

UNIVERSIDADE FEDERAL DO PIAUÍ  
CAMPUS SENADOR HELVÍDIO NUNES DE BARROS  
CURSO BACHARELADO EM SISTEMAS DE INFORMAÇÃO

**SEGMENTAÇÃO AUTOMÁTICA DE CANDIDATOS A NÓDULOS PULMONARES  
EM IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX**

MARIA JAQUELANE CARVALHO DE MOURA

PICOS - PI

2016

MARIA JAQUELANE CARVALHO DE MOURA

SEGMENTAÇÃO AUTOMÁTICA DE CANDIDATOS A NÓDULOS PULMONARES EM  
IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Sistemas de Informação do Campus Senador Helvídio Nunes de Barros da Universidade Federal do Piauí como parte dos requisitos para obtenção do Grau de Bacharel em Sistemas de Informação.

Orientadora: Prof.<sup>a</sup> Ma. Alcilene Dalília de Sousa.

### FICHA CATALOGRÁFICA

Serviço de Processamento Técnico da Universidade Federal do Piauí  
Biblioteca José Albano de Macêdo

**M929:** Moura, Jaquelane Carvalho de  
Segmentação automática de candidatos a módulos  
pulmonares em imagens de tomografia computadorizada do  
tórax / Maria Jaquelane Carvalho de Moura. – 2016.  
CD-ROM : il.; 4 ¼ pol. (43 f.)

Monografia(Bacharelado em Sistemas de Informação) –  
Universidade Federal do Piauí, Picos, 2016.

Orientador(A): Prof.ª Ma. Alcilene Dalília de Sousa.

1. Imagens-Processamento Digital. 2. Imagens Médicas. 3.  
Pulmão-Câncer-Imagens. I. Título.

CDD 005

SEGMENTAÇÃO AUTOMÁTICA DE CANDIDATOS A NÓDULOS PULMONARES EM  
IMAGENS DE TOMOGRAFIA COMPUTADORIZADA DO TÓRAX

MARIA JAQUELANE CARVALHO DE MOURA


Monografia aprovada como exigência parcial para obtenção do grau de  
Bacharel em Sistemas de Informação.

Data de Aprovação

Picos - Pl. 18 de fevereiro de 2016

  
Prof. Ma. Alcilene Dalila de Sousa  
Orientador

  
Prof. Ma. Patricia Medyna Lauritzen de Lucena Drumond  
Membro

  
Prof. Me. Antonio Oseas de Carvalho Filho  
Membro

*Dedico este trabalho à minha mãe, Deusani de Carvalho Rocha, pelo seu amor e por ter investido no meu sonho não medindo esforços para me ajudar, e à minha grande amiga, Maria Rosália de Sousa Nobre, por sua generosidade e apoio.*

## **AGRADECIMENTOS**

À Deus, meu Pai bondoso e misericordioso, meu Salvador e Senhor, por seu amor eterno e incondicional.

À minha orientadora, Prof.<sup>a</sup> Ma. Alcilene Dalília de Sousa, pela paciência, compreensão, disponibilidade e grande contribuição para realização deste trabalho.

A todos os professores do curso de Sistemas de Informação. Em especial aos professores Patrícia Medyna Lauritzen de Lucena Drumond, Flávio Henrique Duarte de Araújo, Romuere Rodrigues Veloso e Silva, e Antonio Oseas de Carvalho Filho, pelos ensinamentos e apoio.

À Universidade Federal do Piauí pelas oportunidades concedidas e apoio à qualificação profissional e desenvolvimento de pesquisa.

A todos os amigos. Em especial, Maíla de Lima Claro, Nayara Holanda de Moura, Wallinson de Lima Silva e José Denes Lima Araújo, que colaboraram, direta ou indiretamente, para a realização deste trabalho, pelo carinho e aprendizado.

A toda minha família pelo amor, suporte e incentivo. Em especial aos meus pais, Miguel de Moura Lima e Deusani de Carvalho Rocha, pela dedicação e esforço em me proporcionar sempre o melhor e estarem ao meu lado em todos os momentos.

A Francisco Ramon Mendes Medeiros, meu namorado e melhor amigo, pelo seu amor, suas orações e auxílio.

Muito obrigada a todos!

“Depois de João ter sido preso, foi Jesus para a Galileia, pregando o evangelho de Deus, dizendo: O tempo está cumprido, e o reino de Deus está próximo; arrependei-vos e crede no evangelho.”

Marcos 1, 14-15

## RESUMO

O câncer de pulmão é o mais comum de todos os tumores malignos e uma das principais causas de morte evitáveis. Quanto mais cedo o diagnóstico ocorre, maiores são as chances de sobrevivência do paciente. Dessa forma, sistemas computacionais são utilizados para detectar automaticamente nódulos pulmonares a partir do processamento de imagens de Tomografia Computadorizada do tórax, permitindo ao especialista responsável lidar com um grande volume de informações dos pacientes e fornecer um diagnóstico eficiente. Esses sistemas se apoiam em algum método de segmentação. A segmentação é responsável por isolar partes de uma imagem; neste caso, as estruturas que podem ser nódulos. Essas estruturas (candidatos a nódulos pulmonares) são analisadas e classificadas como nódulos ou não-nódulos. Este trabalho apresenta dois algoritmos de segmentação automática de candidatos a nódulos pulmonares em imagens de Tomografia Computadorizada do tórax. Os algoritmos desenvolvidos possuem três etapas principais: extração do parênquima pulmonar, melhoramento das estruturas internas ao parênquima pulmonar e segmentação dos candidatos a nódulos. Os testes foram realizados utilizando um conjunto de imagens da base LIDC-IDRI, contendo 1029 nódulos, dos quais o primeiro algoritmo localizou 93% dos nódulos e o segundo algoritmo localizou 92%.

**Palavras-chave:** Processamento Digital de Imagens, Imagens Médicas, Câncer de Pulmão.



## **ABSTRACT**

The lung cancer is the most common of all malignant tumors and one of the main avoidable death causes. The more early the diagnosis is made, larger they are the chances of the patient's survival. In that way, computational systems are used to detect lung nodules automatically starting from the processing of Computerized Tomography images of the thorax, allowing to the responsible specialist to work with a great volume of the patient information and to supply an efficient diagnosis. Those systems are supported by some segmentation method. The segmentation is responsible for isolating parts of an image; in this case, the structures may be nodules. Those structures (candidates to lung nodules) are analyzed and classified as nodules or no-nodules. This work presents two algorithms of automatic segmentation of candidates to lung nodules in Computerized Tomography images of the thorax. The developed algorithms have three main steps: extraction of the lung parenchyma, improvement of the internal structures to the lung parenchyma and segmentation of candidates to nodules. The tests were made using a group of images of the LIDC-IDRI database, containing 1029 nodules, of which the first algorithm located 93% of the nodules and the second algorithm located 92%.

