



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

Edson Cavalcanti Neto

SFPT NEURAL: NOVA TÉCNICA DE SEGMENTAÇÃO DE
FISSURAS PULMONARES BASEADA EM TEXTURAS EM
IMAGENS DE TOMOGRAFIA COMPUTADORIZADAS DO
TÓRAX

FORTALEZA - CEARÁ
DEZEMBRO - 2014

© Edson Cavalcanti Neto, 2014

Edson Cavalcanti Neto

SFPT NEURAL: NOVA TÉCNICA DE SEGMENTAÇÃO DE
FISSURAS PULMONARES BASEADA EM TEXTURAS EM
IMAGENS DE TOMOGRAFIA COMPUTADORIZADAS DO
TÓRAX

DISSERTAÇÃO

Dissertação submetida ao corpo docente da Coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática da **Universidade Federal do Ceará** como parte dos requisitos necessários para obtenção do grau de MESTRE EM ENGENHARIA DE TELEINFORMÁTICA.

Área de concentração: Sinais e Sistemas

Prof. Dr. Paulo César Cortez
(Orientador)

FORTALEZA - CEARÁ

2014

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca de Pós-Graduação em Engenharia - BPGE

-
- C366s Cavalcanti Neto, Edson.
SFPT neural: nova técnica de segmentação de fissuras pulmonares baseada em texturas em imagens de tomografia computadorizadas do tórax / Edson Cavalcanti Neto. – 2014.
87 f. : il. color. , enc. ; 30 cm.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2014.
Área de concentração: Sinais e Sistemas.
Orientação: Prof. Dr. Paulo César Cortez.
1. Teleinformática. 2. Redes neurais. 3. Processamento de imagens – Técnicas digitais. I. Título.



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
CAMPUS DO PICI, CAIXA POSTAL 6007 CEP 60.738-640
FORTALEZA – CEARÁ - BRASIL
FONE (+55) 85 3366-9467 – FAX (+55) 85 3366-9468

EDSON CAVALCANTI NETO

**SFPT NEURAL: NOVA TÉCNICA DE SEGMENTAÇÃO DE FISSURAS
PULMONARES BASEADA EM TEXTURAS EM IMAGENS DE
TOMOGRAFIA COMPUTADORIZADAS DO TÓRAX**

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia de Teleinformática, da Universidade Federal do Ceará, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Teleinformática.
Área de concentração: Sinais e Sistemas.

Aprovada em: 19/12/2014.

BANCA EXAMINADORA

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

Prof. Dr. Pedro Pedrosa Rebouças Filho
Instituto Federal de Educação, Ciência e Tecnologia do Ceará

Prof. Dr. Marcelo Alcântara Holanda
Universidade Federal do Ceará

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

Prof. Dr. Tarcísio Ferreira Maciel
Universidade Federal do Ceará

Sumário

Lista de Figuras	vi
Lista de Tabelas	viii
Lista de Siglas	ix
Resumo	x
Abstract	xiii
Agradecimentos	xvi
1 Introdução	1
1.1 Objetivos	4
1.2 Produção Científica	4
1.3 Organização da Dissertação	5
2 Fundamentação Teórica e Estado da Arte	6
2.1 Imagens Médicas	6
2.1.1 Imagens de TC	8
2.2 Fissuras Pulmonares	10
2.3 Processamento de Imagens	12
2.3.1 Segmentação	14
2.3.1.1 Segmentação por Similaridade	15
2.3.1.2 Segmentação por Descontinuidade	18
2.3.2 Morfologia Matemática	20
2.3.2.1 Erosão e Dilatação	20
2.3.2.2 Abertura e Fechamento	21
2.3.2.3 Afinamento	22
2.4 Rede Neural Perceptron Multicamada - MLP	23
2.4.1 Treinamento através do <i>Backpropagation</i>	25
2.5 Análise de Textura	27
2.5.1 <i>Local Binary Pattern</i> (LBP)	28
2.6 Estado da Arte	30
3 Metodologia	34
3.1 Aquisição das imagens	35
3.2 Segmentação do Pulmão e Filtragem Gaussiana 3D	37
3.3 Segmentação Automática das Fissuras	38

3.4	Pós-Processamento	40
3.5	Criação do Padrão Ouro e do Banco de Dados	43
3.6	Métricas de Avaliação	45
4	Resultados	47
4.1	Análise da variação do tamanho de janela no LBP	48
4.2	Comparação entre técnicas utilizando CS, S e Es	52
4.3	Comparação entre técnicas utilizando distância média	56
5	Conclusões, Contribuições e Trabalhos Futuros	58
	Referências Bibliográficas	61
	Apêndices	70
A	Cálculo do LBP	71

Lista de Figuras

2.1	imagens do corpo humano nas secções transversal, coronal e sagittal (DHAWAN; HUANG; KIM, 2008).	9
2.2	imagens de TC onde a) imagem original e b) representação pelas faixas de densidade (CAVALCANTE, 2010).	10
2.3	imagens do pulmão a) esquerdo com evidência da fissura e b) direito com evidência da fissura (UGALDE; CAMARGO; DESLAURIERS, 2007).	11
2.4	imagens de TC com fissura enfatizada.	12
2.5	etapas de um sistema de Visão Computacional típico. Adaptado de (ALEXANDRIA, 2005).	13
2.6	exemplo de quatro tipos de imagens, a) imagem RGB, b) imagem em tom de cinza, c) imagem binária e d) imagem indexada.	14
2.7	aplicação da limiarização de Bernsen (1986), a) imagem original, e b) imagem resultado.	16
2.8	ilustração da aplicação do Crescimento de Região 3D, a) determinação da semente, b) primeira iteração do CR 3D, e c) resultado final da segmentação (RIBEIRO, 2013).	17
2.9	exemplo de aplicação do operador Sobel, a) imagem em RGB, b) imagem em tom de cinza, c) resultado do operador Sobel para identificação das linhas horizontais, e d) resultado do operador Sobel para identificação das linhas verticais.	19
2.10	imagens sintéticas a) imagem original, b) imagem aplicada a erosão, e c) imagem aplicada a dilatação.	21
2.11	imagens sintéticas, a) imagem original, b) imagem resultante da abertura, e c) imagem resultante do fechamento.	22
2.12	imagens sintéticas, a) imagem original, e b) imagem resultante do afinamento.	23
2.13	rede de neurônios com 2 camadas ocultas. Adaptado de (HAYKIN, 2008).	23

2.14	classificação utilizando MLP.	24
2.15	exemplos de vizinhanças circulares (8,1), (16,2) e (8,2) (AHONEN; HADID; PIETIKAINEN, 2006).	29
2.16	operador básico LBP com vizinhança (8,1) (AHONEN; HADID; PIETIKAINEN, 2006).	29
3.1	fluxograma do método de segmentação de fissuras.	35
3.2	imagens a) TC do pulmão, b) resultado da segmentação do Pulmão e c) resultado da segmentação 3D do pulmão.	37
3.3	filtragem utilizando filtro gaussiano 3D, a) imagem original e b) imagem filtrada.	38
3.4	imagens resultantes da detecção das fissuras.	40
3.5	imagens após aplicação do método proposto nesta dissertação, a e b) resultados sem afinamento.	41
3.6	imagens após aplicação do método proposto nesta dissertação, a e b) resultados com afinamento.	42
3.7	imagens da segmentação das fissuras pulmonares, a) resultado da segmentação 2D em verde, e b) resultado da segmentação 3D.	43
3.8	imagens de TC do tórax, a) e b) imagens com fissuras pulmonares assinadas por médico especialista.	44
3.9	imagens ampliadas das fissuras destacadas pelo médico especialista.	44
3.10	interface desenvolvida para criação do banco de dados.	45
4.1	gráfico com as taxas $Es(\%)$, $CS(\%)$ e $S(\%)$ em relação a cada exame por tamanho de janela.	49
4.2	gráfico com as taxas $Es(\%)$, $CS(\%)$ e $S(\%)$ em relação a cada tamanho de janela por exame.	50
4.3	gráfico com as distâncias médias e os desvios padrões em relação a cada tamanho de janela por exame.	51
4.4	gráfico com as taxas $Es(\%)$ em relação a cada exame.	53
4.5	gráfico com as taxas $CS(\%)$ em relação a cada exame.	54
4.6	gráfico com as taxas $S(\%)$ em relação a cada exame.	54
4.7	gráfico com as taxas para cada método.	55
4.8	distâncias médias para cada exame.	56
A.1	exemplo de LBP (8,1).	72
A.2	resultado da limiarização.	72

Lista de Tabelas

3.1	informações dos exames utilizados.	36
4.1	valores de VP, FP, VN e FN por diferentes tamanhos de janela	48
4.2	resultado do classificador por diferentes tamanhos de janela	49
4.3	resultado do classificador por diferentes tamanhos de janela baseado na distância média e desvio padrão	50
4.4	resultado dos valores VP,FP, VN e FN para fissura sem afinamento.	52
4.5	resultado dos valores VP,FP, VN e FN para fissura com afinamento.	53
4.6	resultado dos valores VP,FP, VN e FN para Lassen et al. (2013).	53
4.7	resultados pelo Método Proposto.	57

Lista de Siglas

CP	Câncer de pulmão
DPOC	Doença Pulmonar Obstrutiva Crônica
ELM	<i>Extreme Learning Machine</i>
LBP	<i>Local Binary Pattern</i>
MLP	<i>Multilayer Perceptron</i>
PS	Perceptron Simples
RNA	Redes Neurais Artificiais
RF	Radiofrequência
TC	Tomografia Computadorizada

Resumo

Entre todos os tipos de câncer, o de pulmão (CP) é um dos mais comuns de todos os tumores malignos, apresentando aumento de 2% por ano na sua incidência mundial. No Brasil, para o ano de 2014 são estimados 27.330 casos novos de CP, sendo destes 16.400, em homens e 10.930 em mulheres. Neste contexto, é de fundamental importância para saúde pública realizar e determinar diagnósticos precoces e mais precisos para detectar os estágios reais das doenças pulmonares. O auxílio ao diagnóstico mostra-se importante tanto do ponto de vista clínico quanto em pesquisa. Dentre os fatores que contribuem para isto, pode-se citar o aumento da precisão do diagnóstico do médico especialista à medida que aumenta o número de informações sobre o estado do paciente. Deste modo, certas doenças podem ser detectadas precocemente, aumentando as chances de cura. O tratamento inicial para esta doença consiste na lobectomia. Nesse contexto, costuma-se realizar a segmentação dos lobos pulmonares em imagens de Tomografia Computadorizada para extrair dados e auxiliar no planejamento da lobectomia. A segmentação dos lobos a partir de imagens de TC é geralmente obtida através da detecção das fissuras pulmonares. Nesse sentido, com o intuito de obter uma segmentação da fissura pulmonar mais eficaz e realizar um processo totalmente independente das demais estruturas presentes no exame de TC, o presente trabalho possui o objetivo de realizar a segmentação das fissuras utilizando medidas de textura LBP e Redes Neurais

Artificiais (RNA). Para a implementação do algoritmo foi utilizado uma MLP (Multilayer Perceptron) com 60 entradas, 120 neurônios na camada oculta e 2 neurônios de saída. Os parâmetros de entrada para a rede foi o histograma LBP do *voxel* a ser analisado. Para o treinamento da rede foi necessário criar um sistema para identificação das classes fissuras e não-fissuras de forma manual, onde o usuário seleciona os *pixels* da classe fissura e da não-fissura. Para realizar as validações do algoritmo foi criado um padrão-ouro que foi extraído um total de 100 imagens de 5 exames do banco de dados LOLA11. Nessas imagens, as fissuras foram destacadas por 2 especialistas. A partir do padrão-ouro, as imagens foram processadas pelo algoritmo e assim os resultados obtidos. Para o conjunto de imagens testadas, o classificador obteve um melhor desempenho quando o tamanho, 15x15 *pixels*, da janela utilizada para gerar o histograma do LBP. Para chegar até essa definição foram testados os tamanhos 11x11, 15x15, 17x17 e 21x21 e os resultados foram comparados utilizando as métricas de Especificidade $Es(\%)$, Coeficiente de Similaridade $CS(\%)$, Sensibilidade $S(\%)$, distância média e desvio padrão da distância. A primeira abordagem de análise dos resultados é através dos *voxels* definidos como fissura no final da metodologia proposta. Para a metodologia proposta, detecção automática utilizando LBP (*Local Binary Pattern*) e MLP, as taxas obtidas foram $CS = 96,7\%$, $S = 69,6\%$ e $Es = 96,8\%$ para o método proposto antes do afinamento e $CS = 99,2\%$, $S = 3\%$ e $Es = 99,81\%$ para o método proposto com o afinamento no fim, considerando a incidência de falsos positivos e falsos negativos. Outra abordagem utilizada na literatura para avaliação de métodos de segmentação de fissuras é baseado na distância média entre a fissura delineada pelo especialista e a fissura resultante do algoritmo proposto. Desta forma, o algoritmo proposto neste trabalho foi comparado com o algoritmo de Lassen et al. (2013) através da abordagem da distância média entre a fissura segmentada manual e a fissura

segmentada de forma automática. O algoritmo proposto com afinamento no final obteve uma menor distância no valor de e e um menor desvio padrão comparado com o método de (LASSEN et al., 2013). Por fim, são apresentados os resultados da segmentação automática das fissuras pulmonares. A baixa incidência de detecções falso negativas, juntamente com a redução significativa de detecções falso positivas, resultam em taxa de acerto elevada. Conclui-se que a técnica de segmentação de fissuras pulmonares é um algoritmo útil para segmentar fissuras pulmonares em imagens de TC, e com o potencial de integrar sistemas que auxiliem o diagnóstico médico.

Palavras-chave: fissuras pulmonares, Tomografia Computadorizada, Processamento Digital de Imagens, Redes Neurais.

Abstract

Among all cancers, lung cancer (LC) is one of the most common tumors, an increase of 2% per year on its worldwide incidence. In Brazil, for the year of 2014, 27,330 new cases of LC are estimated, these being 16,400 in men and 10,930 in women. In this context, it is of fundamental importance for public health the identification on early stages of lung diseases. The diagnosis assistance shows to be important both from a clinical standpoint as in research. Among the factors contributing to this scene, one important is the increasing accuracy of diagnosis of a medical expert as you increase the number of information about the patient's condition. Thus, certain disorders might be detected early, including saving lives in some cases. The initial treatment for this disease consists of lobectomy. In this context, it is customary to perform the segmentation of lung lobes in CT images to extract data and assist in planning for lobectomy. The segmentation of the lobes from CT images is usually obtained by detection of pulmonary fissures. Thus, in order to obtain a more effective segmentation of pulmonary fissures, and perform a completely independent process from the other structures present in the CT scan, the present work has the objective to perform the fissure segmentation using LBP texture measures and Neural Networks (NN). To implement the algorithm we used one MLP with 60 inputs, 120 hidden neurons and 2 output neurons. The input parameters for the network was the LBP histogram of the voxel being analyzed. For network training, it was necessary to

create a system to label the features as fissures and non-fissures manually, where the user selects the fissure pixels class. To perform the validation of the algorithm was necessary to create a "gold standard" in which it was extracted a total of 100 images from 5 exams from the dataset LOLA11, where these images where the fissures were highlighted by two experts. From the gold standard, the proposed algorithm was processed and the results were obtained. For all tested images, the classifier obtained a better performance when the size of 15x15 pixels of the window was used to generate the histogram of the LBP. To get to this definition were tested sizes of 11x11, 15x15, 17x17 and 21x21 and the results were based on metrics comaprados $ACC(\%)$, $TPR(\%)$, $SPC(\%)$ distance mean and standard deviation of the distance. The first approach to analyze the results is through the voxels defined as fissure at the end of the proposed methodology. For the proposed methodology, using automatic detection and MLP LBP before thinning, the rates were obtained $ACC = 96.7 \%$, $TPR = 69.6 \%$ and $SPC = 96.8 \%$ and $ACC = 99.2 \%$ $TPR = 3 \%$ and $SPC = 99.81 \%$ for the proposed method with the thinning in the end, considering the incidence of false positives and false negatives. Another approach used in the literature for evaluating methods of fissure segmentation is based on the average distance between the fissure delineated by the expert and the resulting fissure through the algorithm. Thus, the algorithm proposed in this paper was compared with the algorithm Lassen et al. (2013) by the average distance between the manual segmented and the automatically segmented fissure. The proposed algorithm with the thinning in the end achieved a shorter distance average value and a lower standard deviation compared with the method of (LASSEN et al., 2013). Finally, the results obtained for automatic segmentation of lung fissures are presented. The low incidence of false negative detections detection results, together with the significant reduction in false positive detections result in a high rate of settlement. We

conclude that the segmentation technique for lung fissures is a useful target for pulmonary fissures on CT images and has potential to integrate systems that help medical diagnosis.

Keywords: pulmonary fissures, Computed Tomography, Digital Image Processing, Neural Networks.

Agradecimentos

A Deus.

À minha mãe e ao meu pai, Regina Coeli Figueiredo Cavalcanti e Raimundo Enéas Cavalcanti Neto, por estarem sempre me ajudando nas horas ruins e nas horas boas.

Ao Orientador Paulo César Cortez pela oportunidade e confiança em meu trabalho.

A todos os amigos que me ajudaram de forma direta ou indireta Thomaz M. de Almeida, Alyson B. da Silva, Auzuir R. de Alexandria e Pedro Pedrosa Rebouças Filho, pela ajuda e experiência repassada a mim.

Em especial aos amigos Tarique da S. Cavalcante e Valberto E. Rodrigues pelo apoio e ajuda durante a fase de pesquisa e desenvolvimento.

À Jermana Lopes de Moraes pelo apoio e suporte durante todo o percurso do Mestrado.

À Universidade Federal do Ceará (UFC), pelo apoio e oportunidades que foram dadas.

Aos professores Dr. Marcelo Alcântara e Dr. Daniel Castro do Departamento de Medicina Clínica pelo apoio durante a fase de validação.

Ao Laboratório de Engenharia de Sistemas de Computação (LESC/UFC), LATIN - Laboratório de Teleinformática pelas portas que me foram abertas e os colegas que hoje já considero amigos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte financeiro.

Capítulo 1

Introdução

Dentre as doenças que afetam a população mundial, um alto nível incide nos pulmões. Deste modo, as pesquisas na área de pneumologia possui grande importância na saúde, pois há uma preocupação com câncer, asma, bronquiectasia e a Doença Pulmonar Obstrutiva Crônica (DPOC) (WINKELER, 2006; ALMEIDA, 2011).

