729. dez. 2016.
- GONZALEZ, R. C.; WOODS, R. E.. **Digital Image Processing**. 3. ed. [s.l.] Pearson Education, 2011.
- INCA. **ABC do Câncer**: Abordagens Básicas para o Controle do Câncer. Rio de Janeiro, 2012.
- INCA. **PULMÃO**. Disponível em:<
<http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pulmao>>. Acesso em: 14 jul. 2017.
- KAGADIS, G. C.; LANGER, S. G.. **Informatics in Medical Imaging**. [s.l.]: Taylor & Francis Group, 2012.
- KANITKAR, S. S.; THOMBARE, N. D.; LOKHANDE, S. S.. **Detection of Lung Cancer Using Marker-Controlled Watershed Transform**. ICPC, 2015
- KUMAR, S. L. et al. Identification of Lung Cancer Cell using Watershed Segmentation on CT Images. **Indian Journal Of Science And Technology**. Gandhinagar, p. 1-4. jan. 2016.

KUMAR, V.; ABBAS, A. K.; ASTER, J. C.. **Pathologic Basis of Disease**. 9. ed. [s.l]: Elsevier Saunders, 2015. (Robbins and Cotran).

MARQUES-FILHO, O.; VIEIRA-NETO, H.. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999.

PEREIRA, C. M. F.; MELLO, F. L.; VERGARA, O.R.. **Contornos Ativos Geodésicos: Um Método Alternativo para Segmentação de Imagens de Satélite** XIII Simpósio Brasileiro de Sensoriamento Remoto **Anais...** Florianópolis, 2007

RUSS, J. C.. **The IMAGE PROCESSING Handbook**. 4. ed. [s.l]: CRC Press, 2002.

SHARMA, D.; JINDAL, G.. **Identifying Lung Cancer Using Image Processing Techniques**. ICCTAI v. 17, p. 872-880, 2011.