**Keywords:** Digital Image Processing, Medical Images, Lung Cancer.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1</b> - Principais estruturas encontradas em um exame de TC.....	16
<b>Figura 2</b> - Fechamento de um buraco por Rolling Ball.....	20
<b>Figura 3</b> - Exemplo de imagem da base LIDC-IDRI.....	21
<b>Figura 4</b> - Etapas do algoritmo de segmentação.....	24
<b>Figura 5</b> - (a) Imagem de TC, (b) Imagem filtrada.....	25
<b>Figura 6</b> - Imagem binária.....	26
<b>Figura 7</b> - (a) Máscara, (b) Segmentação com a máscara, (c) Parênquima reconstruído, (d) Segmentação do parênquima.....	27
<b>Figura 8</b> - (a) Parênquima pulmonar, (b) Candidatos a nódulos pulmonares.....	28
<b>Figura 9</b> - (a) Nódulo na imagem de TC, (b) Nódulo entre os candidatos.....	29
<b>Figura 10</b> - Etapas do algoritmo de segmentação.....	30
<b>Figura 11</b> - (a) Imagem de TC, (b) Imagem binária.....	31
<b>Figura 12</b> - (a) Caixa torácica, (b) Região exterior a caixa torácica, (c) Inversão da imagem anterior, (d) Extração da caixa torácica.....	31
<b>Figura 13</b> - Passos da extração do parênquima pulmonar.....	32
<b>Figura 14</b> - Reconstrução do parênquima pulmonar.....	33
<b>Figura 15</b> - (a) Parênquima pulmonar, (b) Imagem binária com os candidatos, (c) Segmentação dos candidatos.....	33
<b>Figura 16</b> - (a) Nódulo na imagem de TC, (b) Nódulo entre os candidatos.....	34
<b>Figura 17</b> - (a) Imagem de TC com nódulo, (b) Nódulo encontrado.....	37
<b>Figura 18</b> - (a) Imagem de TC com nódulo, (b) Nódulo encontrado.....	37
<b>Figura 19</b> - (a) Imagem de TC com nódulo, (b) Nódulo encontrado.....	37
<b>Figura 20</b> - (a) Imagem de TC com nódulo, (b) Nódulo não encontrado.....	38
<b>Figura 21</b> - (a) Imagem de TC com nódulo, (b) Nódulo não encontrado.....	39
<b>Figura 22</b> - (a) Imagem de TC com nódulo, (b) Nódulo não encontrado.....	39

## LISTA DE TABELAS

<b>Tabela 1</b> - Resultado da segmentação.....	35
<b>Tabela 2</b> - Tempo médio de execução em segundos por imagem de cada algoritmo.....	35

## LISTA DE ABREVIATURAS E SIGLAS

ACACM	<i>Adaptive Crisp Active Contour Models</i>
ACR	<i>American College of Radiology</i>
CAD	<i>Computer-Aided Detection</i>
CADx	<i>Computer-Aided Diagnosis</i>
DICOM	<i>Digital Imaging Communications in Medicine</i>
INCA	Instituto Nacional do Câncer
IDRI	<i>Image Database Resource Initiative</i>
LIDC-IDRI	<i>Lung Image Database Consortium</i>
LIDC	<i>Lung Image Database Consortium</i>
NEMA	<i>National Electrical Manufactures Association</i>
GB	<i>Gigabyte</i>
GHz	<i>GigaHertz</i>
GLCM	<i>Gray Level Cooccurrence Matrix</i>
GNG	<i>Growing Neural Gas</i>
HD	<i>Hard Disk</i>
QT	<i>Quality Threshold Clustering</i>
RAM	<i>Random Access Memory</i>
SIM	<i>Spatial Interdependence Matrix</i>
SVM	<i>Support Vector Machine</i>
TC	Tomografia Computadorizada
VIF	<i>Visual Information Fidelity</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>13</b>
<b>1.1</b>	<b>Objetivo .....</b>	<b>14</b>
<b>1.2</b>	<b>Organização do Documento.....</b>	<b>14</b>
<b>2</b>	<b>ESTADO DA ARTE .....</b>	<b>15</b>
<b>2.1</b>	<b>Nódulo Pulmonar .....</b>	<b>15</b>
<b>2.2</b>	<b>Tomografia Computadorizada .....</b>	<b>15</b>
<b>2.3</b>	<b>Sistemas de Diagnóstico do Câncer de Pulmão.....</b>	<b>16</b>
<b>2.4</b>	<b>Processamento Digital de Imagens.....</b>	<b>17</b>
2.4.1	Filtro Wiener.....	17
2.4.2	Segmentação por Limiarização.....	18
2.4.3	Método de Otsu.....	18
2.4.4	Operação Morfológica de Fechamento.....	19
<b>2.5</b>	<b>Base de Imagens LIDC-IDRI.....</b>	<b>20</b>
<b>2.6</b>	<b>Trabalhos Relacionados .....</b>	<b>21</b>
<b>3</b>	<b>METODOLOGIA.....</b>	<b>24</b>
<b>3.1</b>	<b>Segmentação Automática de Candidatos a Nódulos Pulmonares com o Uso do Filtro Wiener e Limiar Fixo.....</b>	<b>24</b>
3.1.1	Eliminação de Ruídos .....	24
3.1.2	Segmentação do Parênquima Pulmonar .....	25
3.1.3	Segmentação dos Candidatos a Nódulos .....	27
<b>3.2</b>	<b>Segmentação Automática de Candidatos a Nódulos Pulmonares com o Uso do Método de Otsu .....</b>	<b>30</b>
3.2.1	Cálculo do Limiar .....	30
3.2.2	Extração da Caixa Torácica .....	31
3.2.3	Extração e Reconstrução do Parênquima .....	32
3.2.4	Segmentação dos Candidatos .....	33
<b>4</b>	<b>RESULTADOS E DISCUSSÕES.....</b>	<b>35</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS.....</b>	<b>40</b>
<b>5.1</b>	<b>Trabalhos Futuros .....</b>	<b>40</b>
<b>5.2</b>	<b>Publicação Obtida.....</b>	<b>41</b>
	<b>REFERÊNCIAS.....</b>	<b>42</b>

## 1 INTRODUÇÃO

O câncer de pulmão é o mais comum de todos os tumores malignos e uma das principais causas de morte, apresentando aumento de 2% por ano na sua incidência mundial. Na maioria dos casos (cerca de 90%), o câncer de pulmão está associado ao consumo de tabaco. A sobrevivência média cumulativa total em cinco anos varia entre 13 e 21% em países desenvolvidos e entre 7 e 10% nos países em desenvolvimento (INCA, 2015). Dessa forma, o câncer de pulmão se destaca por apresentar uma elevada taxa de incidência e de mortalidade.

A Tomografia Computadorizada (TC) é a modalidade de imagem utilizada para diagnosticar e caracterizar nódulos pulmonares. Comparada à convencional radiografia do tórax, a imagem de TC apresenta alta resolução e permite detectar nódulos pequenos e/ou com baixo contraste (LEE; KOUSANI; HU, 2012). Devido a boa qualidade, a TC do tórax facilita a detecção e o acompanhamento da evolução dos nódulos pulmonares.

O diagnóstico precoce do câncer de pulmão através de TC em grupos de risco, como fumantes e ex-fumantes com níveis elevados de tabaco, pode afetar os resultados, contribuindo para aumentar as chances de sobrevivência dos pacientes (SANTOS *et al.*, 2014). No entanto, é demorado para os radiologistas identificarem um grande número de lesões anormais a partir das imagens de TC. Portanto, o problema de reconhecer lesões automaticamente em imagens de TC do pulmão para auxiliar os radiologistas no diagnóstico de doenças pulmonares tem recebido bastante atenção nos últimos anos (MA *et al.*, 2015).

Várias pesquisas surgiram com o objetivo de desenvolver sistemas para a Detecção Assistida por Computador (*Computer-Aided Detection - CAD*) e para o Diagnóstico Assistido por Computador (*Computer-Aided Diagnosis - CADx*) do câncer de pulmão. Esses sistemas ajudam os especialistas a lidar com um grande volume de informações dos pacientes e fornecer um diagnóstico eficiente.