O câncer é definido como um conjunto de doenças que possuem um crescimento desordenado de células, que invadem os tecidos e órgãos, podendo se espalhar pelas regiões do corpo humano. Esse crescimento pode ocorrer de forma rápida e tende a ser muito agressivo e incontrolável, determinando assim a formação de tumores. Os diferentes tipos de câncer correspondem aos vários tipos de células afetadas do corpo (INCA, 2014).

O câncer de pulmão (CP) é o mais comum de todos os tumores malignos, apresentando aumento de 2% por ano na sua incidência mundial. Na pesquisa realizada em 2012 foi observado que aconteceram 1,82 milhões de novos casos de CP para o ano de 2012, sendo 1,24 milhões em homens e 583 mil em mulheres. Em 90% dos casos diagnosticados, o câncer de pulmão está associado ao consumo de derivados de tabaco (INCA, 2014).

No Brasil, o CP foi responsável por 24.424 mortes em 2011, sendo o câncer que mais fez vítimas. Para o ano de 2014 são estimados 27.330 novos casos de CP, sendo destes 16.400 em homens e 10.930 em mulheres. Quanto ao número de mortes são estimadas 22.424 sendo 13.698 homens e 8.726 mulheres (INCA, 2014; ZAMBONI; CARVALHO, 2005).

De acordo com Boing e Rossi (2007), o carcinoma do pulmão é um dos cânceres de maior incidência, sendo a principal causa de morte relacionada ao câncer no mundo. Há o registro de mais de 160.000 mortes/ano nos Estados Unidos e, no Brasil, mais de 20.000 mortes/ano. Devido à dificuldade no diagnóstico precoce, a maioria dos pacientes se encontram em estágios avançados no momento do diagnóstico. Somente um terço destes pacientes submete-se à retirada total cirúrgica do tumor e, portanto, a maioria não é

candidata a tratamento curativo.

Neste contexto, é de fundamental importância para saúde pública realizar e determinar diagnósticos precoces e mais precisos para detectar os estágios reais das doenças pulmonares.

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

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

Diante disto, para realizar o planejamento da lobectomia utilizam-se imagens de Tomografia Computadorizada (TC). A TC é um método de representação de imagens no sentido axial em que o valor de cada *pixel* da imagem corresponde ao coeficiente de atenuação dos raios X, expresso em Unidades Hounsfield (UH), incidente no tecido do órgão desejado. Por gerar imagens no sentido transversal, a TC realiza a amostragem, por exemplo do tecido pulmonar, em seções (fatias) com espessura de 0,2 a 1,5 mm e a densidade pulmonar nos exames de TC pode variar em média de -1000 a +200 UH (MADANI; KEYZER; GEVENOIS, 2001; KALENDER, 2006; HENDEE; RITENOUR, 2002).

Com o constante avanço tecnológico, novas áreas surgiram, como é o caso da Engenharia Biomédica. Este ramo de pesquisa emprega técnicas das áreas de Inteligência Artificial (IA), Processamento Digital de Imagens (PDI), Reconhecimento de Padrões (RP), entre outras (HEIDJEN, 1995). Na Engenharia Biomédica, técnicas de Processamento de Imagens Digitais são aplicadas em imagens médicas, como é o caso de imagens geradas por Tomografia Computadorizada (TC), que foi desenvolvida por Hounsfield (KAK; SLANEY, 1999). Esta foi aplicada inicialmente para medir a densidade radiográfica de forma precisa, e posteriormente para quantificá-la, auxiliando o diagnóstico (DRUMMOND, 1998). As principais facilidades dos exames de TC estão correlacionadas a produzir em menor

tempo os diagnósticos; detalhar imagens inalcançáveis à percepção natural da visão humana; aumentar a confiabilidade nas análises realizadas e proporcionar aos cirurgiões uma maior segurança quanto aos procedimentos (REBOUÇAS FILHO, 2010).

O desenvolvimento de sistemas computacionais, em sintonia com o conhecimento médico, tem possibilitado a construção de equipamentos eletrônicos que têm se mostrado importantes quanto à identificação de doenças e seus tratamentos. O uso destes equipamentos está presente em diversas formas, desde simples exames laboratoriais a exames de elevada complexidade, como os tomógrafos e aparelhos de ultra-som (WEBSTER, 1998). Essas facilidades têm possibilitado importantes avanços nos diagnósticos e seu uso está disseminado na Medicina e Telemedicina (MARKMAN, 1997; OLIVEIRA; CORTEZ; CARVALHO, 2004).

Os métodos de diagnóstico por imagens proporcionam enormes avanços na medicina atual, pois são baseados em métodos computacionais que realizam a extração e análise de informações, tendo importância científica e relevância clínica. Anteriormente e nos dias atuais, os médicos elaboram, por meio de uma análise visual, os diagnósticos reproduzidos em películas de filme ou papéis especiais, portanto em condições de muita subjetividade (WANG et al., 2010).

Considerando um sistema de visão computacional na área de pneumologia com base em TC do tórax, constata-se que a etapa de segmentação é essencial para o auxílio ao diagnóstico médico correto e preciso, visto que esta etapa delimita a área dos pulmões em imagens de TC do tórax que deve ser analisada pelo sistema ou pelo médico especialista. A segmentação dos lobos, a partir de imagens de Tomografia Computadorizada (TC) é geralmente obtida através da detecção das fissuras pulmonares. Esta segmentação é desafiadora, pois a densidade de fissuras se assemelha à densidade de outras estruturas como, por exemplo, pequenos vasos sanguíneos. Além disso, algumas partes das fissuras podem não estar corretamente representadas nas imagens de TC por causa do Efeito de Volume Parcial (EVP), em que as fissuras podem ser incompletas. Para superar essas dificuldades, diversos trabalhos na literatura fazem uso de informações anatômicas do pulmão para determinar a segmentação da fissura pulmonar.

A partir da literatura, observa-se que a segmentação das fissuras geralmente é baseada em um modelo genérico pré-definido que não considera a individualidade da anatomia de cada paciente (ZHANG; HOFFMAN; REINHARDT, 2006). Quando a técnica não se baseia nesses modelos pré-definidos, a segmentação das fissuras baseia-se no resultado de algoritmos de detecção e segmentação de outras estruturas, como vasos sanguíneos ou vias aéreas (LASSEN et al., 2013). Vale ressaltar que esses algoritmos possuem algum grau de erro que

podem chegar a comprometer a segmentação das fissuras, impossibilitando a segmentação correta dos lobos pulmonares.

Nesse sentido, com o intuito de obter uma segmentação da fissura pulmonar mais eficaz, e realizar um processo independente das demais estruturas, vasos sanguíneos e vias aéreas, presentes no exame de TC, o presente trabalho possui o objetivo de realizar a segmentação da fissura utilizando medidas de textura LBP (Local Binary Pattern) (OJALA; PIETIKAINEN; MAENPAA, 2002) e Redes Neurais Artificiais (RNA) (HAYKIN, 2008).

1.1 Objetivos

O objetivo geral desse trabalho consiste em desenvolver, implementar e avaliar algoritmos para segmentar as fissuras pulmonares em imagens de TC do tórax.

Durante o desenvolvimento desta dissertação outros objetivos específicos devem ser alcançados:

- i. pesquisa e estudo de métodos de segmentação de fissuras pulmonares;
- ii. criação de um banco de dados com imagens para testar a técnica desenvolvida;
- iii. comparação dos resultados das aplicações dos algoritmos desenvolvidos; e
- iv. avaliação dos algoritmos pesquisados junto ao médico especialista.

1.2 Produção Científica

- CAVALCANTI NETO, E. ; CORTEZ, P. C. ; SILVA FILHO, V. R. ; CAVALCANTE, T. S. ; REBOUCAS FILHO, P. P.R. . Neural Filter Applied To Fissure Detection. In: X Workshop de Visão Computacional, 2014, Uberlândia. X Workshop de Visão Computacional, 2014.
- CAVALCANTI NETO, E. ; CORTEZ, P. C. ; CAVALCANTE, T. S. ; SILVA FILHO, V. R. ; MARINHO, L. S. ; HOLANDA, M. . Segmentação 3d De Fissuras Pulmonares Em Imagens De Tc Do Tórax Utilizando Texturas. In: Congresso Brasileiro de Engenharia Biomédica, 2014, Uberlândia. XXIV Congresso Brasileiro de Engenharia Biomédica, 2014.

- CAVALCANTI NETO, E. ; CORTEZ, P. C. ; CAVALCANTE, T. S. ; SILVA FILHO, V. R. ; REBOUCAS FILHO, P. P.R. ; HOLANDA, M. . Supervised Enhancement Filter Applied To Fissure Detection. In: Congreso Latinoamericano de Ingeniería Biomédica - CLAIB, 2014, Paraná. VI Congreso Latinoamericano de Ingeniería Biomédica, 2014.

1.3 Organização da Dissertação

Esta dissertação está organizada em 5 Capítulos. No Capítulo 2 são apresentados alguns conceitos importantes sobre imagens médicas, sobretudo imagens de tomografia computadorizada. Ainda no mesmo Capítulo é feita a descrição dos métodos de segmentação utilizados neste trabalho, além de realizar uma apresentação sobre Redes Neurais Artificiais e Textura LBP. Por fim, é realizada uma breve revisão bibliográfica sobre os trabalhos relacionados ao tema da dissertação.

No Capítulo 3 é descrita a metodologia empregada para a implementação de cada algoritmo, abordando as etapas de aquisição de imagens, segmentação e filtragem do pulmão, detecção de fissura pulmonar e pós-processamento. Os resultados de cada método estudado são apresentados no Capítulo 4 e, por fim, no Capítulo 5 são apresentadas as conclusões e contribuições deste trabalho e os trabalhos futuros que podem ser desenvolvidos a partir do mesmo.

Capítulo 2

Fundamentação Teórica e Estado da Arte

Neste Capítulo inicialmente são discutidas as características das imagens médicas em específica as imagens adquiridas por TC do tórax. Posteriormente, é realizada uma breve descrição sobre fissuras pulmonares. Também são descritos os métodos de segmentação, Rede Neural Artificial(RNA) e texturas. Por fim, é discutido o estado da arte em segmentação de fissuras pulmonares em imagens de TC do tórax.

2.1 Imagens Médicas

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

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

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

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

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

O processo básico de formação de uma imagem requer uma fonte de energia para se obter a informação acerca do objeto de interesse presente na imagem. Alguma forma de radiação como a luz, raios X, raios gama, RF ou ondas acústicas, interagem com o objeto tecido ou órgão para fornecer informações sobre a sua propriedade característica. A fonte

de energia pode ser externa (radiografia de raios X, mamografia, tomografia computadorizada, ultra-som), interna (medicina nuclear; tomografia de emissão de fóton único (SPECT); A tomografia de emissão de pósitrons (PET), ou uma combinação de ambas interna e externa, tal como em imagiologia de ressonância magnética. Essas imagens são registradas em um padrão que é denominado DICOM (CHO; JONES; SINGH, 1993; FÉLIX, 2007).

O padrão *Digital Imaging and Communications in Medicine* (DICOM), criado em 1985 com o nome de ARC-NEMA 300-1985, descreve a formatação de imagens médicas com informações associadas a mesma, dirigidas aos mecanismos de operação da interface utilizadas para transferir dados entre determinado dispositivo de imagens e redes (SILVA, 2005; CAVALCANTE, 2010; NEMA, 2014).

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

O padrão DICOM é utilizado por diversos fabricantes de equipamentos médicos inclusive equipamentos de raios-X, ultrassonografia e Tomografia Computadorizada.

2.1.1 Imagens de TC

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

A imagem digital resultante de um exame de TC é composta por *pixels*, na qual o valor de cada *pixel* corresponde à atenuação da intensidade dos raios X, expressa em Unidades Hounsfield (UH). A escala da intensidade de atenuação tem valores específicos para cada tecido ou estrutura do corpo humano. Por exemplo, o tecido ósseo está entre 600 e 2000 UH (REBOUÇAS FILHO, 2010; WEBB; MULLER; NAIDICH, 2001).

A imagem de TC do corpo humano pode ser obtida em três planos diferentes denominados de Sagital, Coronal e Transversal. Na Figura 2.1 é possível observar a ilustração dos planos do corpo humano.

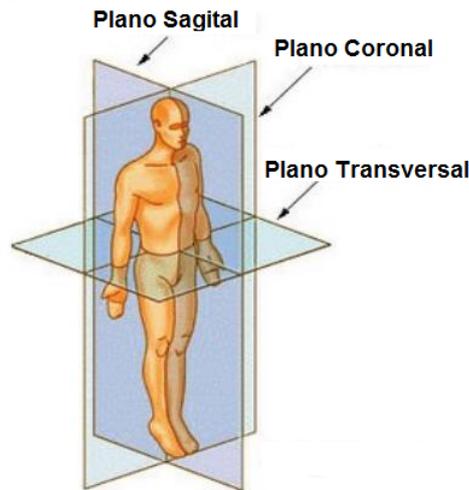


Figura 2.1: imagens do corpo humano nas secções transversal, coronal e sagittal (DHAWAN; HUANG; KIM, 2008).

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

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

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

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

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

É possível observar na Figura 2.2(b) a representação das faixas de densidade da Figura 2.2(a) na forma de cores, em que vermelho representa regiões hiperaeradas, azul as áreas

normalmente aeradas, verde as áreas pouco aeradas, amarelo representa as áreas não aeradas e preto as áreas não-classificadas (CAVALCANTE, 2010; RITTER et al., 2011).

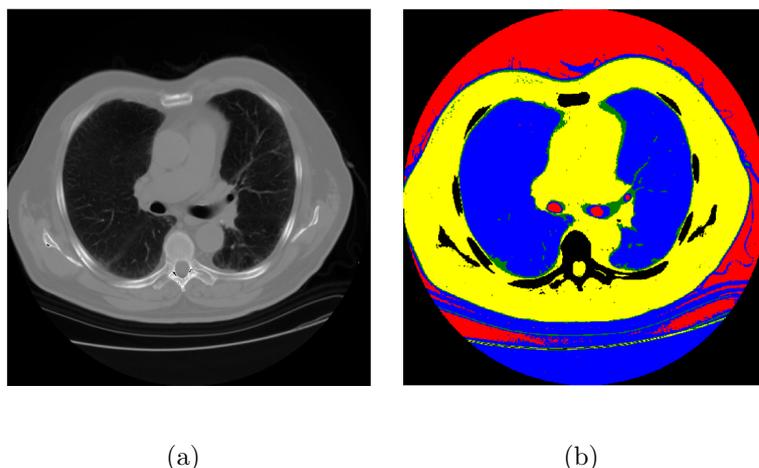


Figura 2.2: imagens de TC onde a) imagem original e b) representação pelas faixas de densidade (CAVALCANTE, 2010).

2.2 Fissuras Pulmonares

Os pulmões são órgãos cuja função principal é proporcionar a troca de ar. Por isto, os pulmões estão expostos a todos os tipos de substâncias cancerígenas no ar, incluindo o fumo do tabaco, o que os predispõem ao desenvolvimento de câncer (YOSHIKAWA; TSUBOTA; KODAMA, 2002; YILDIZ et al., 2004).

Uma estrutura com implicações importantes para a segmentação de áreas locais, dentro do pulmão, é a fissura pulmonar, que é uma superfície tridimensional (3D) de fronteira entre os lobos do pulmão. O pulmão esquerdo possui dois lobos separados por uma grande fissura, e o pulmão direito possui três lobos separados por duas fissuras (WANG; BETKE; KO, 2006). Há ainda outras fissuras, denominadas de fissuras interlobares que são depressões profundas que se estendem a partir da superfície externa do pulmão para o seu centro.

A pleura visceral, que cobre toda a superfície do pulmão, também penetra profundamente nas fissuras para que nessas áreas a pleura visceral de lobos adjacentes entrem em contato. Devido a este revestimento pleural, as superfícies do pulmão que se encontram dentro das fissuras são lisas e, assim, permitem que os lóbulos individuais se movam livremente em relação um ao outro. Na Figura 2.3(a) é possível observar o pulmão esquerdo com a existência da fissura oblíqua separando o pulmão em dois lóbulos, já na Figura

2.3(b) observa-se a fissura oblíqua e a horizontal dividindo assim o pulmão em três lobos (UGALDE; CAMARGO; DESLAURIERS, 2007).

Existem dois tipos de fissuras pulmonares: as fissuras lobares e as fissuras acessório. As fissuras lobares delineam os lobos dos pulmões e são importantes na localização de áreas que podem originar doenças que se espalham entre os lobos. Fissuras incompletas podem provocar um fluxo colateral entre lobos e tornar determinada intervenção broncoscópica de doenças pulmonares crônicas ineficazes. Já as fissuras acessório são uma fenda de profundidade variável coberta por pleura visceral que ocorrem mais frequentemente entre os segmentos pulmonares, mas também podem entrar planos subsegmentares ou interbronquiais. Na literatura a maioria dos métodos de detecção automática de fissura visam apenas a detecção de fissuras lobares (ARIYÜREK; GÜLSÜN; DEMIRKAZIK, 2001).

A segmentação das fissuras pulmonares de tomografias de tórax se tornou viável com o advento dos tomógrafos de múltiplos detectores, permitindo a obtenção de imagens finas a partir de CT de todo o pulmão. Uma vez que as fissuras são superfícies finas nos pulmões, sobre uma secção grossa de tomografia computadorizada, as fissuras são visíveis apenas como bandas vagas de aumento da densidade devido ao efeito de volume parcial (RIKXOORT; BRAM, 2013).

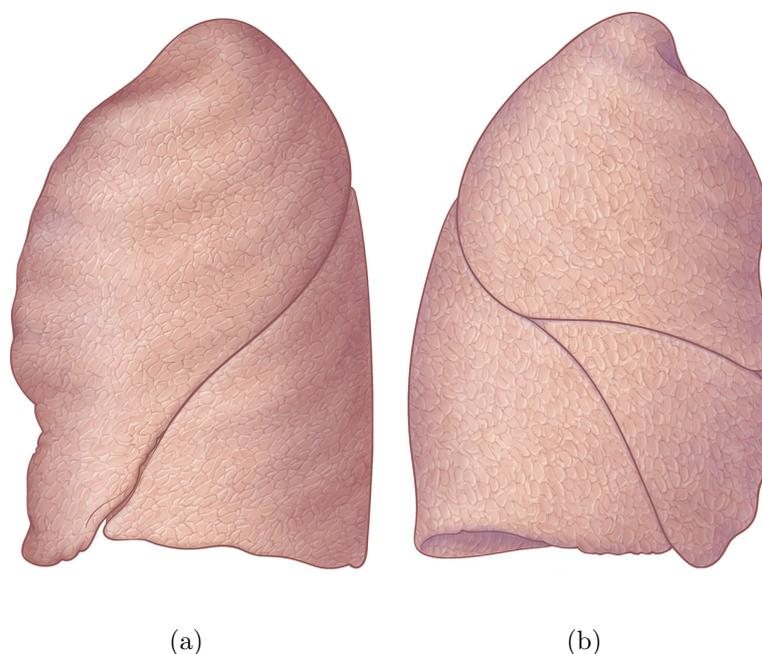


Figura 2.3: imagens do pulmão a) esquerdo com evidência da fissura e b) direito com evidência da fissura (UGALDE; CAMARGO; DESLAURIERS, 2007).