A detecção automática de nódulos pulmonares depende da segmentação, que é responsável por fornecer as regiões da imagem que serão analisadas e classificadas como nódulos. Uma boa técnica de segmentação deve ser capaz de incluir o maior número possível de nódulos presentes nas imagens e ao mesmo tempo excluir regiões desnecessárias. Deste modo, a segmentação reduz a região de interesse, facilitando o processamento. Este trabalho pretende contribuir na detecção automática de nódulos pulmonares, fornecendo uma metodologia para segmentar os candidatos a nódulos em imagens de TC.

## **1.1 Objetivo**

O objetivo deste trabalho é segmentar de forma automática os candidatos a nódulos pulmonares em imagens de Tomografia Computadorizada do tórax, utilizando técnicas de Processamento Digital de Imagens, a fim de auxiliar o profissional da área médica no diagnóstico do câncer de pulmão.

## **1.2 Organização do Documento**

Este trabalho está organizado em 5 capítulos, incluindo o presente. O capítulo 2 contém o embasamento teórico, necessário ao desenvolvimento deste trabalho e à compreensão do mesmo, onde são abordados o conceito de nódulo pulmonar, Tomografia Computadorizada, os sistemas de diagnóstico de câncer de pulmão, técnicas de Processamento Digital de Imagens, a base de imagens utilizada no trabalho e alguns trabalhos relacionados ao reconhecimento automático de nódulos pulmonares em imagens médicas.

O capítulo 3 descreve a metodologia, apresentando em detalhes como as técnicas descritas no capítulo anterior foram utilizadas para segmentar os candidatos a nódulos pulmonares nas imagens de TC. No capítulo 4, os resultados obtidos com os algoritmos são apresentados e discutidos. Por fim, o capítulo 5 contém as considerações finais para este trabalho, as perspectivas de trabalhos futuros e a publicação obtida.

## 2 ESTADO DA ARTE

Neste capítulo, será apresentado o embasamento teórico utilizado no desenvolvimento deste trabalho e necessário para a compreensão do mesmo. Serão abordados os seguintes tópicos: nódulo pulmonar, Tomografia Computadorizada, sistemas de diagnóstico de câncer de pulmão, técnicas de Processamento Digital de Imagens, a base de imagens LIDC-IDRI e alguns trabalhos relacionados.

### 2.1 Nódulo Pulmonar

Segundo o Instituto Nacional de Câncer (INCA, 2015), “câncer é o nome dado a um conjunto de mais de 100 doenças que têm em comum o crescimento desordenado de células que invadem os tecidos e órgãos, podendo espalhar-se para outras regiões do corpo”. O câncer de pulmão é um dos tipos de câncer mais comuns e a sua manifestação se dá através da formação de nódulos pulmonares.

Um nódulo é uma pequena massa de tecido que geralmente se forma em resposta à lesões, podendo ser benigno ou maligno. Um nódulo benigno é um tumor que surge e não se espalha para outras partes do corpo, tende a crescer mais lentamente e causa menos problemas à saúde do que um nódulo maligno (CARVALHO FILHO, 2013). Em ambos os casos, o acompanhamento médico é requerido.

Para Netto (2010), o nódulo pulmonar é uma lesão única de forma esférica, menor que 3 cm e não acompanhada de quaisquer lesões sugestiva de metástase<sup>1</sup> ou invasão de estruturas vizinhas.

### 2.2 Tomografia Computadorizada

A Tomografia Computadorizada surgiu em 1972. Seus criadores são Godfrey e Allan Cormack. Basicamente, eles desenvolveram uma máquina que emite Raios X enquanto gira 360° em torno do paciente. A TC é um exame que fornece imagens ou fatias de cortes do corpo do paciente, permitindo aos médicos realizar o diagnóstico por imagem.

De acordo com Santos (2011), a Tomografia Computadorizada possui melhor precisão e sensibilidade, além de não apresentar uma imagem com sobreposição de tecidos, comparada

---

<sup>1</sup> Migração de doença de um órgão a outro a que não está diretamente ligado anatomicamente.



a radiografia tradicional. A imagem de TC possui um maior número de detalhes e um maior número de níveis de cinza do que um exame de raio X convencional. O efeito visual é monocromático, pois são mostrados apenas os vários níveis de cinza, que vão do preto ao branco. A Figura 1 mostra as principais estruturas encontradas em um exame de TC.




Figura 1 - Principais estruturas encontradas em um exame de TC  
Fonte: (SANTOS, 2011)

### 2.3 Sistemas de Diagnóstico do Câncer de Pulmão

O diagnóstico de câncer de pulmão pode ser feito por meio de Tomografias Computadorizadas do tórax. A análise das TC's normalmente é feita por especialistas. Porém várias pesquisas têm sido realizadas no sentido de desenvolver sistemas computacionais que auxiliem os especialistas no diagnóstico de câncer de pulmão.

Esses sistemas fornecem uma segunda opinião para a tomada de decisão, contribuindo para melhorar a consistência da interpretação das imagens. Existem dois tipos de aplicações desses sistemas. Um é o auxílio à detecção de lesões, conhecido como CAD, e o outro é o auxílio ao diagnóstico de lesões, conhecido como CADx. Ambos, podem ser aplicados para todos os tipos de exames de todas as partes do corpo (NASCIMENTO, 2012).

A detecção dos nódulos pulmonares, como observado na literatura, é feito na maioria das vezes mediante o uso das técnicas de segmentação, extração e seleção de características e classificação. A segmentação tem como objetivo isolar partes de uma imagem e, nesse caso,

essas partes referem-se aos candidatos a nódulos pulmonares. Após a segmentação dos candidatos a nódulos, ocorre a extração e seleção de características como forma, textura, especulação, diâmetro, entre outras, que são os parâmetros de entrada para um modelo de classificação que permita a classificação dos candidatos em nódulo ou não nódulo.

## 2.4 Processamento Digital de Imagens

Dentre as técnicas de Processamento Digital de Imagens que foram utilizadas no desenvolvimento dos algoritmos de segmentação de candidatos a nódulos pulmonares proposto neste trabalho, estão o filtro *wiener*, a segmentação por limiarização, o método de *Otsu* e a operação morfológica de fechamento.

### 2.4.1 Filtro Wiener

O filtro wiener é um filtro adaptativo de suavização que realiza a filtragem com base no cálculo da média e da variância da vizinhança de cada pixel (SHAO; CAO; LIU, 2012). Esse filtro permite suavizar as imagens, eliminando os ruídos (altas frequências). As Equações 1 e 2 são utilizadas para calcular a média e a variância, respectivamente, e a Equação 3 realiza a filtragem.

$$u = \frac{1}{M*N} \sum_{x,y \in s} I(x, y) \quad (1)$$

$$\sigma^2 = \frac{1}{M*N} \sum_{x,y \in s} (I(x, y) - u)^2 \quad (2)$$

$$II(x, y) = u + \frac{\sigma^2 - u^2}{\sigma^2} (I(x, y) - u) \quad (3)$$

Nessas Equações as letras *M* e *N* representam as dimensões da imagem, ou seja, altura e largura. A imagem é representada pela letra *I* e as letras *x* e *y* são as coordenadas dos pixels. Na Equação 3, *II* representa a nova imagem.

### 2.4.2 Segmentação por Limiarização

A segmentação tem como objetivo reduzir uma imagem aos objetos que a compõe (BRAZ JÚNIOR, 2006). A limiarização consiste em separar as regiões de uma imagem em duas classes (o fundo e o objeto) com base em um valor de limiar ( $T$ ) pré-estabelecido. A limiarização produz uma imagem binária e, por isso, muitas vezes o processo é chamado de binarização. Dada uma imagem, aos pixels cujo tom de cinza é maior ou igual a  $T$  é atribuído o valor 1 e aos demais é atribuído o valor 0. O valor  $T$  pode ser definido com base no tom de cinza do ponto  $(x, y)$  e, nesse caso, o limiar é chamado global, ou pode ser definido com base em alguma propriedade desse ponto e o limiar é chamado local, e se for definido dependendo das coordenadas espaciais de  $(x, y)$ , o limiar é chamado dinâmico ou adaptativo (MARQUES; VIEIRA, 1999).

### 2.4.3 Método de Otsu

O método de *Otsu* (OTSU, 1979) é um método de limiarização global ótima baseado na maximização da variância entre as classes de pixels da imagem. Esse método compreende as seguintes etapas:

- I. O histograma da imagem é tratado como uma função de probabilidade, como mostra a Equação 4. Em que,  $q = 0, 1, 2, \dots, L-1$ ,  $n$  = número total de pixels da imagem,  $n_q$  = número de pixels com intensidade  $r_q$ ,  $L$  = número total dos possíveis níveis de intensidade da imagem;

$$p_r(r_q) = \frac{n_q}{n} \quad (4)$$

- II. Um valor  $T$  para o limiar é escolhido tal que,  $C_1$  seja a classe de pixels com níveis entre  $[0, T]$  e  $C_2$  seja a classe de pixels com níveis entre  $[T+1, L-1]$ ;
- III. A probabilidade de um pixel pertencer a classe  $C_1$  é dada pela Equação 5:

$$P_1(T) = \sum_{i=0}^T p_i \quad (5)$$

IV. A probabilidade de um pixel pertencer a classe  $C_2$  é dada pela Equação 6:

$$P_2(T) = \sum_{i=T+1}^{L-1} p_i = 1 - P_1(T) \quad (6)$$

V. A intensidade média dos pixels atribuídos a classe  $C_1$  é dada pela Equação 7:

$$m_1(T) = \frac{1}{P_1(T)} \sum_{i=0}^T ip_i \quad (7)$$

VI. A intensidade média dos pixels atribuídos a classe  $C_2$  é dada pela Equação 8:

$$m_2(T) = \frac{1}{P_2(T)} \sum_{i=T+1}^{L-1} ip_i \quad (8)$$

VII. A intensidade média global de todo o histograma é dada pela Equação 9:

$$m_G = \sum_{i=0}^{L-1} ip_i \quad (9)$$

VIII. O valor  $T$  é escolhido de forma que maximize a variância entre as classes em relação a variância global, como mostra a Equação 10:

$$\sigma^2(T) = P_1(m_1 - m_G)^2 + P_2(m_2 - m_G)^2 \quad (10)$$

A cada iteração um novo valor é atribuído a  $T$  e a variância é calculada. O valor escolhido para o limiar  $T$  é aquele que produzir a variância máxima.

#### 2.4.4 Operação Morfológica de Fechamento

Após a extração do parênquima pulmonar é comum que nódulos conectados a caixa torácica sejam perdidos. Por isso, é importante reconstruir o parênquima para recuperar esses nódulos. A reconstrução pode ser feita utilizando uma técnica denominada *Rolling Ball*.

De acordo com Netto (2010), essa técnica utiliza operações morfológicas de fechamento com um elemento estruturante circular, ao longo do contorno do pulmão, fazendo

com que as concavidades onde este elemento não consiga entrar, sejam reconstruídas. A operação de fechamento entre uma imagem  $A$  e um elemento estruturante  $B$  é dada por  $A \cdot B = (A \oplus B) \ominus B$ , onde  $(A \oplus B)$  é uma operação de dilatação dada por  $(A \oplus B) = \{c | c = a + b, a \in A, b \in B\}$  e  $(A \ominus B)$  é uma operação de erosão dada por  $(A \ominus B) = \{x | x + b \in A \text{ para todo } b \in B\}$ . A Figura 2 ilustra o uso da técnica *Rolling Ball* em um buraco.




Figura 2 - Fechamento de um buraco por Rolling Ball  
Fonte: (NETTO, 2010)

## 2.5 Base de Imagens LIDC-IDRI

No desenvolvimento deste trabalho foi utilizado a coleção de imagens *Lung Image Database Consortium - LIDC-IDRI* (GINNEKEN *et al.*, 2010), por ser uma base que preserva a identidade dos pacientes e apresenta a avaliação dos exames realizada por quatro especialistas. A base é um recurso internacional acessível via *web* para o desenvolvimento, treinamento e avaliação do diagnóstico de sistemas para a detecção e diagnóstico de câncer de pulmão.

A base LIDC-IDRI é disponibilizada pelo *National Cancer Institute of EUA* (NCI), sendo resultado da associação entre o consórcio de instituições conhecido como *Lung Image Database Consortium* (LIDC) e o *Image Database Resource Initiative* (IDRI). A base contém 1012 exames com uma quantidade variável de fatias por exame e um arquivo individual para cada exame contendo as marcações feitas pelos especialistas. O arquivo especifica as coordenadas dos nódulos, as fatias que o compõe e as características dos nódulos. As imagens estão no formato DICOM (*Digital Imaging Communications in Medicine*).

O padrão DICOM foi criado pela ACR (*American College of Radiology*) e pelo NEMA (*National Electrical Manufactures Association*) em 1983, com o objetivo de padronizar o formato das imagens e suas informações, usados entre os diferentes fabricantes

de TC, de ressonância magnética nuclear, ultrassom e etc., e assim facilitar a troca de informações entre médicos e especialistas que se encontram em localidades distintas (NEMA, 2016). A Figura 3 mostra um exemplo de imagem da base LIDC-IDRI.




Figura 3 - Exemplo de imagem da base LIDC-IDRI  
Fonte: (GINNEKEN et al., 2010)

As imagens possuem até 16 bits por voxel (representação tridimensional de um pixel) e dimensões de 512 X 512. O desafio da detecção se deve ao fato das imagens terem sido obtidas por tomógrafos distintos.

## 2.6 Trabalhos Relacionados

A literatura possui diversos trabalhos voltados para a análise de imagens médicas com o objetivo de detectar doenças pulmonares. Um algoritmo de detecção automática de nódulos pulmonares solitários é proposto por Shao, Cao e Liu (2012), contendo as seguintes etapas: pré-processamento, segmentação do parênquima pulmonar, localização dos candidatos a nódulos, extração das características e classificação por meio de *Support Vector Machine* (SVM). Esse sistema obteve uma sensibilidade de 89,5%, precisão de 90,4% e especificidade de 90,5%.

Netto *et al.* (2012), apresenta uma metodologia para segmentação automática de nódulos pulmonares, que consiste em extrair o parênquima pulmonar, aplicar o algoritmo de

aprendizagem competitiva *Growing Neural Gas* (GNG) para obter as estruturas internas ao parênquima pulmonar (nódulos, vasos sanguíneos, brônquios, etc.), separar as estruturas semelhantes a nódulos pulmonares de outras estruturas, tais como vasos e brônquios, e por fim, classificar as estruturas utilizando SVM. Os resultados experimentais conferiram a essa metodologia sensibilidade de 86%, especificidade de 91%, precisão de 91% e taxa de falso positivo por exame de 0,138.

Em Jacobs *et al.* (2013) é apresentado um sistema de detecção automática para nódulos pulmonares semi-sólidos. As etapas que compõe esse sistema são a segmentação dos candidatos a nódulos, o cálculo de características dos candidatos (como intensidade, textura, características de forma e contexto) e o uso de classificadores para classificar os candidatos em nódulos e não-nódulos. Os resultados mostraram uma sensibilidade de 80% e uma média de 1 falso positivo por exame.