Em imagens de TC, a fissura pode muitas vezes ser observada como uma curva fina com

altos valores de atenuação, em comparação com os tecidos circundantes (WEBB; MULLER; NAIDICH, 2001). Quando vista a imagem do TC no plano axial da parte superior para inferior do tórax, a fissura que mede a partir do meio para o lado lateral do pulmão, parece mover-se a partir da posição posterior para a anterior em ambos os pulmões. Na Figura 2.4 é possível observar uma imagem de TC em que a fissura é destacada a partir de um retângulo vermelho tanto no pulmão direito quanto no esquerdo.

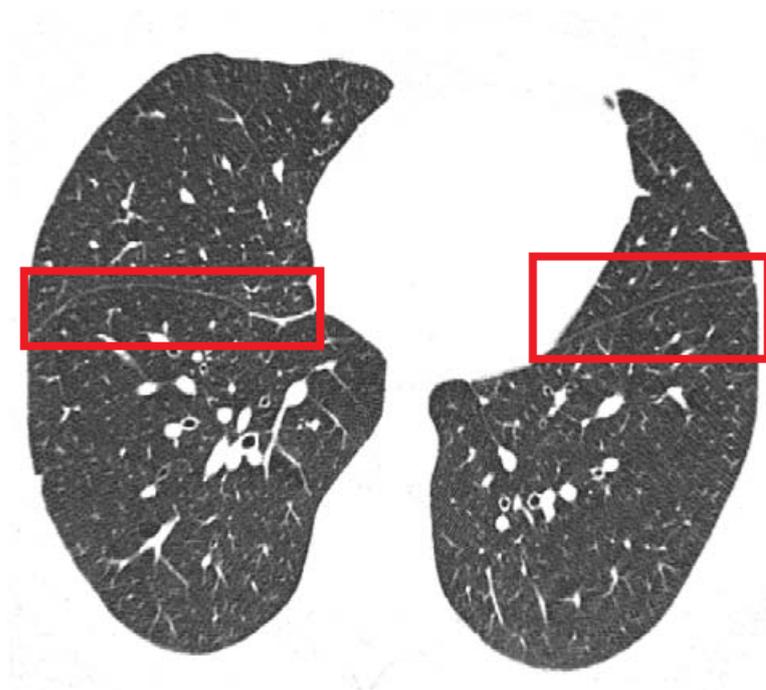


Figura 2.4: imagens de TC com fissura enfatizada.

2.3 Processamento de Imagens

Um sistema de Visão Computacional típico possui seis etapas. A etapa de aquisição de imagens, que consiste no processo de captura da imagem, enquanto a etapa de pré-processamento consiste em retirar falhas e imperfeições da mesma (ALEXANDRIA, 2005). A segmentação é a etapa responsável por dividir a imagem em regiões de interesse (GONZALEZ; WOODS; EDDINS, 2009). Posteriormente, a região segmentada é utilizada para extrair atributos, que são utilizados na etapa do reconhecimento através de um classificador. Por fim, é gerado um relatório com as análises e informações obtidas (ALEXANDRIA, 2005). Uma ilustração das etapas de um sistema típico de Visão Computacional pode ser observado na Figura 2.5.

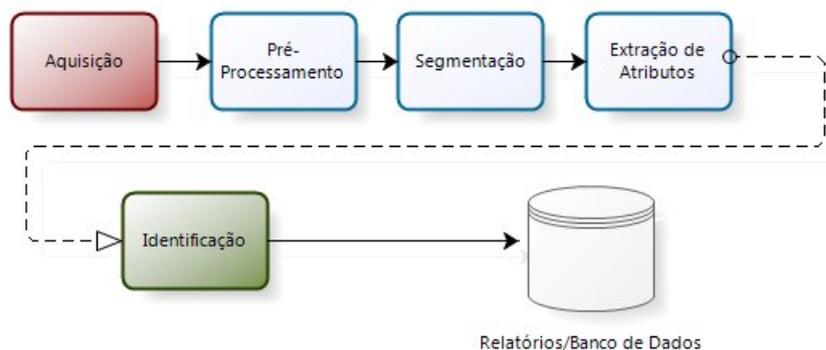


Figura 2.5: etapas de um sistema de Visão Computacional típico. Adaptado de (ALEXANDRIA, 2005).

Uma imagem é uma matriz de *pixels*, em que o valor de cada *pixel* pode ser obtido por uma função bidimensional $f(x,y)$, no qual os valores de x e y representam a posição do ponto no plano cartesiano e a amplitude f é chamada de intensidade ou nível de cinza (GONZALEZ; WOODS; EDDINS, 2009).

De acordo com McAndrew (2004), as imagens digitais podem ser divididas em quatro tipos: imagem RGB (*red-green-blue*), imagem em tom de cinza, imagem binária e imagem indexada.

Na imagem RGB cada *pixel* possui uma cor particular. Cada cor é descrita a partir da intensidade de vermelho, verde e azul, armazenada em vinte e quatro *bits*, conforme a Figura 2.6(a). Já uma imagem em um tom de cinza: cada *pixel* é um tom de cinza, normalmente 0 (preto) e 255 (branco), oito *bits*. Este tipo de imagem cada *pixel* é representado por oito *bits*, conforme Figura 2.6(b). Há ainda um tipo de imagem mais simples, as imagens binárias em que cada *pixel* é preto ou branco. Neste tipo de imagem necessita somente de um *bit* para representar um *pixel*, ver Figura 2.6(c). Por fim, em uma imagem indexada, cada *pixel* possui um valor que não informa a sua cor, mas um índice de cor em um mapa de cores, ver Figura 2.6(d).



Figura 2.6: exemplo de quatro tipos de imagens, a) imagem RGB, b) imagem em tom de cinza, c) imagem binária e d) imagem indexada.

A aquisição da imagem consiste na etapa da obtenção da mesma. Esta etapa é importante pois dependendo dos fatores do ambiente e das características da câmera podem influenciar na imagem resultante. A etapa de pré-processamento consiste em preparar a imagem para as etapas de segmentação e extração de atributos, desta forma um dos processos de pré-processamento é a transformação da imagem capturada em RGB para tom de cinza, com a finalidade de diminuir o custo computacional nos processos seguintes.

As outras etapas de um sistema de Visão Computacional são a segmentação da imagem, ou seja, a etapa na qual o objeto de interesse é obtido a partir da imagem original, a extração de atributos que consiste na extração de informações a partir da imagem, os quais servirão como entrada no sistema de reconhecimento e por último a identificação do objeto através de técnicas de Reconhecimento de Padrões.

2.3.1 Segmentação

A segmentação é a etapa que separa as regiões de interesse na imagem (CAVALCANTI NETO et al., 2010; ALEXANDRIA, 2005), sendo necessário aplicar algum método que identifique o objeto.

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

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

2.3.1.1 Segmentação por Similaridade

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

Limiarização

A limiarização é uma das técnicas mais simples e populares de segmentação. A limiarização consiste da classificação dos *pixels* de acordo com limiares. Esta técnica possui como objetivo realçar conjuntos de pixels de uma imagem que ocupam a mesma faixa de níveis de cinza de forma a extrair atributos a partir de uma imagem, dividindo a imagem de acordo com o objetivo do processo (GONZALEZ; WOODS; EDDINS, 2009; CAVALCANTE, 2010).

Desta forma, se determina um valor, limiar, no qual a imagem em análise é percorrida e caso o valor do *pixel* $f(x,y)$ atual seja menor do que o valor do limiar, recebe um valor mínimo. Caso ele seja maior, recebe um valor máximo, onde estes valores serão determinados em cada aplicação. Existem formas de se definir este limiar, algumas adaptativas e outras fixas (MCANDREW, 2004; ALEXANDRIA, 2005).

Existem alguns tipos de limiarizações como a Limiarização adaptativa de Bernsen (1986), Limiarização adaptativa da média criada por Glasbey (1993), Limiarização adaptativa de Niblack (1986) e Limiarização adaptativa de derivada do histograma criada por Pratt (2007).

O resultado da aplicação da limiarização em uma imagem de pulmão é ilustrado na Figura 2.7, onde a Figura 2.7(a) é a imagem original e a imagem resultante é ilustrada na Figura 2.7(b).

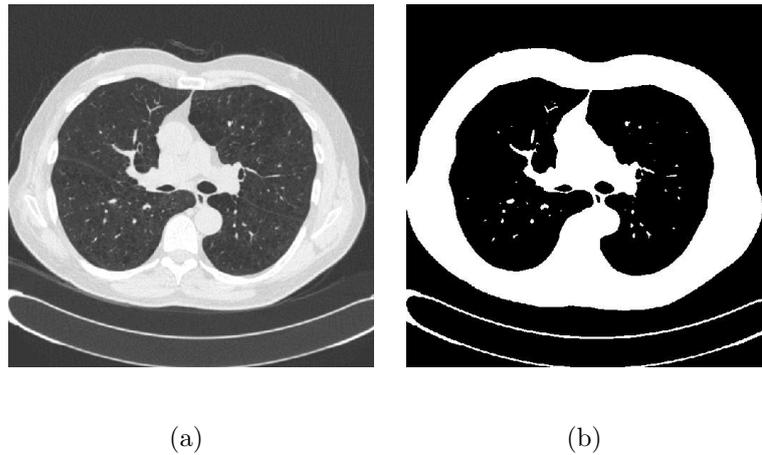


Figura 2.7: aplicação da limiarização de Bernsen (1986), a) imagem original, e b) imagem resultado.

Crescimento de Regiões 3D

O crescimento de região consiste em um procedimento de agrupamento de *pixels* ou sub-regiões em regiões maiores com base em critérios predefinidos de crescimento. A abordagem básica é iniciar através de uma região denominada de semente e a partir da mesma identificar os vizinhos e analisar os critérios para realizar o crescimento da região (GONZALEZ; WOODS; EDDINS, 2009).

Seja R uma região de N *pixels* vizinhos de um pixel com tom de cinza y . Defina-se a média da região \bar{X} e dispersão S^2 por (SHAPIRO; STOCKMAN, 2000):

$$\bar{X} = \frac{1}{N} \sum_{[x,y,z] \in R} I[x, y, z] \quad (2.2)$$

e

$$S^2 = \sum_{[x,y,z] \in R} (I[x, y, z] - \bar{X})^2. \quad (2.3)$$

Partindo do pressuposto de que todos os pixels em R e o *pixel* teste y são independentes e identicamente normalmente distribuídos, a estatística

$$T = \left[\frac{(N-1)N}{(N+1)} \frac{(y - \bar{X})^2}{S^2} \right]^{\frac{1}{2}} \quad (2.4)$$

possui distribuição T_{N-1} . Se T é pequeno o suficiente y é adicionado à região R e a média e a dispersão são atualizadas com y . A nova média da dispersão é dada por

$$\bar{X}_{novo} = \frac{(N \cdot \bar{X}_{antigo} + y)}{(N + 1)} \quad (2.5)$$

e

$$S_{novo}^2 = S_{antigo}^2 + (y - \bar{X}_{novo})^2 + N(\bar{X}_{novo} - \bar{X}_{antigo})^2 \quad (2.6)$$

Se T é muito alto não é provável que o valor de y tenha surgido a partir da população de pixels em R . Se y é diferente de todas suas regiões vizinhas, então começa sua própria região (SHAPIRO; STOCKMAN, 2000).

A aplicação básica do Método Crescimento de Regiões 3D é ilustrada na Figura 2.8. Considera-se uma máscara volumétrica 3x5x5, em que as propriedades de cada *voxel* foram distinguidas por meio de atribuição de cores. Dessa forma, os *voxels* de cor branca possuem propriedade A e os de cor cinza, propriedade B . Foi atribuída cor vermelha à semente. Nesse exemplo, deseja-se segmentar os *voxels* com propriedade A .

Este método de segmentação baseia-se primordialmente em análise de similaridade na vizinhança da semente. Dessa forma, deve ser localizada em posição estratégica para melhor desempenho do algoritmo. Na Figura 2.8(a) é visualizada a determinação da semente. Na Figura 2.8(b) é ilustrado o resultado da primeira iteração onde os *voxels* vizinhos com propriedade A passam a possuir o mesmo rótulo da semente. Na Figura 2.8(c) é ilustrado o resultado final da segmentação através da técnica de CR 3D onde foram segmentados os *voxels* com característica A .

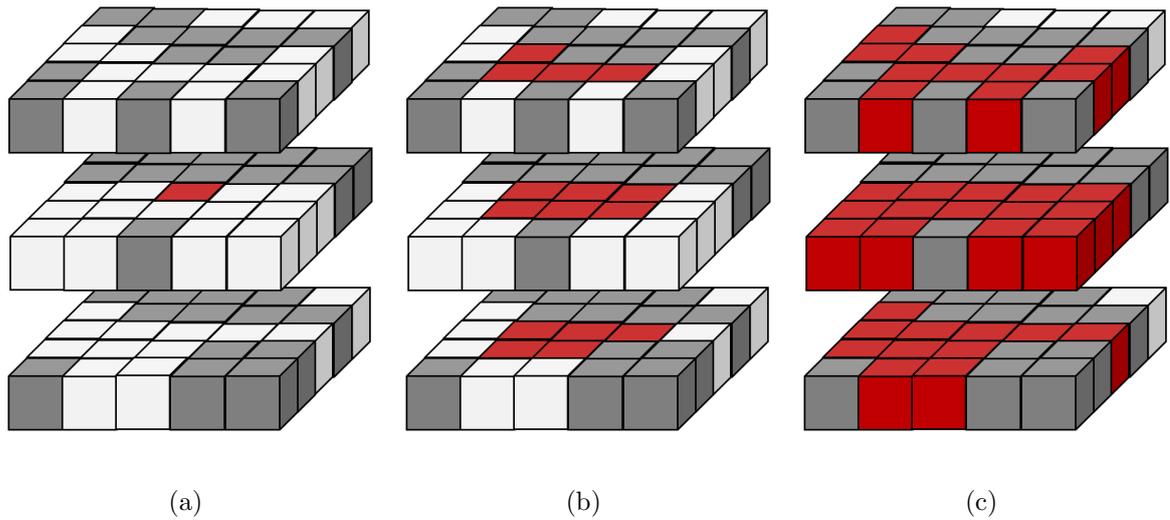


Figura 2.8: ilustração da aplicação do Crescimento de Região 3D, a) determinação da semente, b) primeira iteração do CR 3D, e c) resultado final da segmentação (RIBEIRO, 2013).

2.3.1.2 Segmentação por Descontinuidade

As técnicas de segmentação baseadas em descontinuidade detectam, em imagens em níveis de cinza, variações abruptas de intensidade entre um *pixel* e seus vizinhos. A maioria dessas técnicas se baseiam em uma convolução bidimensional entre uma máscara específica e uma dada imagem (CAVALCANTE, 2010).

Dentre as formas de detectar as bordas de objetos em imagens, destaca-se a utilização de operadores gradiente, podendo-se citar os operadores de Roberts, Prewitt e Sobel (SIEGWART; NOURBAKHS, 2004). Uma forma de implementar estes operadores é aplicar uma convolução bidimensional na imagem utilizando máscaras específicas, dadas por (SONKA; HLAVAC; BOYLE, 2007).

- Roberts

$$g(x, y) \cong \sqrt{(r_1^2 + r_2^2)}; \quad (2.7)$$

em que

$$r_1 = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}; r_2 = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}. \quad (2.8)$$

- Prewitt

$$g(x, y) \cong \sqrt{(p_1^2 + p_2^2)}; \quad (2.9)$$

em que

$$p_1 = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}; p_2 = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}. \quad (2.10)$$

- Sobel

$$g(x, y) \cong \sqrt{(s_1^2 + s_2^2)}; \quad (2.11)$$

em que

$$s_1 = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}; s_2 = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}. \quad (2.12)$$

As matrizes citadas nas equações 2.8, 2.10, 2.12 são utilizadas pra realizar uma convolução desta com a imagem, na qual o objetivo desta convolução é evidenciar as bordas da imagens. Esta convolução pode ser implementadas de acordo com as equações 2.7, 2.9, 2.11

Um exemplo de aplicação de um operador gradiente está ilustrado nas Figuras 2.9(c) e 2.9(d), em que a imagem original é apresentada na Figura 2.9(a) e a imagem em tom de cinza na Figura 2.9(b).

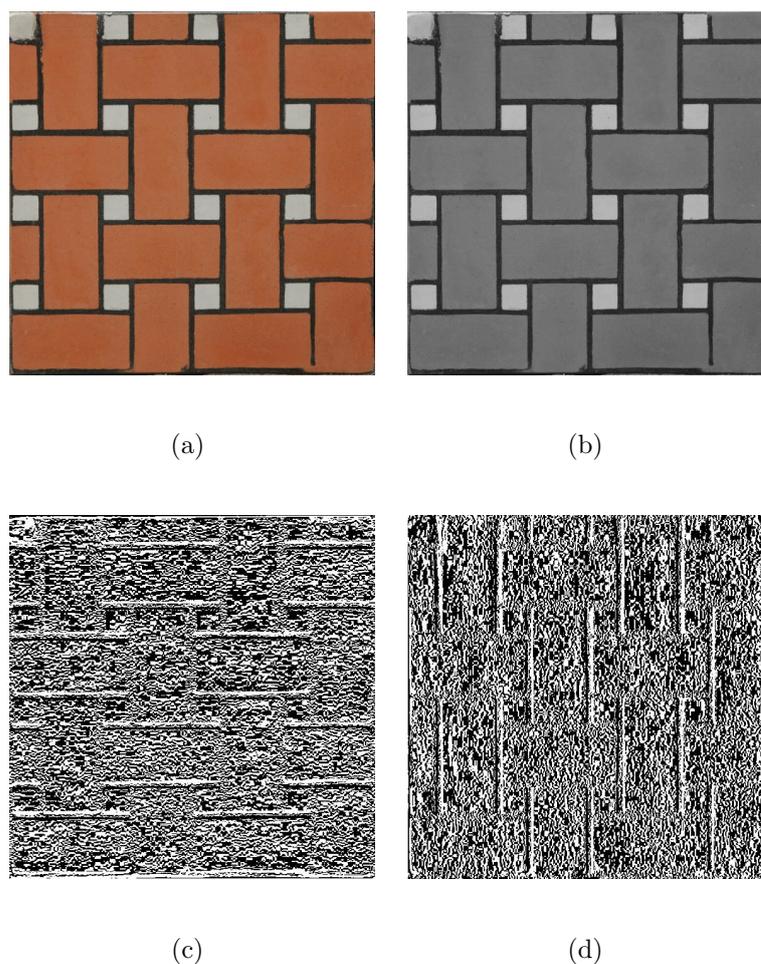


Figura 2.9: exemplo de aplicação do operador Sobel, a) imagem em RGB, b) imagem em tom de cinza, c) resultado do operador Sobel para identificação das linhas horizontais, e d) resultado do operador Sobel para identificação das linhas verticais.