Em seu trabalho, Carvalho Filho (2013), descreve uma metodologia para a detecção automática de nódulos pulmonares, utilizando técnicas de segmentação, extração de características e classificação. A segmentação dos candidatos a nódulos é feita utilizando o algoritmo *Quality Threshold Clustering* (QT) e a classificação é realizada com base na extração de características, como forma e textura e o uso de SVM. Esse algoritmo alcançou sensibilidade de 85,91%, especificidade de 97,70%, precisão de 97,55% e uma taxa de falso positivo de 1,82 por exame.

Zhou, Cheng e Tamura (2014) propõe um método automático para incluir os nódulos justapleurais e vasos presentes nas bordas do pulmão, que muitas vezes são perdidos durante a segmentação dos nódulos pulmonares. O algoritmo possui os seguintes passos: pré-processamento das imagens, extração do tórax, identificação do pulmão e correção do contorno do pulmão. Os resultados mostraram que esse algoritmo é capaz de incluir todos os nódulos justapleurais e obter uma taxa de sobreposição de volume médio de  $95,81 \pm 0,89\%$  e uma média de distância de borda média de  $0,63 \pm 0,09$  mm comparados com os resultados de segmentação manuais.

Ramalho *et al.* (2014) relata um sistema de detecção de doenças pulmonares utilizando extração de características e aprendizagem de máquina extrema. Neste trabalho, foi empregado o método *Adaptive Crisp Active Contour Models* (ACACM) para segmentar as estruturas internas do pulmão (nódulos, vasos e etc.) e os descritores *Spatial Interdependence Matrix* (SIM), *Gray Level Cooccurrence Matrix* (GLCM) e *Visual Information Fidelity* (VIF) para extrair as características das imagens segmentadas de TC, sendo que o SIM obteve melhor desempenho. A aprendizagem de máquina extrema é utilizada para realizar a

classificação em três classes: fibrose pulmonar, doença pulmonar obstrutiva crônica ou pulmão saudável. Os resultados experimentais alcançaram uma precisão de 96%.

Messay, Hardie e Tuinstra (2015) apresentam um método de segmentação de nódulos pulmonares em exames de TC do tórax, composto de três novos algoritmos de segmentação: um sistema totalmente automático (*Fully-automated*), um sistema semiautomático (*Semi-automated*) e um sistema híbrido. A aplicação sequencial dos três algoritmos e o uso de uma rede neural de regressão para calcular uma série de características de cada candidato a nódulo pulmonar, permite melhorar os resultados da segmentação. Além disso, a comparação com outros dez métodos de segmentação existentes, mostrou que este trabalho apresenta um melhor desempenho pela sobreposição média de 69,23%.

Vivanti *et al.* (2015) desenvolveu um algoritmo de segmentação automática de tumores pulmonares em exames de TC, obtidas durante o acompanhamento de pacientes. O processo de segmentação consiste em registrar a imagem TC de linha de base e a delimitação dos tumores com as imagens de acompanhamento, realizar a segmentação inicial dos tumores nas imagens de acompanhamento, detectar e corrigir os vazamentos da segmentação dos tumores de acompanhamento, e regularizar o limite do tumor. Este algoritmo apresenta resultados significativos, como indicado pelo erro médio de sobreposição DICE de 14,5% e fornece medições relevantes para os tumores pulmonares.



### 3 METODOLOGIA

Este capítulo descreve a metodologia empregada para segmentar de forma automática os candidatos a nódulos pulmonares em imagens de TC. Dois novos algoritmos são apresentados. O primeiro algoritmo elimina os ruídos das imagens utilizando o filtro *wiener*, segmenta o parênquima pulmonar e, em seguida, segmenta os candidatos a nódulos. A segmentação é feita utilizando o processo de limiarização, em que o mesmo limiar é empregado em todas as imagens, por isso ele é fixo. O segundo algoritmo não realiza filtragem e para cada imagem é calculado o limiar adequado utilizando o método de *Otsu*. Inicialmente é calculado o limiar, depois o algoritmo segmenta a caixa torácica, extrai e reconstrói o parênquima pulmonar, e por fim, segmenta os candidatos.

#### 3.1 Segmentação Automática de Candidatos a Nódulos Pulmonares com o Uso do Filtro Wiener e Limiar Fixo

O algoritmo de segmentação automática de candidatos a nódulos pulmonares em Tomografias Computadorizadas do tórax com o uso do filtro *wiener* e um limiar fixo possui três etapas: eliminação de ruídos, segmentação do parênquima pulmonar e segmentação dos candidatos a nódulos. A eliminação de ruídos tem como objetivo melhorar a qualidade das imagens. A segmentação ocorre em dois momentos, primeiro é segmentado o parênquima pulmonar e depois é segmentado os candidatos a nódulos. A Figura 4 ilustra essas três etapas.




Figura 4 - Etapas do algoritmo de segmentação

##### 3.1.1 Eliminação de Ruídos

A primeira etapa do algoritmo é realizar um pré-processamento nas imagens de TC para eliminar os ruídos que podem existir. A eliminação de ruídos facilita a detecção dos

candidatos a nódulos pulmonares, pois melhora a qualidade das imagens. A Figura 5 mostra o resultado da aplicação do filtro *wiener* na imagem original.




Figura 5 - (a) Imagem de TC, (b) Imagem filtrada

### 3.1.2 Segmentação do Parênquima Pulmonar

A próxima etapa é a segmentação do parênquima pulmonar. Nessa fase, é necessário limiarizar a imagem filtrada gerando uma imagem binária. O processo de limiarização consiste em separar as regiões de uma imagem utilizando um determinado limiar. O limiar utilizado neste algoritmo é 0,51 para imagens com níveis mais elevados de intensidade e 0,01 para imagens com níveis de intensidade mais baixos. Vários valores de limiar foram testados, porém os melhores resultados foram obtidos com esses valores, garantindo a segmentação completa do parênquima pulmonar.

Inicialmente a imagem filtrada é binarizada utilizando o limiar 0,51. Depois é calculado o maior valor de intensidade de uma coluna central da imagem. Se esse valor for igual a 0, significa que a imagem não foi limiarizada corretamente. Então, a imagem filtrada é binarizada novamente utilizando o limiar 0,01. Assim, o limiar é definido de acordo com a imagem considerada. A imagem binária pode ser vista na Figura 6.




Figura 6 - Imagem binária

A partir da imagem binária é obtido uma máscara como ilustrado na Figura 7 (a). A máscara é gerada da seguinte forma: segmentando a caixa torácica, segmentando a região exterior a caixa torácica e aplicando a operação *not* nesta imagem. Cada um desses passos gera uma nova imagem que é a entrada do passo seguinte. A operação *not* em uma imagem binária gera uma nova imagem atribuindo aos pixels cujo valor é igual a 1 o valor 0 e aos pixels cujo valor é igual 0 o valor 1.

A Figura 7 (b) mostra a segmentação realizada com a máscara, eliminando a região exterior a caixa torácica. Essa imagem é então transformada em uma imagem binária e depois é invertida por meio da operação *not* gerando uma nova imagem. Em seguida é aplicado a operação *and* com essa imagem e a máscara, resultando em uma imagem segmentada do parênquima pulmonar. A operação *and* é aplicada a duas imagens binárias para gerar uma nova imagem contendo regiões comuns a essas duas imagens. Uma operação de fechamento utilizando um elemento estruturante circular com raio de dez unidades é feita para reconstruir o parênquima pulmonar como mostrado na Figura 7 (c). O parênquima pulmonar é então obtido a partir desta imagem, como mostrado na Figura 7 (d).