2.3.2 Morfologia Matemática

A morfologia matemática é utilizada como ferramenta para extração de componentes da imagem que são úteis na representação e descrição de formas, por exemplo bordas, esqueletos e curvas convexas. Esta técnica também é utilizada para técnicas de pré e pós-processamento, como por exemplo filtragem, afinamento e poda (GONZALEZ; WOODS; EDDINS, 2009; MCANDREW, 2004; MARCHAND-MAILLET; SHARAIHA, 2000).

A morfologia matemática define alguns operadores morfológicos básicos: dilatação, erosão, anti-dilatação e anti-erosão. Baseado nos operadores básicos, um estudo foi realizado de forma a obter os operadores reticulados (BANON; BARREIRA, 1998).

2.3.2.1 Erosão e Dilatação

Sejam A e B conjuntos não-vazios, sendo que A representa a imagem em análise e B o elemento estruturante. Define-se matematicamente a erosão binária para os conjuntos A e B ($A \ominus B$) em Z^2 por

$$(A \ominus B) = \{z | (\hat{B})_z \subseteq A\}, \quad (2.13)$$

em que a erosão de A por B consiste em um conjunto de todos os pontos $z = (x, y)$ para cada B_z está em A . Para executar uma erosão, podemos mover B sobre A , encontrar todos os lugares que vai se encaixar, e para cada lugar marcar o valor correspondente $(0,0)$ ponto de B .

A dilatação binária para os conjuntos A e B é definida por

$$(A \oplus B) = \{z | [(\hat{B})_z \cap A] \subseteq A\}, \quad (2.14)$$

em que $(\hat{B})_z$ é a reflexão de B sobre a sua origem e transladado por z , que resulta na expansão da imagem analisada (GONZALEZ; WOODS; EDDINS, 2009). Isso significa que em cada ponto $x \in B$, A é transladado por estas coordenadas.

O resultado da aplicação do operador erosão sobre a imagem da Figura 2.10(a) é ilustrado na Figura 2.10(b). Já na Figura 2.10(c) é ilustrado o resultado da aplicação do operador dilatação sobre a imagem da Figura 2.10(a).

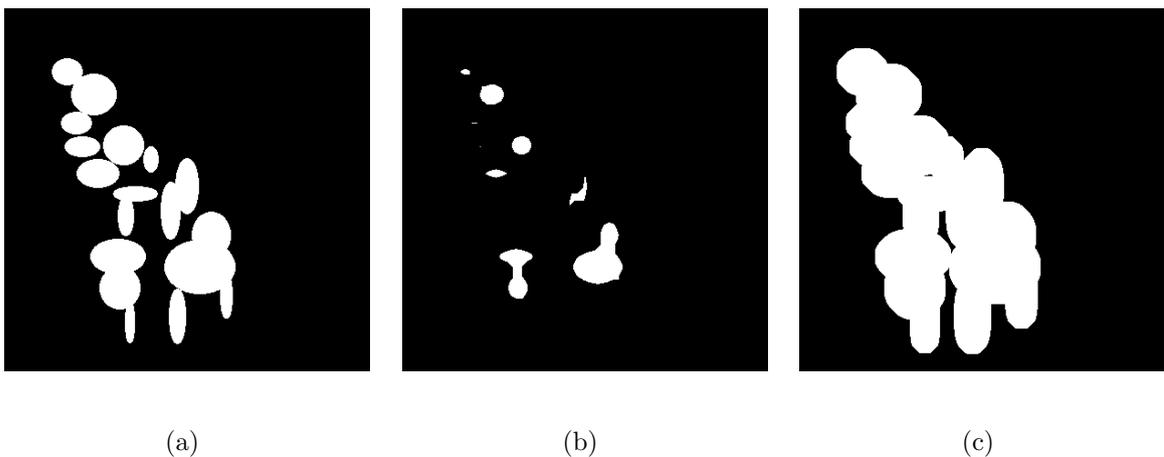


Figura 2.10: imagens sintéticas a) imagem original, b) imagem aplicada a erosão, e c) imagem aplicada a dilatação.

Os operadores morfológicos dilatação e erosão, aplicados alternadamente em uma imagem evidenciam melhor as características desta, pois, permitem construir funções importantes como, por exemplo, gradiente morfológico, abertura, fechamento, entre outras.

2.3.2.2 Abertura e Fechamento

A abertura binária de um conjunto A por B é definida pela erosão de A por B , seguida da dilatação deste resultado por B , denotada por

$$(A \circ B) = (A \ominus B) \oplus B, \quad (2.15)$$

causando o efeito de suavização no contorno, eliminando pequenas protuberâncias. A abertura consiste em uma erosão e logo após uma dilatação, que promove a união de todas as translações de B que se encaixam dentro de A (JAIN, 1989; GONZALEZ; WOODS; EDDINS, 2009; MCANDREW, 2004).

Invertendo-se a ordem das operações que definem a abertura, ou seja, dilatação de A por B , seguida da erosão do resultado por B , produz-se a operação de fechamento, expressa por

$$(A \bullet B) = (A \oplus B) \ominus B, \quad (2.16)$$

resultando no preenchimento de pequenos buracos e/ou lacunas no contorno da imagem analisada (JAIN, 1989; GONZALEZ; WOODS; EDDINS, 2009).

O resultado da aplicação da morfologia matemática da abertura aplicado sobre a imagem da Figura 2.11(a) é ilustrado na Figura 2.11(b). Já na Figura 2.11(c) é ilustrado o resultado da aplicação da morfologia matemática do fechamento sobre a imagem da Figura 2.11(a).

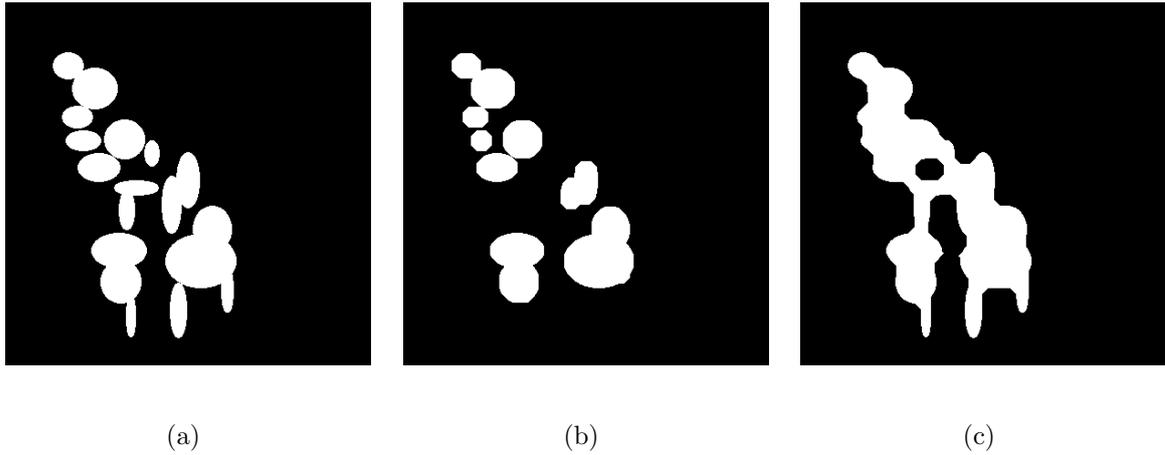


Figura 2.11: imagens sintéticas, a) imagem original, b) imagem resultante da abertura, e c) imagem resultante do fechamento.

2.3.2.3 Afinamento

O afinamento de um conjunto A por um elemento estruturante B , denotado de $A \otimes B$, pode ser definido em termos da operação toca-não-toca (*hit-or-miss*):

$$A \otimes B = A - (A \circledast B) = A \cap (A \circledast B)^C, \quad (2.17)$$

em que o símbolo \circledast denota a operação de *hit-or-miss*. A expressão mais usual para o afinamento de A simetricamente é baseada numa sequência de elementos estruturantes (GONZALEZ; WOODS; EDDINS, 2009; JAIN, 1989)

$$\{B\} = \{B^1, B^2, B^3, \dots, B^n\}, \quad (2.18)$$

em que B^i é a versão rotacionada de B^{i-1} . Usando este conceito, o afinamento é definido por uma sequência de elementos estruturantes como

$$A \otimes \{B\} = (((...(A \otimes B^1) \otimes B^2)...) \otimes B^n). \quad (2.19)$$

Este processo consiste em afinar A passando B^1 , o resultado é processado com B^2 e assim por diante, até afinar A com o passo de B^n . O resultado do afinamento pode ser obtido através de termos da dilatação e erosão (GONZALEZ; WOODS; EDDINS, 2009; MCANDREW, 2004).

O resultado da aplicação do operador afinamento aplicado na imagem da Figura 2.12(a) é ilustrado na Figura 2.12(b).

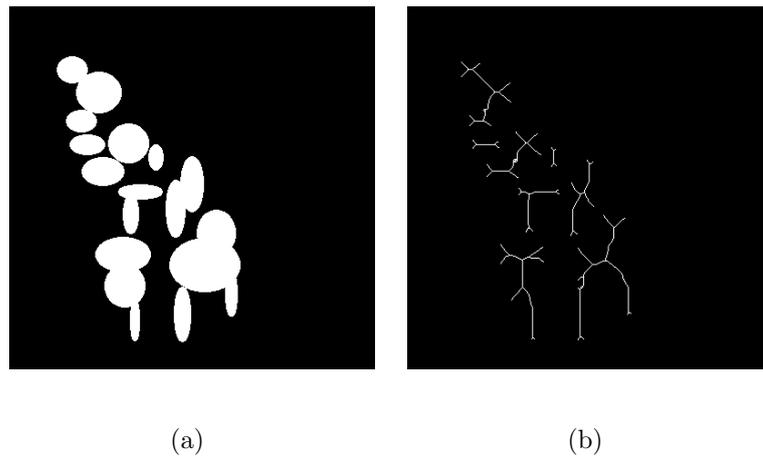


Figura 2.12: imagens sintéticas, a) imagem original, e b) imagem resultante do afinamento.

2.4 Rede Neural Perceptron Multicamada - MLP

A MLP é subdividida em camada de entrada, pesos da camada oculta, saída da camada oculta que consiste na entrada da camada de saída, pesos da camada de saída e saída do sistema, podendo haver mais de uma camada oculta (RUCK et al., 1990; HAYKIN, 2008). Estas subdivisões podem ser observadas na Figura 2.13.

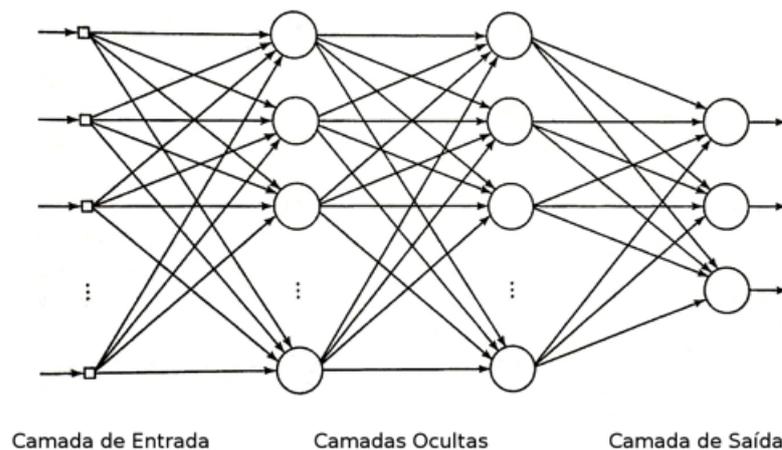


Figura 2.13: rede de neurônios com 2 camadas ocultas. Adaptado de (HAYKIN, 2008).

De acordo com Minsky e Papert (1969), os Perceptrons Simples (PS) não representam funções não linearmente separáveis, onde foram utilizados argumentos de lógica e geometria para mostrar tais limitações.

A maneira de resolver este problema é através da utilização de duas ou mais camadas de neurônios em série com pesos adaptativos. No entanto, faz-se necessário utilizar algum algoritmo capaz de ajustar os pesos nestas novas camadas (AZEVEDO; BRASIL; OLIVEIRA, 2000), o qual pode utilizar a retropropagação do erro para ajustar os pesos das camadas ocultas (MEDEIROS, 2008). Já o modelo de treinamento em batelada é a *Extreme Learning Machine* (ELM), que gera pesos aleatórios para a camada oculta e utiliza o método dos mínimos quadrados para treinar a camada de saída (HUANG; CHEN; SIEW, 2006).

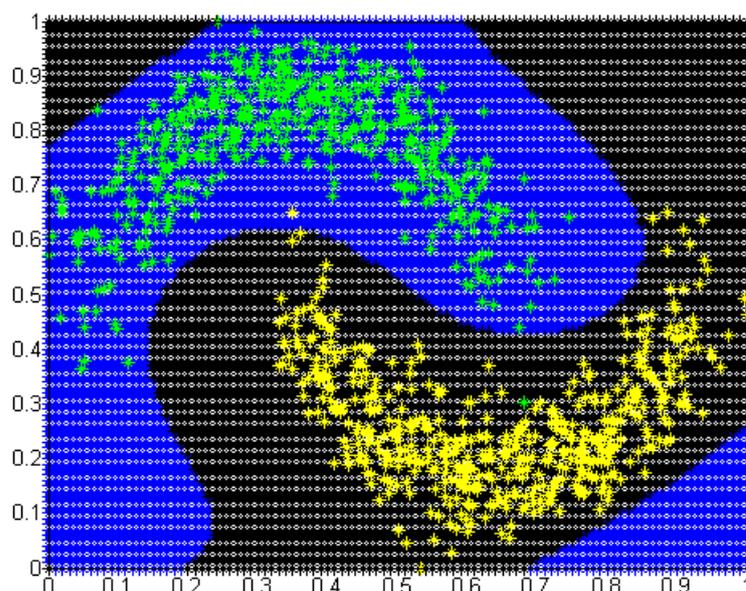


Figura 2.14: classificação utilizando MLP.

Na Figura 2.14 é ilustrada a dispersão dos dados de duas classes nas cores verde e amarela e nas cores azul e preta são ilustradas as duas áreas nas quais se dividem as duas classes. As duas classes são não linearmente separáveis, pois utilizando uma reta não é possível separá-las corretamente (HAYKIN, 2008). Neste exemplo é utilizado um classificador com múltiplas camadas, e com isso a região de dispersão dos dados é dividida em curvas de dispersões dos dados em análise.

2.4.1 Treinamento através do *Backpropagation*

Uma rede MLP é formada por uma camada de saída que possui neurônios não-lineares e uma ou mais camadas intermediárias compostas por neurônios somadores com função de ativação não-linear (FROTA, 2005; ARBIB, 2003). O sinal se propaga sempre para

a frente, camada por camada. A rede MLP tem sido aplicada a problemas através de seu treinamento de forma supervisionada com o algoritmo de retropropagação do erro (*backpropagation*). Este algoritmo é baseado na regra de correção de erro. Na Figura 2.13 é ilustrado um modelo genérico de uma rede multicamada.

Uma rede MLP com uma camada oculta com n neurônios pode ser representada por

$$w_i(t) = \begin{pmatrix} w_{i0}(t) \\ \vdots \\ w_{in}(t) \end{pmatrix} \quad (2.20)$$

e uma camada de saída de q neurônios pode ser representada por

$$m_k(t) = \begin{pmatrix} m_{k0}(t) \\ \vdots \\ m_{kq}(t) \end{pmatrix} \quad (2.21)$$

A MLP é uma rede supervisionada, ou seja, os pesos de cada camada são reajustados de acordo com o valor da saída da rede comparada com o valor real da saída (ARBIB, 2003). Nesse sentido, a fase de treinamento da MLP pode ser dividida em duas etapas, uma chamada de sentido direto na qual o trânsito de informações flui da entrada até a saída, gerando o valor de saída da rede. Enquanto isso na segunda etapa, chamada de sentido inverso, é utilizado o valor do erro gerado no sentido direto, e este é retropropagado para as camadas intermediárias para ajustar os pesos destas (BISHOP, 2006; WIDROW; WINTER, 1988).

A primeira etapa, ou sequência direta dos dados, envolve o cálculo dos dados das ativações e saídas de todos os neurônios, desde a entrada passando pela camada oculta, até a saída. Para calcular a saída dos neurônios da camada oculta é necessário calcular a ativação da saída dos neurônios da camada oculta, realizando o seguinte processo (HAYKIN, 2008)

$$u_i(t) = \sum_{j=0}^p w_{ij}(t)x_j(t) = w_i^T(t)x(t), \quad (2.22)$$

$$z_i(t) = \phi_i(u_i(t)) = \phi_i(w_i^T(t)x(t)), \quad (2.23)$$

em que $u_i(t)$ e $z_i(t)$ são o resultado da multiplicação da entrada da camada oculta pelos seus pesos e o resultado da função de ativação da camada oculta, respectivamente. A

função de ativação ϕ_i pode assumir duas funções não lineares que são a função sigmóide logística

$$\phi_i(u_i(t)) = \frac{1}{1 + \exp[-u_i(t)]} \quad (2.24)$$

e a função tangente hiperbólica:

$$\phi_i(u_i(t)) = \frac{1 - \exp[-u_i(t)]}{1 + \exp[-u_i(t)]}. \quad (2.25)$$

As próximas etapas consistem em realizar os mesmos processos das equações 2.22 e 2.23 para a camada de saída:

$$u_k(t) = \sum_{i=0}^q m_{ki}(t)z_i(t) = m_k^T(t)z(t) \quad (2.26)$$

$$y_k(t) = \phi_k(u_k(t)) = \phi_k(m_k^T(t)z(t)) \quad (2.27)$$

em que $u_k(t)$ e $y_k(t)$ são o resultado da multiplicação da entrada da camada de saída pelos seus pesos e o resultado da função de ativação da camada de saída, respectivamente, e a função de a ativação ϕ_k assume a forma da função sinal

$$y_k = \text{sign}(u_k(t)) = \begin{cases} +1, & y_k(t) > 0, \\ 0, & y_k(t) = 0, \\ -1, & y_k(t) < 0. \end{cases} \quad (2.28)$$

Na etapa seguinte ocorre a sequência inversa dos dados, calculando a última camada e o erro retropropagado para as camadas ocultas. Nesse sentido, primeiramente é calculado o erro de cada neurônio da camada de saída

$$e_k(t) = d_k(t) - y_k(t), \quad (2.29)$$

no qual $d_k(t)$ é o valor real do alvo de cada neurônio de saída pelo k-ésimo neurônio da amada de saída.