Figura 7 - (a) Máscara, (b) Segmentação com a máscara, (c) Parênquima reconstruído, (d) Segmentação do parênquima

### 3.1.3 Segmentação dos Candidatos a Nódulos

A etapa final deste algoritmo é a segmentação dos candidatos a nódulos pulmonares, que consiste em segmentar as estruturas interiores ao parênquima pulmonar (nódulos, traqueia, vasos sanguíneos e etc.).

A segmentação dos candidatos a nódulos é feita de forma simples, convertendo a imagem do parênquima pulmonar em uma imagem binária, utilizando um limiar menor do que o valor definido na etapa de segmentação do parênquima pulmonar. A partir de testes realizados foi observado que diminuir esse limiar permite detectar um maior número de nódulos, que seriam perdidos por apresentar um nível de intensidade semelhante ao do pulmão, ou estar localizado muito próximo a borda. Assim, o limiar 0,51 foi atualizado para

0,504 e o limiar 0,01 foi atualizado para 0,005. A imagem binária resultante da aplicação desses limiares apresenta as bordas do pulmão. Por isso, o passo seguinte consiste em eliminar essas bordas. A eliminação da borda é feita segmentando a borda do parênquima e subtraindo da imagem segmentada a imagem que contém a borda do pulmão, resultando em uma imagem com os candidatos a nódulos pulmonares como mostra a Figura 8 (b).





Figura 8 - (a) Parênquima pulmonar, (b) Candidatos a nódulos pulmonares

A Figura 9 (a) apresenta uma imagem de TC da base LIDC-IDRI com o nódulo indicado por um círculo vermelho e a Figura 9 (b) apresenta a imagem gerada pelo algoritmo contendo os candidatos a nódulos, entre eles o nódulo especificado (também indicado por um círculo vermelho) pelos especialistas.



(a)



(b)

Figura 9 - (a) Nódulo na imagem de TC, (b) Nódulo entre os candidatos

### 3.2 Segmentação Automática de Candidatos a Nódulos Pulmonares com o Uso do Método de Otsu

O algoritmo de segmentação automática de candidatos a nódulos pulmonares em imagens de Tomografia Computadorizada do tórax com o uso do método de *Otsu* possui quatro etapas como mostra a Figura 10. Inicialmente é calculado o limiar  $T$  utilizado para limiarização das imagens, depois ocorre a extração da caixa torácica, a extração e reconstrução do parênquima, e por último, a segmentação dos candidatos a nódulos pulmonares.




Figura 10 - Etapas do algoritmo de segmentação

#### 3.2.1 Cálculo do Limiar

O algoritmo desenvolvido utiliza a técnica de segmentação por limiarização. O limiar global  $T$  é calculado por meio do método de *Otsu*, tomando como parâmetro a linha central e horizontal da imagem de TC. A partir do limiar  $T$ , a imagem de TC é limiarizada gerando uma imagem binária. A Figura 11 (a) mostra a imagem de TC do tórax e a Figura 11 (b) mostra a imagem após a limiarização.




Figura 11 - (a) Imagem de TC, (b) Imagem binária

### 3.2.2 Extração da Caixa Torácica

A próxima etapa é a extração da caixa torácica, reduzindo a região de processamento. A partir da imagem binária é obtido uma máscara. Essa máscara é gerada da mesma forma que no primeiro algoritmo: segmentando a caixa torácica, segmentando a região exterior a caixa torácica e aplicando a operação *not* nesta imagem. Logo após, é feito uma segmentação na imagem de TC com a máscara, eliminando a região exterior a caixa torácica. A Figura 12 mostra esses passos.




Figura 12 - (a) Caixa torácica, (b) Região exterior a caixa torácica, (c) Inversão da imagem anterior, (d) Extração da caixa torácica



### 3.2.3 Extração e Reconstrução do Parênquima

A partir da imagem da caixa torácica ocorre a extração e reconstrução do parênquima pulmonar. Essa etapa também é feita da mesma forma que no primeiro algoritmo. A imagem da caixa torácica é limiarizada gerando uma imagem binária e depois é invertida por meio da operação *not* gerando uma nova imagem. Em seguida é aplicado a operação *and* com essa imagem e a máscara, resultando em uma imagem segmentada do parênquima pulmonar. A Figura 13 mostra a extração do parênquima pulmonar.



Figura 13 - Passos da extração do parênquima pulmonar

Depois de extrair o parênquima, uma operação de fechamento utilizando um elemento estruturante circular com raio de dez unidades é feita para reconstruir o parênquima pulmonar, recuperando partes que foram perdidas na extração. Uma vez reconstruído, o parênquima pode então ser obtido da imagem de TC, como mostra a Figura 14.




Figura 14 - Reconstrução do parênquima pulmonar

### 3.2.4 Segmentação dos Candidatos

A etapa final do algoritmo é a segmentação dos candidatos a nódulos pulmonares, que posteriormente serão analisados e classificados como nódulos ou não-nódulos. A segmentação dos nódulos é realizada a partir da limiarização da imagem do parênquima obtido na etapa anterior. Após a limiarização é segmentado as regiões da imagem de TC que correspondem aos candidatos a nódulos. O resultado pode ser visto na Figura 15.




Figura 15 – (a) Parênquima pulmonar, (b) Imagem binária com os candidatos, (c) Segmentação dos candidatos

A Figura 16 (a) apresenta uma imagem de TC da base LIDC-IDRI com o nódulo indicado por um círculo vermelho e a Figura 16 (b) apresenta a imagem gerada pelo algoritmo

contendo os candidatos a nódulos, entre eles o nódulo especificado (também indicado por um círculo vermelho) pelos especialistas.



(a)



(b)

Figura 16 - (a) Nódulo na imagem de TC, (b) Nódulo entre os candidatos

#### 4 RESULTADOS E DISCUSSÕES

Os resultados foram obtidos submetendo os algoritmos desenvolvidos a uma série de testes. Nos testes foram utilizados 20 exames da base LIDC-IDRI, contendo 1029 nódulos. Essa base contém informações das coordenadas do contorno dos nódulos e as fatias que compõem esses nódulos. Conhecendo a localização exata do nódulo em determinada fatia, o teste consiste em aplicar o método de segmentação nesta imagem e verificar se dentre as estruturas segmentadas alguma corresponde ao nódulo considerado.

Os exames foram escolhidos aleatoriamente. As imagens foram segmentadas utilizando os dois algoritmos desenvolvidos. Um teste a mais foi realizado com o segundo algoritmo para verificar se ao aplicar o filtro *wiener* nas imagens melhoraria o resultado da segmentação. Na Tabela 1, o resultado da segmentação é apresentado, mostrando a quantidade de nódulos que foram localizados e a respectiva taxa de porcentagem dos nódulos localizados de cada algoritmo.

Tabela 1 - Resultado da segmentação

Algoritmos	Quantidade de nódulos igual a 1029	
	Quantidade de nódulos encontrados	Porcentagem de nódulos encontrados
Algoritmo 1	958	93.1
Algoritmo 2	948	92.1
Algoritmo 2 com filtro	923	89.7

De um total de 1029 nódulos presentes nas imagens, o primeiro algoritmo segmentou 958 nódulos, ou seja, 93.1% dos nódulos. O segundo algoritmo segmentou 948 nódulos e, portanto, 92.1% dos nódulos. Já o segundo algoritmo com o uso do filtro segmentou 923 nódulos, localizando assim 89.7% dos 1029 nódulos. O tempo médio de execução em segundos por imagem de cada algoritmo é apresentado na Tabela 2. O tempo médio de execução foi calculado tomando como base um conjunto de 100 imagens.

Tabela 2 - Tempo médio de execução em segundos por imagem de cada algoritmo

Algoritmos	Tempo médio de execução em segundos por imagem
Algoritmo 1	0.1665
Algoritmo 2	0.0997
Algoritmo 2 com filtro	0.1131

A partir da Tabela 1, observamos que o primeiro algoritmo obteve o melhor desempenho nos testes, segmentando uma maior quantidade de nódulos. O segundo algoritmo segmentou uma quantidade menor de nódulos comparado ao primeiro algoritmo, contudo apresentou melhor desempenho do que quando fez uso do filtro *wiener*. Já a partir da Tabela 2 percebemos que o menor tempo de execução foi do segundo algoritmo e o maior tempo de execução foi do primeiro algoritmo. Diante disso, o primeiro algoritmo apresenta o melhor resultado de segmentação com relação a quantidade de nódulos encontrados, mas o segundo algoritmo apresentou o menor tempo de execução.

Outra observação importante é que o segundo algoritmo possui uma maior vantagem na segmentação dos candidatos a nódulos pulmonares em relação ao primeiro algoritmo, pelo fato do limiar ser calculado para cada imagem em tempo de execução. Como a qualidade das imagens da base LIDC-IDRI difere muito em virtude de terem sido obtidas por tomógrafos distintos, é melhor fazer a limiarização com um limiar que se adapte a imagem considerada. O limiar utilizado no primeiro algoritmo foi escolhido a partir de uma série de testes e funcionou bem com as imagens testadas, mas pode ser que não seja adequado a outras imagens da base.

O uso do filtro *wiener* no primeiro algoritmo foi importante para eliminar os ruídos das imagens, melhorando a qualidade delas e facilitando a localização dos nódulos. O uso do filtro não interferiu no processo de limiarização porque o limiar utilizado é o mesmo para todas as imagens. No caso do segundo algoritmo, a aplicação do filtro *wiener* nas imagens interferiu no processo de limiarização porque o limiar é calculado para cada imagem utilizando o método de *Otsu*. Ao filtrar as imagens, os pixels das imagens foram alterados não permitindo calcular o limiar adequado para cada imagem.

Os testes foram realizados em um computador com o processador *Intel(R) Core(TM) i5-2410M* de 2.30 GHz, 640 GB de HD e 4 GB de RAM.

As Figuras 17, 18 e 19 mostram três casos de acerto, em que os nódulos marcados pelos especialistas foram encontrados dentre os candidatos a nódulos. A parte *A* apresenta as imagens de TC e a parte *B* as imagens geradas pelos algoritmos contendo os candidatos a nódulos. Os nódulos são indicados por um círculo vermelho.




Figura 17 - (a) Imagem de TC com nódulo, (b) Nódulo encontrado




Figura 18 - (a) Imagem de TC com nódulo, (b) Nódulo encontrado




Figura 19 - (a) Imagem de TC com nódulo, (b) Nódulo encontrado

As Figuras 20, 21 e 22 mostram três casos de erros, em que os nódulos marcados pelos especialistas não foram encontrados pelos algoritmos. A Figura 20 mostra um nódulo que não foi encontrado por apresentar um nível de intensidade muito próximo ao do parênquima pulmonar. Já a Figura 21 mostra um nódulo que não foi encontrado por estar ligado a borda pulmonar. E a Figura 22 mostra um caso em que o nódulo marcado pelos especialistas não aparece na imagem de TC. Possivelmente, foi um erro de marcação devido à grande quantidade de imagens que foram analisadas pelos especialistas. Em cada Figura a parte *A* mostra a imagem de TC e a parte *B* mostra a imagem com os candidatos a nódulos, entre os quais o nódulo marcado pelos especialistas não foi localizado, mas aparece em vermelho para indicar onde ele deveria estar nessa imagem.




Figura 20 - (a) Imagem de TC com nódulo, (b) Nódulo não encontrado

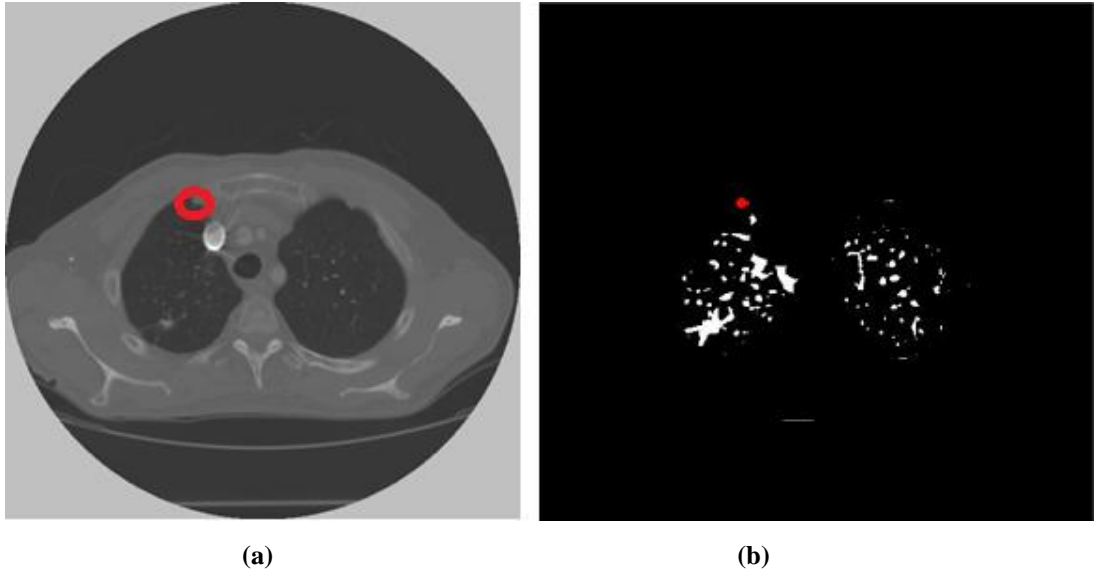


Figura 21 - (a) Imagem de TC com nódulo, (b) Nódulo não encontrado




Figura 22 - (a) Imagem de TC com nódulo, (b) Nódulo não encontrado



## 5 CONSIDERAÇÕES FINAIS

Este trabalho apresentou dois novos algoritmos de segmentação de candidatos a nódulos pulmonares em imagens de TC, compostos de três etapas principais: extração do parênquima pulmonar, melhoramento das estruturas internas ao parênquima pulmonar e segmentação dos candidatos a nódulos. Embora possuam essas três etapas principais, eles diferem em suas implementações. O primeiro algoritmo realiza um pré-processamento nas imagens de TC para eliminar os ruídos utilizando o filtro *wiener* e faz a segmentação por limiarização empregando o mesmo limiar em todas as imagens. Já o segundo algoritmo não realiza filtragem e o limiar utilizado na segmentação é calculado para cada imagem através do método de *Otsu*. Somente as etapas de extração da caixa torácica, extração e reconstrução do parênquima pulmonar foram implementadas usando as mesmas técnicas.

Os dois algoritmos apresentados têm como entrada uma imagem de TC e a partir dela eles geram uma imagem contendo as regiões segmentadas que correspondem aos candidatos a nódulos. Nos testes foram utilizados 20 exames da base LIDC-IDRI contendo 1029 nódulos, dos quais o primeiro algoritmo conseguiu localizar 93% e o segundo algoritmo conseguiu localizar 92%. Em alguns casos, não foi possível localizar os nódulos devido ao nível de intensidade ser semelhante ao do parênquima pulmonar, ou por estar localizado muito próximo a borda e, em alguns casos, o nódulo marcado pelos especialistas não aparece na imagem de TC.