O erro na camada oculta é calculado através da propagação do erro vindo da camada de saída, em que este é propagado através do gradiente local do neurônio, tal que

$$\delta_k(t) = e_k(t)\phi'(u_k(t)) \quad (2.30)$$

$e_k(t)$ é o erro da camada de saída da rede e $\phi'_k(u_k(t))$ é a derivada da função de ativação da camada de saída. A derivada da função de ativação pode assumir os valores nas equações 2.31 ou 2.32, onde varia de acordo com a função de ativação escolhida dependendo se é a tangente hiperbólica ou o a sigmóide logística. No caso a função de ativação ser a função sigmóide logística, a derivada da função de ativação é dada por

$$\phi'_k(u_k(t)) = \frac{d\phi_k(u_k(t))}{du_k(t)} = y_k(t)[1 - y_k(t)] \quad (2.31)$$

Já no caso a função de ativação ser a função tangente hiperbólica, a derivada da função de ativação é dada por

$$\phi'_k(u_k(t)) = \frac{d\phi_k(u_k(t))}{du_k(t)} = \frac{1}{2}[1 - y_k^2(t)]. \quad (2.32)$$

Utilizando os erros calculados, os pesos de todas as camadas são atualizados da seguinte forma

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \Delta w_{ij}(t) \\ w_{ij}(t+1) &= w_{ij}(t) + \alpha \delta_i(t) x_j(t) \end{aligned} \quad (2.33)$$

em que α é a taxa de aprendizagem, δ_i corresponde ao gradiente local do i -ésimo neurônio.

Para a camada de saída, a equação de atualização dos pesos é dada por

$$\begin{aligned} m_{ki}(t+1) &= m_{ki}(t) + \Delta m_{ki}(t) \\ m_{ki}(t+1) &= m_{ki}(t) + \alpha \delta_k(t) z_i(t) \end{aligned} \quad (2.34)$$

em que α é a taxa de aprendizagem, δ_k corresponde ao gradiente local do k -ésimo neurônio.

2.5 Análise de Textura

Classificação de textura é um tópico de pesquisa em visão computacional e reconhecimento de padrões. Os primeiros métodos de classificação de textura se concentram na análise estatística de imagens de textura. Os mais representativos incluem o método matriz de co-ocorrência (HARALICK; SHANMUGAM; DINSTEN, 1973) e os métodos de filtragem com base (RANDEN; HUSOY, 1999). Kashyap e Khotanzad (1986) foram os primeiros pesquisadores a estudar classificação de textura invariante à rotação em por meio de um modelo auto-regressivo circular.

A textura é uma característica importante na percepção de imagens e pode ser interpretada como a relação espacial entre o arranjo de elementos básicos de uma imagem

(CHRISTODOULOU; MICHAELIDES; PATTICHIS, 2003). Em geral, as texturas são utilizadas para indicar propriedades intrínsecas de superfícies ou regiões, principalmente as que apresentam uma variação suave de intensidade, sendo tão pequenas que não conseguem separar objetos na resolução observada (SABINO et al., 2004).

Diversos sistemas de visão artificial, encontrados na literatura, utilizam texturas para identificar informações importantes de superfícies ou objetos em diferentes tipos de imagens (M.PAKDEL; F.TAJERIPOUR, 2011; WANG et al., 2011; DOSHI; SCHAEFER, 2012; LOSSON; MACAIRE, 2012; JUNIOR; BACKES; CORTEZ, 2013; JUNIOR; CORTEZ; BACKES, 2014).

Ojala, Pietikainen e Maenpaa (2002) propuseram o uso do histograma de padrão binário local (LBP) para classificação de textura invariante à rotação. O LBP é um operador simples, mas eficiente para descrever o padrão de imagem local e tem alcançado resultados impressionantes de classificação sobre as bases de dados de representação de textura (OJALA et al., 2002). O LBP também foi adaptado para muitas outras aplicações, tais como reconhecimento de face (AHONEN; HADID; PIETIKAINEN, 2006), o reconhecimento de textura dinâmica (ZHAO; PIETIKAINEN, 2007) e localização de formas em imagens (HUANG; LI; WANG, 2004).

2.5.1 *Local Binary Pattern (LBP)*

Local Binary Pattern (LBP) é um algoritmo de textura muito robusto em termos de variações da escala de cinza, uma vez que o operador é, por definição, invariante contra qualquer transformação monótona da escala de cinza. Além disso, é computacionalmente simples e pode ser realizado com algumas operações em uma pequena área e uma tabela de pesquisa (OJALA; PIETIKAINEN; MAENPAA, 2002).

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

Uma análise simples de cada pixel na imagem de uma pequena vizinhança gera um código binário denominado de código LBP. Definindo uma vizinhança como um conjunto de pontos de amostragem igualmente espaçados em um círculo centrado no pixel a ser

rotulado permite que qualquer raio e número de pontos de amostragem possam ser utilizados.

A interpolação bilinear é utilizada quando um ponto da amostragem não cai no centro de um pixel. Para calcular o LBP são consideradas as variáveis P e R que correspondem ao número total de vizinhos envolvidos e o raio da vizinhança, respectivamente. Se as coordenadas de pixel central são $(0,0)$, então as coordenadas do *pixel* vizinho é dado por $(-R.\sin(2\pi/P), R.\cos(2\pi/P))$. Os valores da intensidade de cinza dos vizinhos que não estão nas grades de imagem são dadas por interpolação (OJALA; PIETIKAINEN; HARWOOD, 1996). Na Figura 2.15 é possível visualizar alguns exemplos de vizinhanças.

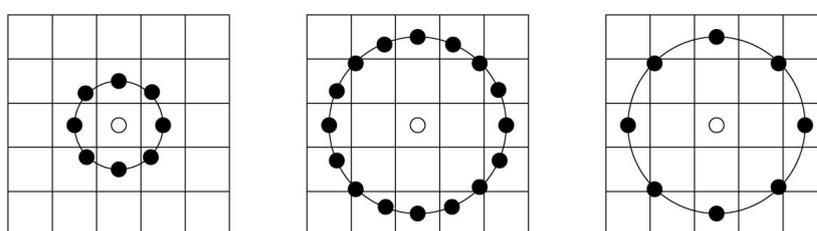


Figura 2.15: exemplos de vizinhanças circulares (8,1), (16,2) e (8,2) (AHONEN; HADID; PIETIKAINEN, 2006).

O operador LBP foi originalmente concebido para a descrição de textura que atribui uma etiqueta para cada pixel de uma imagem através da limiarização com uma janela predefinida e cada pixel com o valor de pixel central e considera o resultado como um número binário. Em seguida, o histograma dos rótulos podem ser utilizados como um descritor de textura. Na Figura 2.16 é ilustrado o operador básico LBP.

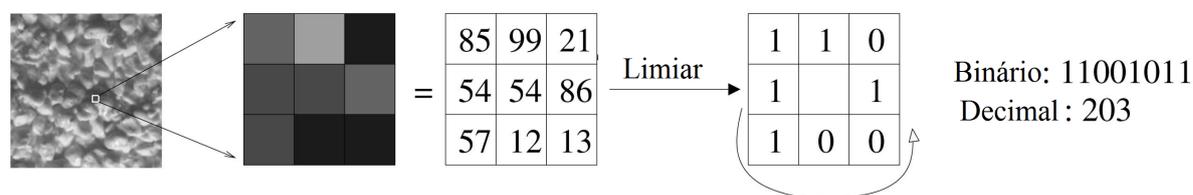


Figura 2.16: operador básico LBP com vizinhança (8,1) (AHONEN; HADID; PIETIKAINEN, 2006).

Outra versão para o operador do modelo é a definição dos chamados padrões uniformes. Um padrão binário local é chamado uniforme se o padrão binário contém, no máximo, duas transições de *bits* 0-1 ou vice-versa, quando o padrão de bits é considerado circular. Por exemplo, os padrões 00000000 (0 transições), 01110000 (2 transições) e 11001111 (2)

transições são uniformes ao passo que os padrões de 11001001 (4 transições) e 01010011 (5 transições) não são uniformes.

No cálculo do histograma do LBP, os padrões uniformes são utilizados de forma que o histograma resultante possua uma posição para cada padrão uniforme e todos os não uniformes são atribuídos a uma única posição. Ojala, Pietikainen e Maenpaa (2002) notaram que, em seus experimentos com imagens de texturas, padrões uniformes representam um pouco menos de 90 por cento de todos os padrões ao utilizar a vizinhança (8, 1) e cerca de 70 por cento na vizinhança (16, 2).

Desta forma, o código do LBP é calculado comparando o pixel com os seus vizinhos. A partir do valor do *pixel* central, a vizinhança é limiarizada em um padrão binário (GUO; ZHANG; ZHANG, 2010), dado por

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c)2^p, \quad (2.35)$$

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

onde g_c é o valor de cinza do pixel central, g_p é o valor de seus vizinhos. Ao atribuir um fator binomial 2^p para cada sinal $s(gp - gc)$ (OJALA; PIETIKAINEN; MAENPAA, 2002).

Depois que o padrão LBP de cada *pixel* é identificado, calculamos o valor de U . O valor U de um padrão de LBP é definido como o número de transições espaciais, mudanças bit a bit 0/1, naquele padrão (GUO; ZHANG; ZHANG, 2010).

$$U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)|. \quad (2.36)$$

Os padrões uniformes LBP referem-se aos padrões de transição que estejam limitados a $U \leq 2$ no padrão binário (OJALA; PIETIKAINEN; MAENPAA, 2002). Neste caso é mapeado de $LBP_{P,R}$ para $LBP_{P,R}^{u2}$. O subscrito $u2$ significa um padrão uniforme com ($U \leq 2$), que possui $P(P - 1) + 3$ padrões distintos que são uniformes.

Finalmente, o histograma é construído para representar a imagem de textura

$$H(k) = \sum_{i=1}^I \sum_{j=1}^J f(LBP_{P,R}(i, j), k), k \in [0, K] \quad (2.37)$$

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

que K é o valor máximo padrão do LBP, i e j são as dimensões da imagem.

2.6 Estado da Arte

A abordagem mais comum de filtros para detecção de fissuras pulmonares é baseada nos valores próprios da matriz Hessiana ou na estrutura tensora, tal como descrito para a segmentação de vasos sanguíneos. Vários autores propuseram modificações do método aplicando a retirada dos vasos proposta por Frangi et al. (1998) para melhorar as estruturas das fissuras Sato et al. (2000), Li et al. (2003). Para a detecção de fissuras a partir de tomografias de tórax, o uso destes filtros foi proposto pela primeira vez por Wiemker, Bülow e Blaffert (2005), que apresentaram dois filtros para o aperfeiçoamento das fissuras pulmonares. Um com base na análise dos valores da estrutura tensora e outro com base nos valores da matriz Hessiana de cada *pixel*. Nenhuma análise quantitativa foi realizada, mas somente de modo visual, pois os resultados dos filtros foram semelhantes de acordo com os autores.

Ochs et al. (2007) propõem um método utilizando reconhecimento de padrões para detectar todas as fissuras pulmonares. Um classificador foi treinado baseado em pontos fornecidos manualmente de fissuras, vasos e vias aéreas. Os autovalores da matriz Hessiana e suas combinações foram utilizados como atributos para o classificador. O método foi avaliado em um conjunto de 29 exames de tomografia computadorizada do tórax a partir de diferentes fontes de forma a chegar à uma área sob a curva Receiver-operator characteristic (ROC) de 0,95 em média.

Rikxoort et al. (2008) também propuseram uma abordagem de reconhecimento de padrões para enfatizar as fissuras pulmonares. Os valores da matriz Hessiana foram utilizados como atributos em combinação com as derivadas de primeira e de segunda ordem da imagem. O classificador foi treinado a partir de fissuras delineadas manualmente. O método foi avaliado quantitativamente em um conjunto de 22 exames com segmentações manuais das fissuras e ilustrou um bom desempenho, com uma área sob a curva ROC de 0,98 comparada com 0,90 para o método pelo Wiemker, Bülow e Blaffert (2005) que foi implementado para comparação.

Métodos que visam apenas localizar as fissuras lobares geralmente são um pré-requisito para uma segmentação lobar subsequente, começando por definir uma localização aproximada das fronteiras dos lobos com base em um prévio conhecimento anatômico para limitar a área da procura de fissura.

Zhang, Hoffman e Reinhardt (2006) utilizaram um atlas anatômico construído utilizando dados de pulmão TC de 16 indivíduos para inicializar segmentação da fissura. O método utiliza ainda um sistema *fuzzy* para inicializar a segmentação da fissura lobular e

emprega um outro sistema fuzzy juntamente com pontos inseridos manualmente que servem como base para identificar a fissura pulmonar, ou seja, depende diretamente do atlas anatômico do pulmão e da interação com o usuário que insere pontos para segmentação final. Uma avaliação em 22 tomografias do tórax foi realizada comparando a saída do método manualmente traçadas das fissuras em termos do erro quadrático médio.

Sapthagirivasan e Mahadevan (2010) utilizam uma filtragem para realçar as árvores vasculares e brônquicas de forma a identificar o local das fissuras e então aplicam uma transformada *wavelet* baseada em uma árvore dupla complexa 2D para encontrar as curvaturas das fissuras. Com base no local e nas curvaturas, é realizada, uma busca para a fissura pulmonar, ou seja, o algoritmo depende de uma prévia identificação das árvores vasculares e brônquicas, além do resultado da identificação das curvaturas através da transformada *wavelet*.

Wang, Betke e Ko (2006) apresentaram um método para segmentar as fissuras lobares que começa com a inicialização manual em uma seção axial de tomografia computadorizada de tórax localizada na metade inferior do pulmão. A partir desta seção axial, cortes axiais importantes foram identificados pelo pulmão nos quais as fissuras foram segmentadas. A fissura traçada manualmente na primeira seção foi transformada para a seção axial seguinte mais próxima para iniciar uma busca na região à procura da fissura. Na região da fissura, um mapa de picos é computado e combinado com a imagem de entrada em um método de crescimento de curva para delinear a fissura na seção. Este processo foi repetido até que as fissuras em todas as seções fossem segmentadas e então foi aplicada, por fim, uma interpolação linear 3D para segmentar a fissura em todas as seções da varredura. O método foi avaliado em dez tomografias em que fissuras foram traçadas manualmente. A distância média entre a fissura delineada automaticamente e a traçada manual foi de 1,01mm, em 2,4% dos setores uma correção manual foi aplicada.

Ukil e Reinhardt (2009) combinaram a transformada da distância aplicada em vasos segmentados e a imagem de tomografia computadorizada do tórax original de forma a servir como uma imagem de custo para a transformada *watershed* guiada pelas vias aéreas e marcações vasculares. Com base na segmentação de *watershed*, uma área de pesquisa inicial para as fissuras pulmonares foi determinada. Na área de interesse, uma medida de *ridgeness* baseada na análise da estrutura do tensor foi aplicada em fatias transversais, seguida por uma procura através de grafo 3D para localizar a superfície ótima dentro da área de busca para encontrar a fissura pulmonar. O método foi avaliado comparando os traçados manuais das fissuras em exames de 12 indivíduos normais na inspiração e expiração e em 17 pacientes com enfisema em plena inspiração.

Pu et al. (2009) fazem uso de um modelo geométrico para realizar a segmentação inicial da fissura, após aplicar um filtro de suavização Laplaciano e realizam um processamento na imagem resultante através de método estatístico de forma a obter uma aproximação da fissura na imagem de TC, o que torna um algoritmo dependente do modelo geométrico que pode variar dependendo do pulmão em análise.

Lassen et al. (2013) apresentaram um filtro ligeiramente diferente baseado em um filtro utilizando matriz Hessiana e obtendo os autovalores no qual a forma da fissura foi levada em conta, assim como a força da estrutura de imagem para uma melhor diferenciação entre vasculatura e fissuras. O filtro de realce da fissura não foi avaliado separadamente, uma vez que fazia parte de um método de segmentação dos lobos.

Desta forma, o objetivo geral desse trabalho consiste em desenvolver, implementar e avaliar algoritmos para segmentar as fissuras pulmonares em imagens de TC do tórax.

Capítulo 3

Metodologia

De posse das técnicas descritas no Capítulo anterior é realizada neste momento a descrição de todo o processo, bem como a detalhada configuração dos algoritmos utilizados para segmentação das fissuras pulmonares. Também é apresentada neste Capítulo a metodologia de criação do banco de dados para treinamento e os métodos de avaliação utilizados para verificar a exatidão das segmentações.

O processo de segmentação das fissuras pulmonares é constituído por cinco fases: aquisição das imagens, segmentação do pulmão, filtragem gaussiana 3D, detecção de fissura com MLP e por fim a etapa de pós-processamento que contempla algoritmos de análise de componentes conectados e morfologia matemática.

A etapa de aquisição consiste na obtenção da imagem a partir do tomógrafo, nesta dissertação as imagens são obtidas a partir de vários tomógrafos, pois as imagens utilizadas foram obtidas de LObe Lung Analysis 11. A etapa seguinte consiste na segmentação do pulmão, ou seja, nesta etapa será destacado o pulmão na imagem, pois o método proposto atua de forma a identificar fissuras dentro do pulmão. Após a segmentação do pulmão é realizada a filtragem Gaussiana 3D na imagem original de forma a filtrar os ruídos. De posse do resultado da segmentação do pulmão e da filtragem, a próxima etapa consiste na detecção da fissura pulmonar através de uma rede supervisionada. Por fim é realizado um pós-processamento para retirada de ruídos e preenchimento de algumas pequenas lacunas. O fluxograma das etapas do método desenvolvido neste trabalho é ilustrado na Figura 3.1.