A vantagem desta metodologia sobre outros métodos de segmentação de candidatos a nódulos pulmonares, é a facilidade de implementação, devido a menor complexidade e que resulta em uma execução mais rápida. Em outros trabalhos por exemplo, são utilizadas técnicas como crescimento de região, uso de histogramas para cálculo de um limiar ideal, algoritmos de agrupamento, redes neurais, entre outros. Além de ser simples, o método proposto fornece bons resultados de segmentação, comprovado pela porcentagem dos nódulos segmentados nos testes.

### 5.1 Trabalhos Futuros

Para trabalhos futuros pretende-se aperfeiçoar o método de segmentação para recuperar os nódulos que foram perdidos, testar mais exames da base LIDC-IDRI e de outras bases de imagens, dar continuidade a construção de um sistema CAD, desenvolvendo um

método que permita extrair as características dos candidatos a nódulos e classificá-los como nódulos e não-nódulos.

## **5.2 Publicação Obtida**

MOURA, M. J. C. de.; SOUSA, A. D. de.; OLIVEIRA, I. A. de.; MESQUITA, L. N.; DRUMOND, P. M. L. de. L. **Segmentação Automática de Candidatos a Nódulos Pulmonares em Imagens de Tomografia Computadorizada**. XV Workshop de Informática Médica e XXXV Congresso da Sociedade Brasileira de Computação, Recife, 2015.

## REFERÊNCIAS

BRAZ JÚNIOR, G. **Identificação de Massas em Mamografias Usando Textura, Geometria e Algoritmos de Agrupamento e Classificação**. Trabalho de Conclusão de Curso de Bacharelado, UFMA: São Luís, 2006.

CARVALHO FILHO, A. O. de. **Deteção automática de nódulos pulmonares solitários usando quality threshold clustering e mvr**, Dissertação de Mestrado na área de Ciência da Computação, (Programa de Pós-Graduação em Engenharia de Eletricidade), Universidade Federal do Maranhão, São Luís, 2013.

Instituto Nacional do Câncer – INCA, Ministério da Saúde, **Câncer de pulmão**. Disponível em: <<http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/pulmao/definicao>>. Acesso em: 04 de dezembro de 2015.

GINNEKEN, B. V.; ARMATO III, S. G.; HOOP, B. de.; VORST, S. V. A. de.; DUINDAM, D.; NIEMEIJER, M.; MURPHY, K.; SCHILHAM, A.; RETICO, A.; FANTACCI, M. E.; CAMARLINGHI, N.; BAGAGLI, F.; GORI, I.; HARA, T.; FUGITA, H.; GARGANO, G.; BELLOTTI, R.; TANGARO, S.; BOLAÑOS, L.; CARLO, F. de.; CERELLO, P.; CHERAN, S. C.; TORRES, E. L.; PROKOP, M. **Comparing and combining algorithms for computer-aided detection of pulmonary nodules in computed tomography scans: The ANODE09 study**, Medical Image Analysis, 2010, p. 707-722.

JACOBS, C.; RIKXOORT, E.M.V.; TWELLMANN, T.; SCHOLTEN, E. TH.; JONG, P. A.; De. KUHNIGK, J. M.; OUDKERK, M.; KONING, H. J.; De PROKOP, M.; PROKOP, C. S.; GINNEKEN, B.V. **Automatic detection of subsolid pulmonary nodules in thoracic computed tomography images**, Medical Image Analysis, 2013, p. 374-384.

LEE, S. L. A.; KOUSANI, A. Z.; HU, E. J. **Automated detection of lung nodules in computed tomography images: review**, Mach.Vis.Appl.23 (1), 2012, p. 151–163.

MA. L.; LIU, X.; SONG, L.; ZHOU, C.; ZHAO, X., ZHAO, Y. **A new classifier fusion method based on historical and on-line classification reliability for recognizing common CT imaging signs of lung diseases**, Computerized Medical Imaging and Graphics 40, 2015, p. 39-48.

MARQUES, F. O.; VIEIRA, N. H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999, p. 71 - 73.

MESSAY, T.; HARDIE, R. C.; TUINSTRA, T. R. **Segmentation of pulmonary nodules in computed tomography using a regression neural network approach and its application to the Lung Image Database Consortium and Image Database Resource Initiative dataset**, Medical Image Analysis, 2015, p.48-62.

NASCIMENTO, L. B. **Classificação de nódulos pulmonares em maligno e benigno utilizando os Índices de Diversidade de Shannon e Simpson**. Dissertação de Mestrado na área de Ciência da Computação. (Programa de Pós-Graduação em Engenharia de Eletricidade) - Universidade Federal do Maranhão, São Luís, 2012.

NEMA - National Electrical Manufacturers Associations. **Digital Imaging and Communications in Medicine (DICOM)**. Disponível em:  
<<http://medical.nema.org/standard.html>> Acesso em: 04 de janeiro de 2016.

NETTO, S. M. B. **Segmentação Automática de Nódulo Pulmonar com Growing Neural Gás e Máquina de Vetores de Suporte**. Dissertação de Mestrado na área de Ciência da Computação. (Programa de Pós-Graduação em Engenharia de Eletricidade) - Universidade Federal do Maranhão, São Luís, 2010.

NETTO, S. M. B.; SILVA, A. C.; NUNES, R. A.; GATTASS, M. **Automatic segmentation of lung nodules with growing neural gas and support vector machine**, Computers in Biology and Medicine 42, 2012, p. 1110–1121.

OTSU, N. **A Threshold Selection Method from Grey-Level Histograms**, IEEE Transactions on Systems, Man and Cybernetics, 9, 1, Janeiro 1979, 62-66.

RAMALHO, G. L. B.; FILHO, P. P. R.; MEDEIROS, F. N. S.; CORTEZ, P. C. **Lung disease detection using feature extraction and extreme learning machine**, Revista Brasileira de Engenharia Biomédica, 2014, p. 207-214.

SANTOS, A. M. **Deteção de nódulos pulmonares pequenos usando o Modelo de Mistura Gaussiana e Matriz Hessiana**. Dissertação de Mestrado na área de Ciência da Computação. (Programa de Pós-Graduação em Engenharia de Eletricidade) - Universidade Federal do Maranhão, São Luís, 2011.

SANTOS, A. M.; FILHO, A. O. C.; SILVA, A. C.; PAIVA, A. C.; NUNES, R. A.; GATTASS, M. **Automatic detection of small lung nodules in 3D CT data using Gaussian mixture models, Tsallis entropy and SVM**, Engineering Applications of Artificial Intelligence 36, 2014, p. 27-39.

SHAO, H.; CAO, L.; LIU, Y. **A detection approach for solitary pulmonary nodules based on CT images**, 2nd International Conference on Computer Science and Network Technology (ICCSNT), 2012.

VIVANTI, R.; JOSKOWICZ, L.; KARAASLAN, O. A.; SOSNA, J. **Automatic lung tumor segmentation with leaks removal in follow-up CT studies**, Int J CARS, 2015.

ZHOU, S.; CHENG, Y.; TAMURA, S. **Automated lung segmentation and smoothing techniques for inclusion of juxtapleural nodules and pulmonar vessels on chest CT images**, Biomedical Signal Processing and Control, 2014, p. 62-70.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA  
"JOSÉ ALBANO DE MACEDO"**

**Identificação do Tipo de Documento**

- Tese  
 Dissertação  
 Monografia  
 Artigo

Eu, Maria Jaqueline Carvalho de Moura, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação Segmentação Automática de Candidatos a Nódulos Pulmonares em Imagens de Tomografia Computadorizada do Tórax de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI, 26 de fevereiro de 2016.

Maria Jaqueline Carvalho de Moura

Assinatura