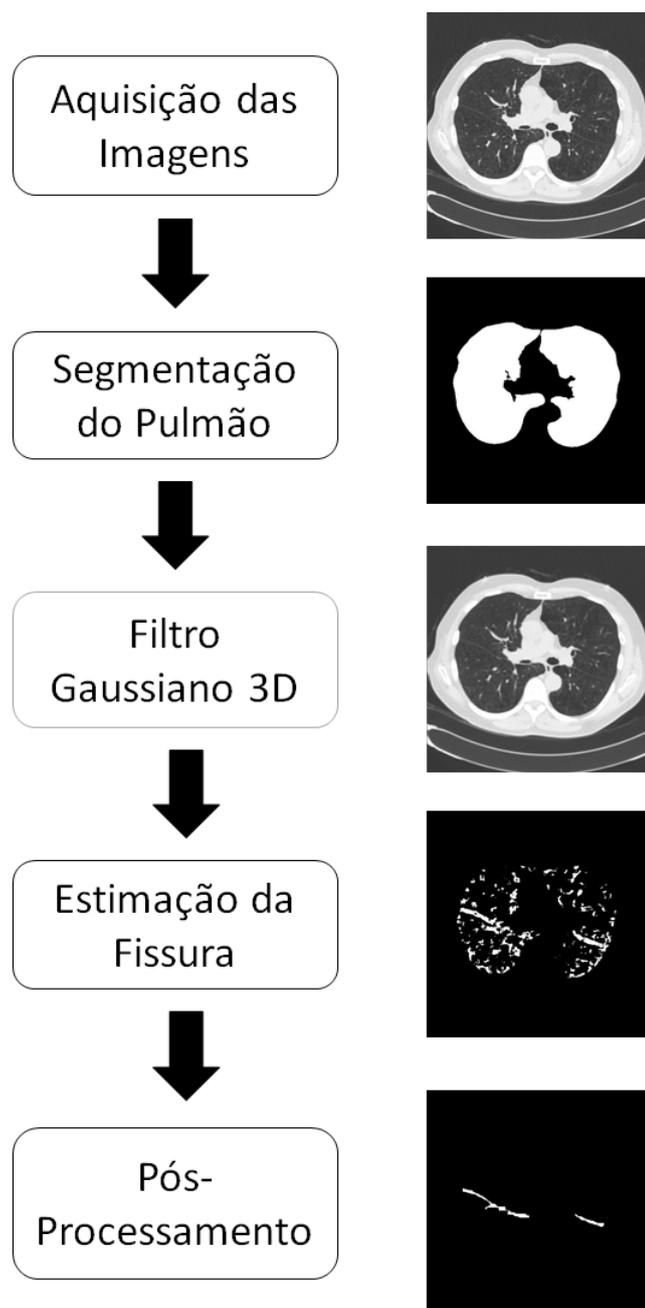


Figura 3.1: fluxograma do método de segmentação de fissuras.

3.1 Aquisição das imagens

As imagens utilizadas neste trabalho fazem parte de um banco de imagens de TC disponibilizadas para fins acadêmicos por LOLA11 em <http://lola11.com/>. O LOLA11 consiste em um banco de dados de imagens de TC de tórax, com anormalidades, que são

utilizadas como base para avaliação de algoritmos de segmentação de estruturas pulmonares.

Lassen et al. (2013), Rikxoort e Bram (2013) utilizam o banco LOLA11 para validação do método de segmentação de lobos pulmonares.

Muitos algoritmos de segmentação de pulmão e lóbulos foram publicados, mas compará-los diretamente é difícil, pois são métodos diferentes e utilizam conjuntos de dados variados para sua validação em seus artigos. Alguns métodos podem ser reimplementados com base na publicação disponível, mas muitas vezes há parâmetros a serem definidos nos quais um profundo conhecimento do método é necessário ou os dados de treinamento utilizados não estão disponíveis ao público. O LOLA11 é um desafio no qual equipes enviam resultados de segmentação de pulmão e lobo das imagens de TC contidas no banco e os mesmos possuem seu desempenho avaliado.

Desta forma, o LOLA11 fornece um conjunto de dados de imagens de TC do tórax com diversas patologias diferentes nos quais foram estabelecidos padrões de referência de segmentações de pulmão e de lóbulos. Entretanto, para realizar a comparação de todos os métodos, é necessário utilizar um padrão comum para todos, o que ocorre no LOLA11 (LOLA11, 2011). Neste trabalho, é analisado a segmentação de fissuras pulmonares, onde apesar de não ser um tema abordado no desafio de LOLA11 é uma etapa de segmentação importante, pois, alguns dos métodos encontrados na literatura necessitam da fissura para realizar a segmentação dos lóbulos.

Nesta etapa, são utilizadas imagens de exames nas posições ápice, hilo e base obtidas a partir de imagens de TC para que possa ser obtido a segmentação através do algoritmo proposto. Todas as imagens utilizadas neste trabalho possuem resolução 512 X 512 *pixels* e 16 *bits* em tons de cinza. Na Tabela 3.1 estão dispostas as características das imagens utilizadas.

Tabela 3.1: informações dos exames utilizados.

Dados das Imagens	Caso LOLA	Número de Fatias	Espessura do Corte (mm)
Exame 1	01	464	0,71
Exame 2	18	411	0,76
Exame 3	23	330	0,68
Exame 4	39	497	0,78
Exame 5	53	339	0,78

3.2 Segmentação do Pulmão e Filtragem Gaussiana 3D

A segmentação da área do pulmão é processada baseada no algoritmo de Kuhnick (2008). O método é iniciado com uma análise da imagem de TC, ver Figura 3.2(a), para identificar a semente e, em seguida, realiza um crescimento de região 2D com um limiar fixo.

O primeiro passo é encontrar um ou mais pontos dentro dos pulmões a fim de se obter os pontos de partida para a segmentação baseada na conectividade de áreas de baixa densidade. No entanto, a segmentação de ambos os pulmões a partir de um ponto de semente pode ser dificultada por condições patológicas, tais como um brônquio obstruído e/ou o colapso completo de um dos pulmões. Por isso, é necessário sempre identificar as áreas de baixa densidade em ambos os lados, restringindo a busca para a parte central dos dados. Para cada pulmão, um ponto de semente é determinado que corresponde a condição de ter valor inferior a -600 HU (as faixas de densidade foram definidas na subseção 2.1).

Para etapa de detecção de fissura, é utilizada uma rede MLP conforme procedimento descrito na seção 2.4.

A imagem original do pulmão pode ser observada na Figura 3.2(a). Desta forma após o algoritmo de segmentação do pulmão é obtida a imagem segmentada como pode ser observada na Figura 3.2(b). Por fim, após a segmentação de todas as fatias do exame de TC é possível obter a reconstrução 3D do pulmão, como pode ser observada na Figura 3.2(c).

A próxima etapa consiste na filtragem, em que é aplicado um filtro gaussiano 3D na imagem com o objetivo de suavizar os componentes de alta frequência da imagem e assim aumentar a eficácia do algoritmo proposto. Neste trabalho é aplicado um filtro gaussiano com $\mu=1\text{mm}$ e máscara de $3 \times 3 \times 3$, estes parâmetros foram obtidos de forma empírica. Na Figura 3.3(a) é ilustrada a imagem original antes da filtragem e na Figura 3.3(b) é ilustrada a imagem resultante após a filtragem.

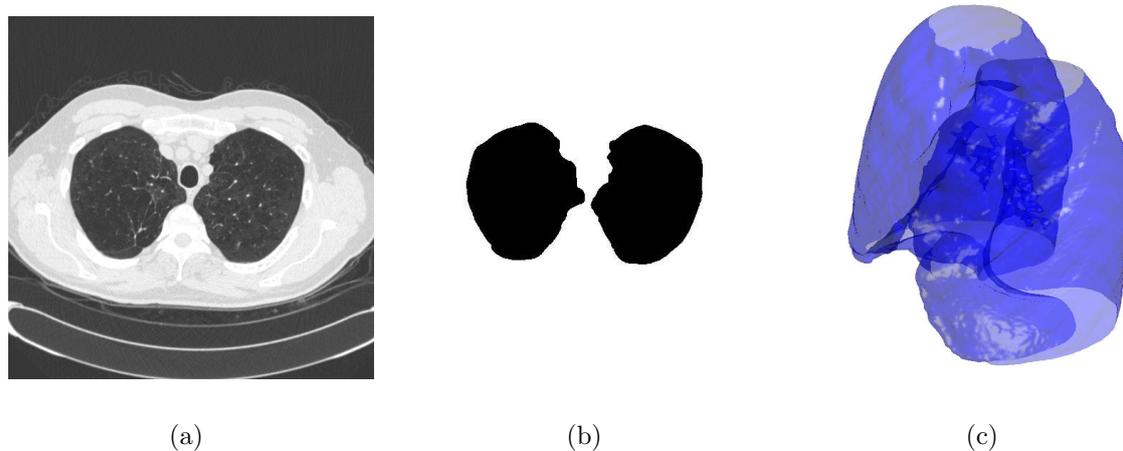


Figura 3.2: imagens a) TC do pulmão, b) resultado da segmentação do Pulmão e c) resultado da segmentação 3D do pulmão.

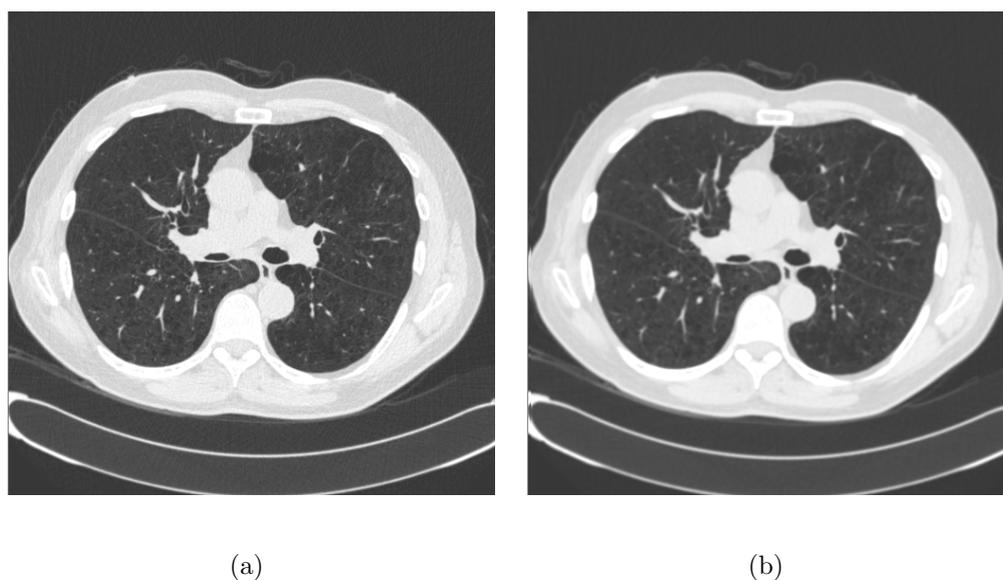


Figura 3.3: filtragem utilizando filtro gaussiano 3D, a) imagem original e b) imagem filtrada.

3.3 Segmentação Automática das Fissuras

O processo de segmentação automática é dividido em duas etapas. A primeira etapa revela-se em uma detecção automática de possíveis fissuras pulmonares, cuja resposta é um parâmetro de entrada para a segunda etapa, que consiste em Crescimento de Região 3D e filtragem por volume.

A rede MLP é uma rede que possui múltiplas camadas, diferente da rede LMS que possui somente uma única camada. De acordo com Rikxoort et al. (2008), a classificação de fissuras pulmonares em imagens de TC pode ser realizada através de uma rede MLP. Neste trabalho foi utilizada uma MLP com duas camadas, uma camada oculta e uma camada de saída. Foi desenvolvida uma rede MLP para o banco de dados utilizado neste trabalho. O treinamento desta MLP ocorreu através do algoritmo de retropropagação do erro (HAYKIN, 2008).

Para detectar as fissuras pulmonares é avaliado um algoritmo baseado em rede MLP utilizando valores de LBP como atributos. A avaliação do método dar-se-á pela comparação dos resultados com um “padrão ouro”, obtido por médicos especialistas.

A rede MLP apresenta três camadas, uma camada de entrada, uma oculta e uma de saída com dois neurônios, já que se possui dois padrões a serem definidos, ou seja, uma saída para indicar se o elemento é pulmão e outra para indicar se é fissura.

Em relação aos dados de entrada, representados por *voxels*, possuem como parâmetros os valores obtidos a partir do histograma do LBP citado na seção 2.5.1 baseados na sua vizinhança. Nesta dissertação é utilizado como parâmetro o $LBP_{8,2}^{u2}$ e para calcular os padrões dos *voxels* é realizado um teste com quatro janelas com diferentes dimensões iguais a 11x11, 15x15, 17x17 e 21x21 *pixels* e o melhor resultado deve ser utilizado.

Desta forma, os dados para treinamento são definidos da seguinte forma: o vetor de entrada consiste em 60 atributos em que 59 são os valores do LBP e o outro valor é o *bias*, os rótulos são 0 ou 1 em que são classificados o pulmão e as fissuras pulmonares.

A determinação da quantidade de neurônios que deve ser utilizada na camada oculta, é uma tarefa complexa (MURATA; YOSHIZAWA; AMARI, 1994), em que geralmente faz-se uso de heurísticas. Assim, utiliza-se uma rede cuja quantidade de neurônios ocultos é igual a duas vezes o número de classes. Logo a rede empregada para classificar as fissuras possui 120 neurônios na camada oculta. A função de ativação utilizada na camada oculta desta rede é a sigmóide logística devido à compatibilidade de sua saída e os valores dos dados. Quanto aos pesos iniciais da rede, são gerados números aleatórios entre -1.5 e +1.5 (SCHIMIDT, 1993). No treinamento da rede define-se uma taxa de aprendizagem decrescente de forma que o seu valor inicial é de 0.5. Assim, a topologia utilizada é 60/120/2, ou seja, 60 entradas, 120 neurônios na camada oculta e 2 de saída.

Na fase de treinamento é formado um banco de dados com 28000 conjuntos de atributos provenientes de 60 imagens selecionadas aleatoriamente do banco de imagens LOLA11. São atribuídos aos *voxels* escolhidos um rótulo igual a 1 caso o mesmo represente parte de

uma fissura, e rótulo igual a -1 caso contrário. Estes rótulos são obtidos de forma manual pelos médicos especialistas.

Em relação ao critério de parada de treinamento da rede, é definido que o treinamento seja finalizado quando a rede passe de 10 épocas sem diminuir o erro quadrático médio, ou se o erro quadrático médio crescer em relação à época anterior. O problema deste critério de parada está relacionado com uma falsa parada através de um mínimo local, ou seja, a rede ainda pode ser treinada, mas pára o treinamento porque atinge um mínimo local. Desta forma, para corrigir este problema são definidos vários pontos de início do treinamento de forma a obter um melhor ponto mínimo global para a rede.

O resultado da rede supervisionada é ilustrado na Figura 3.4.

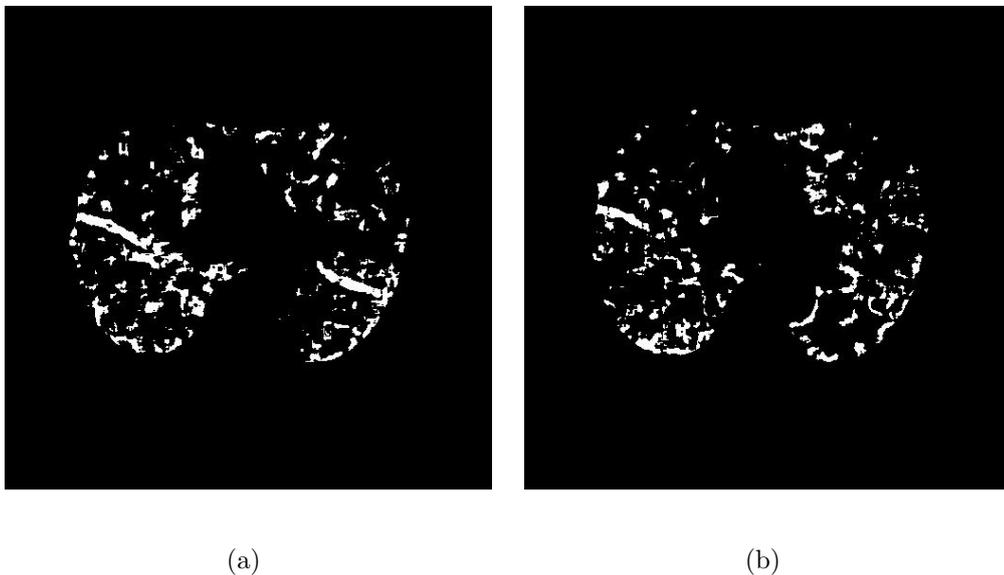


Figura 3.4: imagens resultantes da detecção das fissuras.

Por fim, o resultado da classificação apresentada pela rede MLP pode ser interpretado como uma limiarização supervisionada, nas quais as regiões em branco consistem em regiões com textura semelhante à fissura. Este resultado da limiarização serve como entrada para a próxima etapa que consiste no pós-processamento.

3.4 Pós-Processamento

No pós-processamento é realizada uma análise de componentes conectadas baseada no algoritmo de crescimento de regiões 3D, tendo como dados de entrada as imagens resultantes da limiarização através da rede MLP na etapa anterior.

A partir da imagem limiarizada, é armazenado em um vetor $V = [v_1 \ v_2 \ \dots \ v_n]$ que são os *voxels* rotulados como sementes, ou seja, os *voxels* que são rotulados como fissura pela rede. Deste modo, calcula-se a média μ_s dos componentes desse vetor.

A classificação do *voxel* $v(x, y, z)$ em *fissura* ou *não fissura* é concluída após a realização da etapa de análise de vizinhança.

O processo de análise de vizinhança, ver eq. 3.1, em que é verificado na vizinhança $3 \times 3 \times 3$ do *voxel* a ser classificado, se existe semente

$$Vizinho(x, y, z) = \begin{cases} verdadeiro, & \sum_{i=-1}^1 \sum_{j=-1}^1 \sum_{k=-1}^1 G(x+i, y+j, z+k) > 0, \\ falso, & \text{caso contrário.} \end{cases} \quad (3.1)$$

em que G é o valor do *voxel* que está sendo analisado em relação ao *voxel* central.

A partir do resultado da análise da vizinhança, se o *voxel* vizinho ao *voxel* em análise possuir um valor verdadeiro obtido pela equação 3.1, o mesmo é adicionado ao volume.

A partir da semente, o volume cresce de acordo com a sua vizinhança até que em sua N iteração nenhum *voxel* seja adicionado. O método para identificação de similaridade entre os *voxels* ocorre através do nível de cinza, o qual, se for branco, pertence à classe fissura e preto se for da classe não-fissura. Por fim, os volumes acima de 0,1 ml são mantidos e se forem menores são descartados. O limiar de 0,1 ml foi obtido através da literatura.

A imagem I_r é resultante do CR3D consiste que se $I_r(x, y, z) = 1$ conclui-se que o *voxel* $v(x, y, z)$ pertence à classe fissura pulmonar. Em caso contrário, se $I_r(x, y, z) = 0$, o *voxel* não foi classificado como fissura.

Após o CR 3D, um fechamento através de operação morfológica é aplicado nas imagens. A operação morfológica de fechamento, baseada na metodologia descrita na subseção 2.3.2, é aplicado com um *kernel* 3x3x3 cúbico de *voxels*, com o objetivo de fechar lacunas menores. O elemento estruturante utilizado foi uma esfera de raio igual a 3 *voxels*.

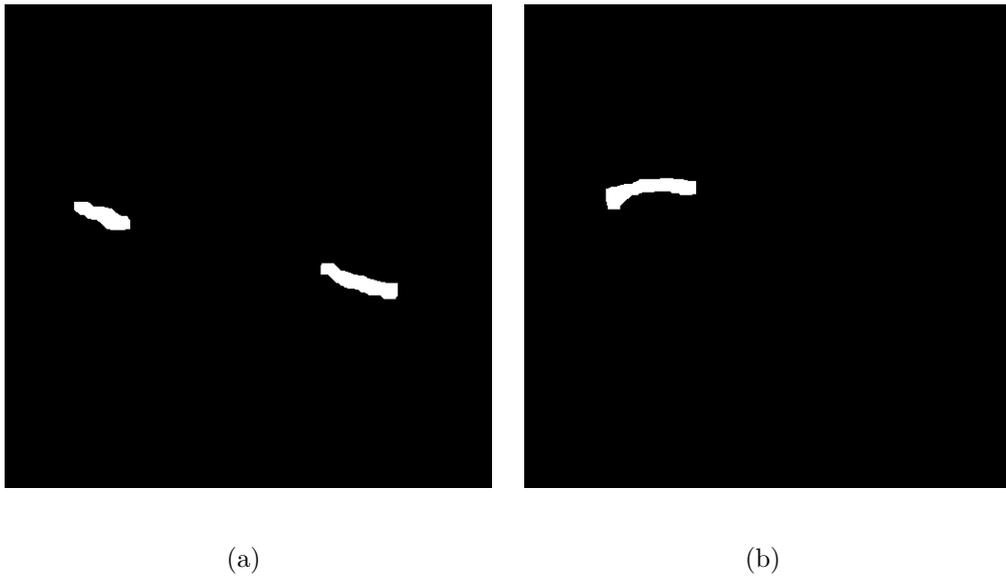


Figura 3.5: imagens após aplicação do método proposto nesta dissertação, a e b) resultados sem afinamento.

Nesta dissertação abordam-se duas metodologias no pós-processamento para se obter os resultados: o primeiro resultado é sem afinamento e o outro resultado é com o afinamento na imagem. Nas Figuras 3.5(a) e 3.5(b) as imagens ilustram os resultados do método proposto sem afinamento no pós-processamento. Já nas Figuras 3.6(a) e 3.6(b) são ilustradas as imagens resultantes do método com o afinamento no fim do algoritmo. Desta forma, é possível observar que a quantidade de *pixels* identificados como fissuras na imagem sem o afinamento é bem maior do que a quantidade de *pixels* identificada na imagem com afinamento que deve influenciar no desempenho das taxas a serem apresentadas no próximo Capítulo.

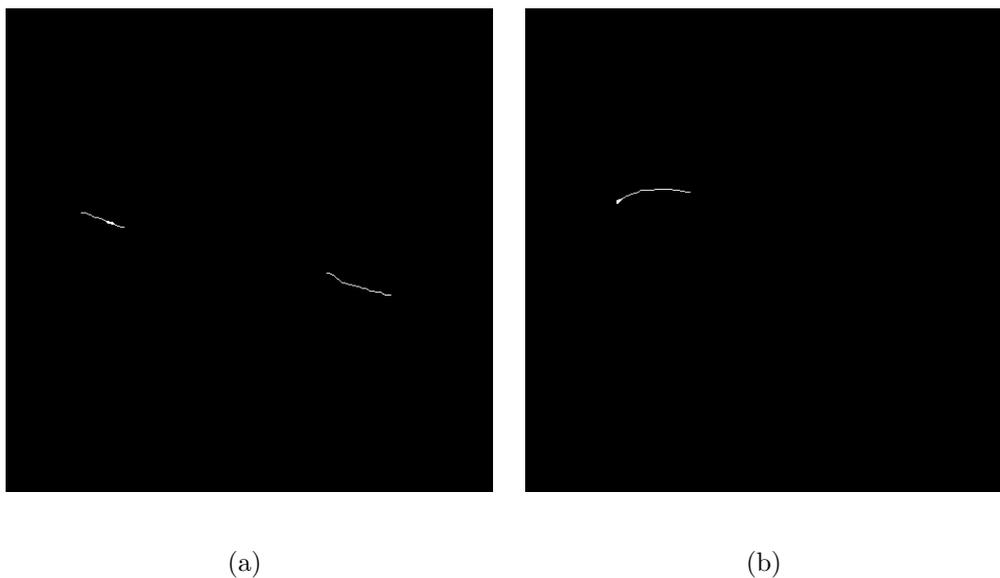


Figura 3.6: imagens após aplicação do método proposto nesta dissertação, a e b) resultados com afinamento.

Para ilustrar o resultado do método, é possível demarcar a fissura na imagem 2D, Figura 3.7(a), como também é possível gerar a imagem 3D do pulmão juntamente com a fissura, Figura 3.7(b). A partir da Figura 3.7(b) é possível identificar o formato resultante da fissura que se aproxima do modelo da fissura real em um pulmão.

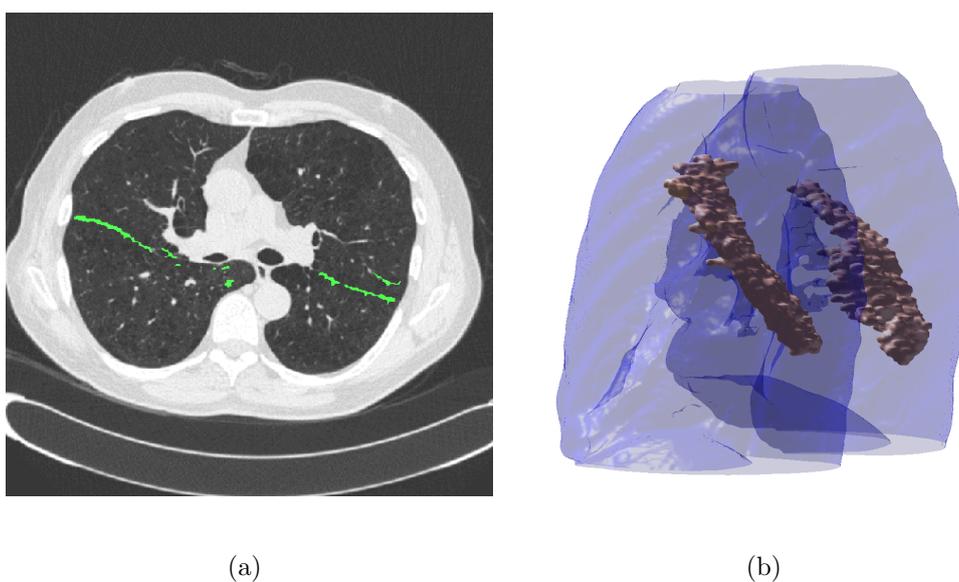


Figura 3.7: imagens da segmentação das fissuras pulmonares, a) resultado da segmentação 2D em verde, e b) resultado da segmentação 3D.

3.5 Criação do Padrão Ouro e do Banco de Dados

Para validação do método é necessário utilizar algum padrão com o qual o resultado do método proposto é comparável. Nesta dissertação, para comparação é utilizado um “padrão ouro”, no total de 100 imagens, representativas de todas as regiões do pulmão que são analisadas por dois médicos especialistas, sendo um doutor pneumologista e um doutor radiologista. Todas as fissuras visíveis são assinaladas individualmente por cada um dos médicos. Na Figura 3.8 são ilustrados dois exemplos de imagens, cujas fissuras pulmonares são assinaladas pelos médicos.

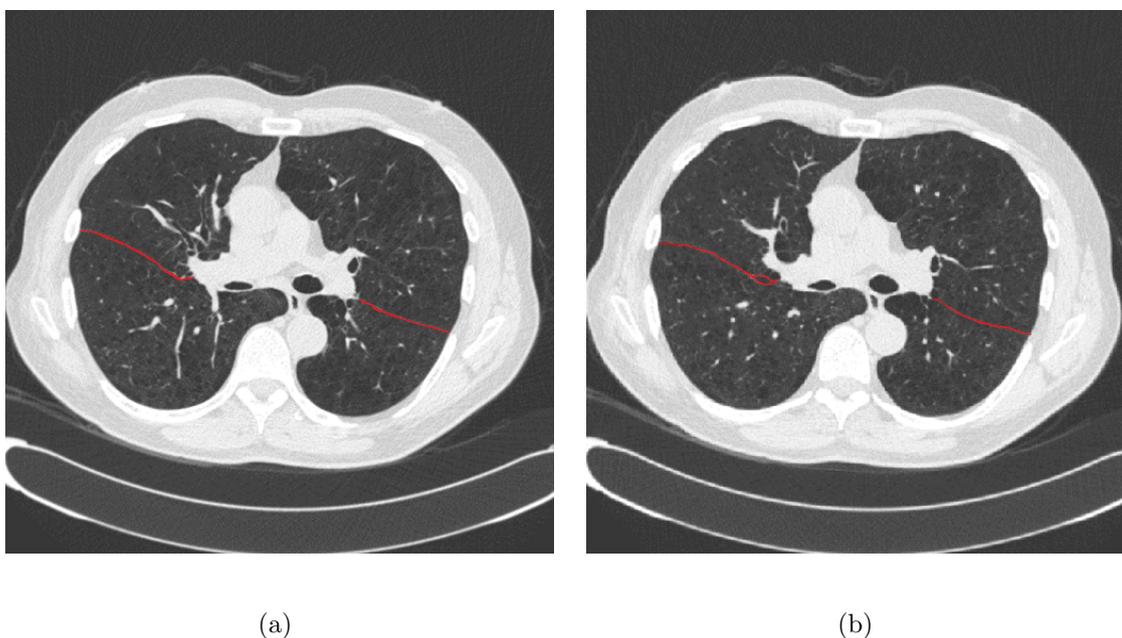


Figura 3.8: imagens de TC do tórax, a) e b) imagens com fissuras pulmonares assinaladas por médico especialista.

Com base nas fissuras discriminadas no banco de imagens é então executado o algoritmo para rotular os *voxels* dos exames de forma a assinalar o que é fissura e o que não é fissura. Utilizam-se 5 exames do LOLA11 como banco de dados de *voxels* do pulmão e da fissura para realizar a análise comparativa.

No conjunto de 100 imagens destinadas à fase de teste, as fissuras são destacadas pelos médicos especialistas de forma manual para servir como padrão-ouro. Para a marcação dos médicos os mesmos destacaram a fissura de forma manual e depois destacaram regiões que não são fissuras. Na Figura 3.9 são ilustrados exemplos destas imagens. Os pontos em vermelho são as fissuras assinaladas pelos médicos.

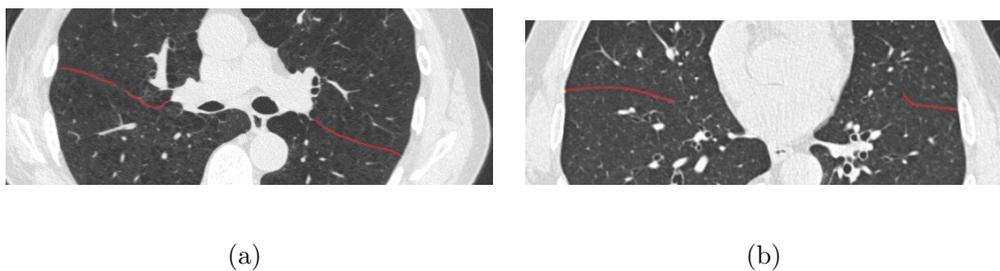


Figura 3.9: imagens ampliadas das fissuras destacadas pelo médico especialista.

O banco de dados foi construído baseado na rotulação manual dos dados através de uma interface desenvolvida, em que manualmente é identificado, pelos médicos especialistas, o que é fissura e o que é pulmão, conforme é ilustrado na Figura 3.10.

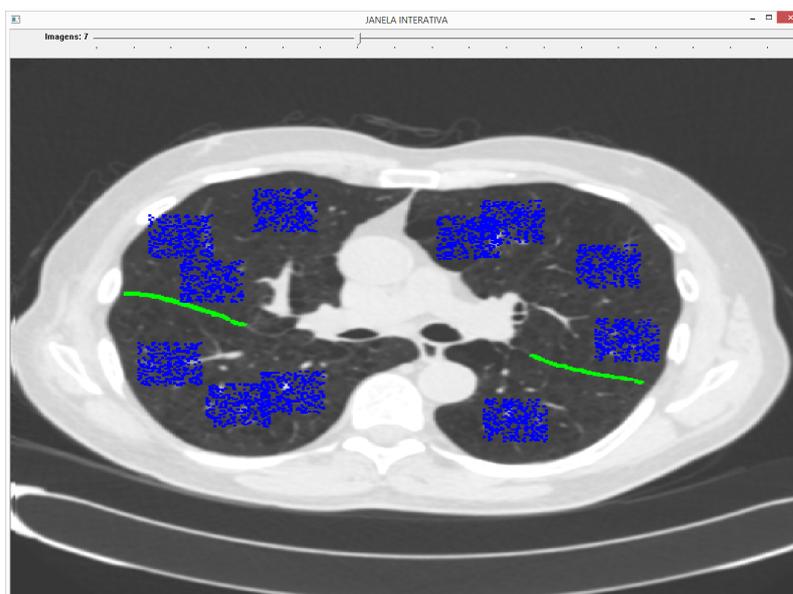


Figura 3.10: interface desenvolvida para criação do banco de dados.

3.6 Métricas de Avaliação

Neste trabalho, o banco de dados selecionado para testes é formado por 20 imagens de cada um dos 5 exames presentes no banco de imagens LOLA11, totalizando 100 imagens e 5699411 *voxels* a serem classificados. As imagens selecionadas são representativas de todas as regiões dos pulmões de 5 exames do LOLA11 e são analisadas por dois médicos especialistas. Os resultados apresentados neste trabalho, são baseados nos *voxels* definidos como fissura após a etapa de pós-processamento.

Os resultados apresentados nessa seção, são baseados nos *voxels* definidos como fissura após a etapa de pós-processamento. Cada voxel é classificado depois do pós-processamento em uma das categorias seguintes:

- Verdadeiros Positivos (VP) - *Voxels* constantes no banco de dados como fissura e classificados como fissura pelo algoritmo.
- Verdadeiros Negativos (VN) - *Voxels* que não constam no banco de dados como fissura e não classificados como fissura pelo algoritmo.
- Falsos Positivos (FP) - *Voxels* que não constam no banco de dados como fissura e classificados como fissura pelo algoritmo.
- Falsos Negativos (FN) - *Voxels* constantes no banco de dados como fissura e não classificados como fissura pelo algoritmo.

Por fim, são calculados o Coeficiente de Similaridade (CS) e Sensibilidade (S) e Especificidade (Es) dados por:

$$CS = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.2)$$

$$S = \frac{VP}{VP + FN} \quad (3.3)$$

$$Es = \frac{VN}{VN + FP} \quad (3.4)$$

O CS mensura a taxa de acerto geral do algoritmo, ou seja, o quão semelhante ao cenário real foi o resultado do algoritmo. A taxa de sensibilidade quantifica o percentual de amostras de fissura que foram classificadas como fissura. Já a taxa de especificidade quantifica o percentual de amostras que não são fissuras e foram classificadas corretamente.

Outra abordagem utilizada na literatura para avaliação de métodos de segmentação de fissuras é baseada na distância média entre a fissura delineada pelo especialista e a fissura resultante através do algoritmo. A métrica utilizada para comparação entre distâncias se baseia na distância euclidiana entre dois pares de pontos no plano cartesiano. A equação que rege o valor da distância média entre a fissura delineada de forma automática e manual é:

$$\bar{x} = \sum_{i=1}^N \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (3.5)$$

onde N é o número de pontos, $P_1(x_1, y_1)$ consiste no par cartesiano da fissura delineada de forma automática, $P_2(x_2, y_2)$ consiste no par cartesiano que possui menor distância para o ponto P_1 .

No próximo capítulo são apresentados os resultados obtidos bem como é realizada uma análise e discussão sobre os mesmos.

Capítulo 4

Resultados

Neste Capítulo o método proposto é aplicado em imagens de TC contidas no banco de dados LOLA11 (LOLA11, 2011). Os métodos são desenvolvidos em C++ com auxílio de funções da biblioteca de visão computacional *OpenSource OpenCV*. Os testes são realizados em um computador com a plataforma *Windows 8.1*, com processador core i7, 8gb de memória RAM e placa de vídeo dedicada. A partir das imagens obtidas e utilizando o algoritmo obtido através das técnicas ilustradas no capítulo 2, as imagens de TC capturadas foram processadas e em cada imagem foram identificados os *voxels* de fissuras e pulmão e assim foram gerados os valores de LBP para cada *voxel*.

Para a obtenção dos resultados primeiramente foi obtida a segmentação do pulmão nas imagens. Logo após foi realizada a filtragem Gaussiana na imagem original utilizando um filtro gaussiano com $\mu=1\text{mm}$ e máscara de $3 \times 3 \times 3$ *voxels*. A partir da imagem resultante da etapa anterior e com a segmentação do pulmão a etapa seguinte consiste na detecção da fissura a partir de uma rede supervisionada com 60 atributos de entrada que são o LBP, 120 neurônios na camada oculta e 2 de saída. Logo após é realizado um CR3D de forma que volumes abaixo de 0,1 ml são descartados e por fim é realizado uma operação morfológica de fechamento utilizando como elemento estruturante uma esfera de raio igual a 3 *voxels*.

Afim de realizar a validação do método proposto é de extrema importância a comparação do mesmo com outro método. Nesta dissertação, é escolhida para comparação a método decrito em Lassen et al. (2013), devido a qualidade dos resultados e a relevância do trabalho na literatura. Este método se baseia em um filtro utilizando matriz Hessiana e nos autovalores da mesma. Este considera a forma da fissura e a força da estrutura da imagem para uma melhor diferenciação entre vasculatura e fissuras. Para atingir a segmentação final através deste método é necessário obter a segmentação dos

vasos sanguíneos previamente. Este método foi implementada a partir do seu descritivo no trabalho de Lassen et al. (2013). Dessa forma, é possível realizar a comparação com o método proposto para as mesmas imagens e padrão ouro. O algoritmo de Lassen et al. (2013) foi campeão do desafio LObe and Lung Analysis 2011, que consiste na avaliação de métodos de segmentação de lóbulos, etapa posterior à segmentação das fissuras.

Neste sentido, para avaliar a eficácia do método de segmentação de fissura proposto, os resultados obtidos são divididos em três etapas: análise da influência da variação do tamanho de janela do LBP, análise do algoritmo de segmentação através de coeficientes estatísticos e análise utilizando a métrica de distância média. Esta análise é realizada a partir de três resultados que são: resultado do método proposto sem afinamento, resultado do método proposto com afinamento e resultado da Lassen et al. (2013).

4.1 Análise da variação do tamanho de janela no LBP

Afim de definir a janela do LBP a ser utilizada no algoritmo, é então realizado um teste com 4 tamanhos de janelas diferentes sendo estes 11x11, 15x15, 17x17 e 21x21 *pixels*. Este teste é realizado para identificar qual é a janela que consegue obter a informação necessária para o classificador obter seu melhor desempenho.

Para a obter os resultados do classificador utilizando diferentes janelas foram utilizadas 100 imagens de 5 exames do LOLA11. Essas imagens foram obtidas de uma sequência de 20 imagens de posições aleatórias dentro dos exames. Baseado na descrição apresentada na secção 3.6, foram calculados os valores em *pixels* de *VP*, *FP*, *VN* e *FN* e assim obtidas as taxas de *Es*, *S* e *CS*.

Os valores de *VP*, *FP*, *VN* e *FN* são ilustrados na Tabela 4.1 no geral por tamanho de janela, já na Tabela 4.2 são ilustrados os valores dos coeficientes *Es*, *S* e *CS* para cada dimensão de janela. Desta forma, é possível inferir, baseado nos coeficientes que o classificador utilizando a janela de 15x15 *pixels* obtém um resultado melhor comparado com as demais janelas, utilizando a métrica das taxas *Es*, *S* e *CS*.

Tabela 4.1: valores de VP, FP, VN e FN por diferentes tamanhos de janela

	11x11	15x15	17x17	21x21
VP	18478	21634	17852	16645
FP	269591	178456	605288	759103
VN	5398753	5489888	5063056	4909241
FN	12589	9433	13215	14422

Tabela 4.2: resultado do classificador por diferentes tamanhos de janela

%	11x11	15x15	17x17	21x21
Es	95,24	96,85	89,32	86,60
S	59,47	69,63	57,46	53,57
CS	96,88	96,18	82,20	77,43

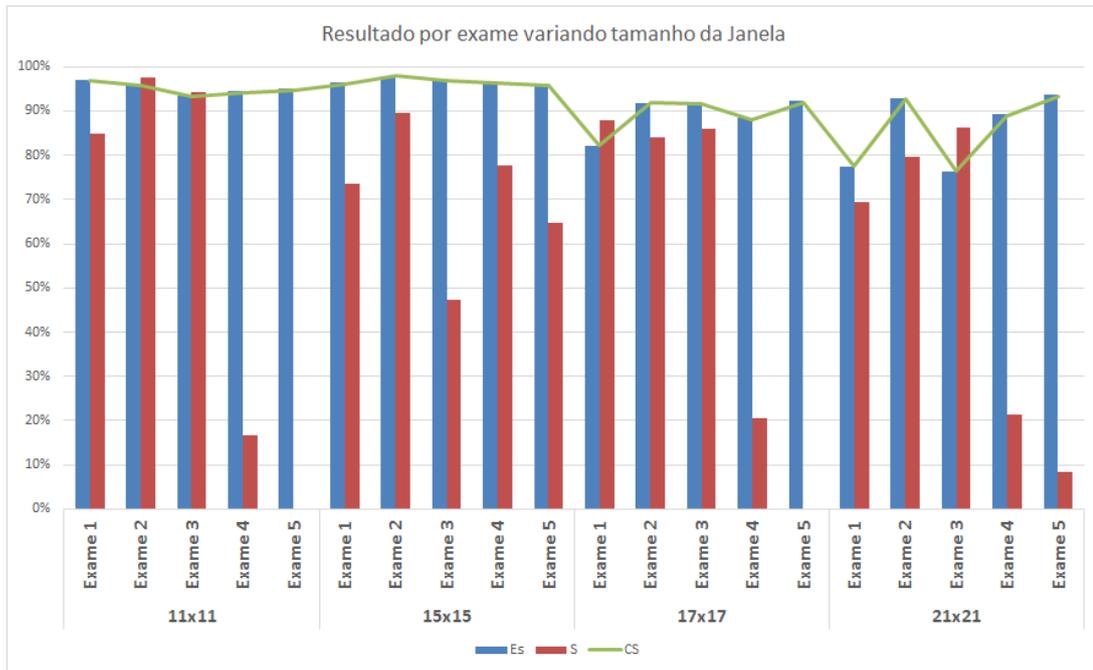


Figura 4.1: gráfico com as taxas $Es(\%)$, $CS(\%)$ e $S(\%)$ em relação a cada exame por tamanho de janela.

Na Figura 4.1 é ilustrado o gráfico resultante desta comparação, sendo possível observar que o resultado do classificador com dados de entrada resultantes do LBP com janela 15x15 se sobressai em relação às taxas de acerto do classificador para as demais janelas de dimensões. Apesar destas dimensões possuírem, em alguns exames, resultados melhores do que a dimensão 15x15, os mesmos possuem uma variação maior, ou seja, essas dimensões de janelas criam uma instabilidade no momento da classificação, isto gera uma variação abrupta na sua taxa de acerto quando os dados de entrada sofrem variações.

Este fato pode ser observado através da Figura 4.2, na qual é ilustrado um gráfico das taxas $Es(\%)$, $CS(\%)$ e $S(\%)$ variando a dimensão da janela e agrupado por exame. Desta forma, é possível identificar essa variação abrupta da taxa de acerto do classificador quando utilizando dimensões de janelas iguais a 11x11, 17x17, 21x21. Neste gráfico, é possível observar que nos exames 1 e 2 o classificador utilizando tamanho de janela 15x15

possui taxa de acerto menor do que os outros, já nos exame 3, 4 e 5 o classificador utilizando a janela de tamanho 15x15 possui uma taxa de acerto maior.

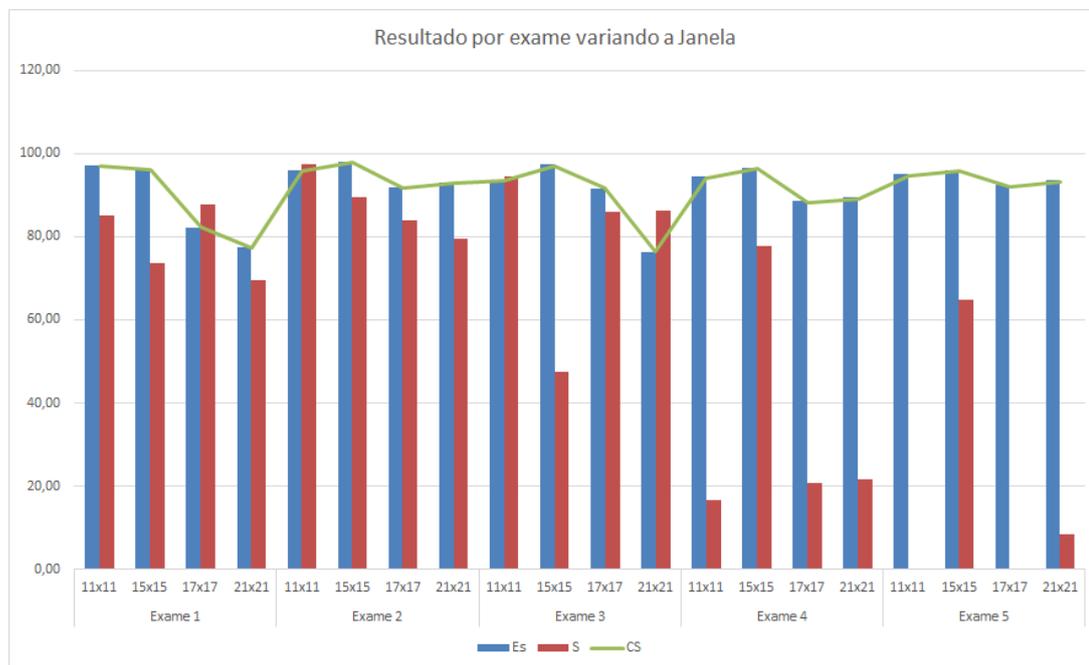


Figura 4.2: gráfico com as taxas $Es(\%)$, $CS(\%)$ e $S(\%)$ em relação a cada tamanho de janela por exame.

Baseado na métrica das taxas $Es(\%)$, $CS(\%)$ e $S(\%)$ é possível determinar que o classificador possui uma melhor taxa de acerto em geral quando utilizado uma janela 15x15 *pixels* como dimensão padrão a ser utilizado para gerar o histograma LBP. Para confirmar a certeza da utilização desta dimensão de janela, é possível realizar a comparação dos resultados baseado em outra métrica, ou seja, através da métrica da distância média e desvio padrão em relação à fissura na imagem segmentada pelo especialista e a imagem segmentada automática.

Tabela 4.3: resultado do classificador por diferentes tamanhos de janela baseado na distância média e desvio padrão

	11x11	15x15	17x17	21x21
Distância média (cm)	4,5216	3,4985	22,9334	36,4953
Desvio padrão (cm)	10,4	7,7	37,4	42,9

Os valores da distância média e desvio padrão entre as fissuras da imagen do padrão ouro e a imagem segmentada automática são ilustrados da Tabela 4.3 por dimensão de janela. Desta forma, confirma-se a análise feita anteriormente, baseada nos valores das

distâncias e dos desvios, o classificador, utilizando a janela de 15x15, obtém um resultado melhor comparado com as dimensões 11x11, 17x17 e 21x21 *pixels*. Analisando os valores da Tabela, pode-se observar que as dimensões 17x17 e 21x21 possuem uma alta distância média e para descartá-las totalmente, os resultados dos desvios padrões também são bastante elevados. Assim, é possível inferir, que utilizando estas dimensões, o classificador fica instável. Comparando com a janela de 11x11 *pixels*, a janela com dimensão 15x15 possui um resultado melhor, pois possui uma distância média e desvio padrão menores.

Outra abordagem é realizar esta comparação por exame, ou seja, obter o valor resultante da distância média e do desvio padrão por exame variando-se as dimensões da janela.

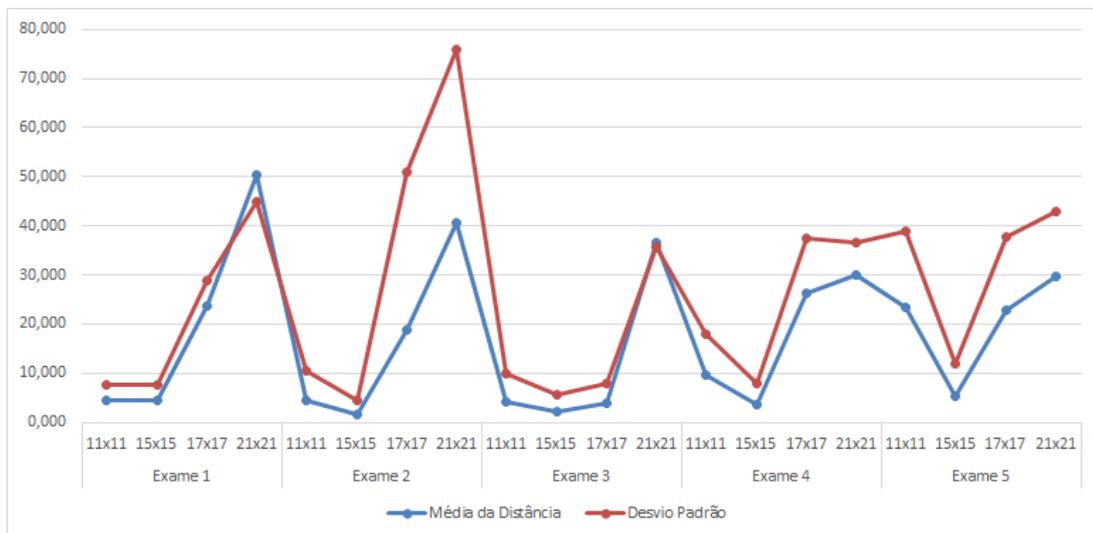


Figura 4.3: gráfico com as distâncias médias e os desvios padrões em relação a cada tamanho de janela por exame.

É ilustrado o gráfico resultante na Figura 4.3 a partir das distâncias médias e os desvios padrões para cada exame comparado em relação à cada dimensão de janela. A partir deste gráfico é possível concluir que o classificador, utilizando a janela de tamanho 15x15 *pixels*, apresenta um resultado melhor, pois, as distâncias médias e seu desvio padrão, na maioria dos exames, são menores comparado com os resultados do classificador para as demais janelas.

Baseado nos resultados ilustrados nesta seção, é possível definir em 15x15 *pixels*, a dimensão de janela a ser utilizada no método proposto. Esta definição foi realizada baseada nos resultados do classificador variando o tamanho da janela para 5 exames e comparados com as métricas de $Es(\%)$, $CS(\%)$, $S(\%)$, distância média e desvio padrão. A justificativa dos resultados apresentados é devida as janelas maiores englobarem uma maior

área de estruturas semelhantes como vasos de pequeno calibre, e às janelas menores não apresentarem uma representatividade de textura suficiente para sua classificação. Após a definição da janela, é possível obter os resultados mais detalhados do método proposto utilizando a janela de 15×15 *pixels*.

4.2 Comparação entre técnicas utilizando CS, S e Es

Na avaliação de algoritmos aplicados em imagens médicas, alguns autores chegam a um padrão ouro por meio da *expertise* de médicos especialistas e validam algoritmos com base na comparação visual ou obtenção de taxas de acerto entre os resultados obtidos e os resultados apresentados no padrão ouro. Em outros trabalhos na área de segmentação de fissuras, uma das métricas utilizadas é a distância média entre a fissura destacada pelo médico e a fissura resultante do algoritmo.

O primeiro teste consiste em obter os valores de VP , FP , VN e FN com a fissura sem afinamento, pois, desta forma a soma dos valores dos Verdadeiros Positivos será maior e então uma taxa maior para CS e S serão obtidas. Na Tabela 4.4 são ilustrados os valores de VP , FP , VN e FN para cada um dos exames baseados nos resultados da classificação da MLP após o pós-processamento.

Tabela 4.4: resultado dos valores VP,FP, VN e FN para fissura sem afinamento.

	Exame 1	Exame 2	Exame 3	Exame 4	Exame 5
VP	6132	3921	3063	4893	3625
FP	41055	27050	24685	38984	46682
VN	1083216	1303774	893728	1087344	1121826
FN	2191	456	3394	1413	1979

Um segundo teste consiste em realizar um afinamento na fissura de forma a obter uma espessura menor, sendo que, quando a técnica é aplicada, o resultado da taxa de acerto reduz-se devido a diminuição da quantidade de FP . O resultado dos valores VP , FP , VN e FN para o teste após o afinamento são ilustrados na Tabela 4.5

O algoritmo implementado baseado em Lassen et al. (2013) também foi aplicado nas imagens utilizadas para validação e o resultado de VP , FP , VN e FN é ilustrado na Tabela 4.6.

Para facilitar a comparação entre os três resultados foram gerados três gráficos com os valores de Es , CS e S de cada método para cada exame. Na Figura 4.4 é possível

Tabela 4.5: resultado dos valores VP,FP, VN e FN para fissura com afinamento.

	Exame 1	Exame 2	Exame 3	Exame 4	Exame 5
VP	213	146	57	230	278
FP	1909	1394	1337	1822	4161
VN	1122362	1329430	917076	1124506	1164347
FN	8110	4231	6400	6076	5326

Tabela 4.6: resultado dos valores VP,FP, VN e FN para Lassen et al. (2013).

	Exame 1	Exame 2	Exame 3	Exame 4	Exame 5
VP	1455	404	36	602	1666
FP	4927	5533	1595	3953	1474
VN	1119344	1325291	916818	1122375	1167034
FN	6868	3973	6421	5704	3938

observar a taxa de Especificidade de cada método para cada exame utilizado.

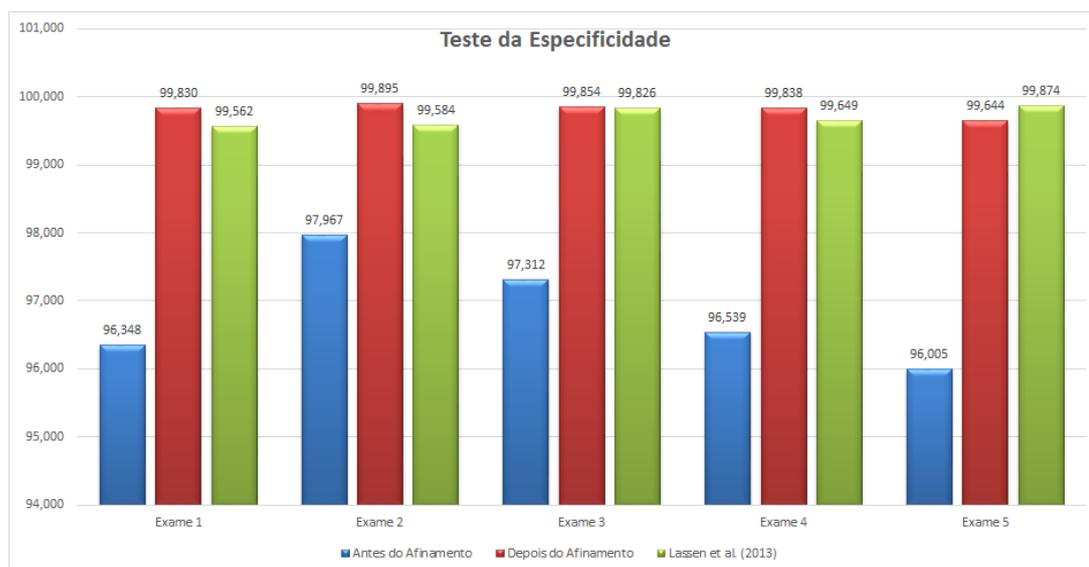


Figura 4.4: gráfico com as taxas $E_s(\%)$ em relação a cada exame.

A partir da Figura 4.4 é possível observar que o método proposto depois do afinamento possui na maioria dos casos uma melhor taxa de Especificidade em relação aos outros métodos, em que a especificidade informa a taxa de acerto do classificador para a classe não-fissura.

É possível observar na Figura 4.5 a taxa do Coeficiente de Similaridade de cada método para cada exame utilizado. Assim, é possível observar que novamente o método proposto com o afinamento possui um melhor resultado na maioria dos exames. O CS mensura a

taxa de acerto do classificador tomando como base tanto acerto da classe da fissura e da não-fissura.

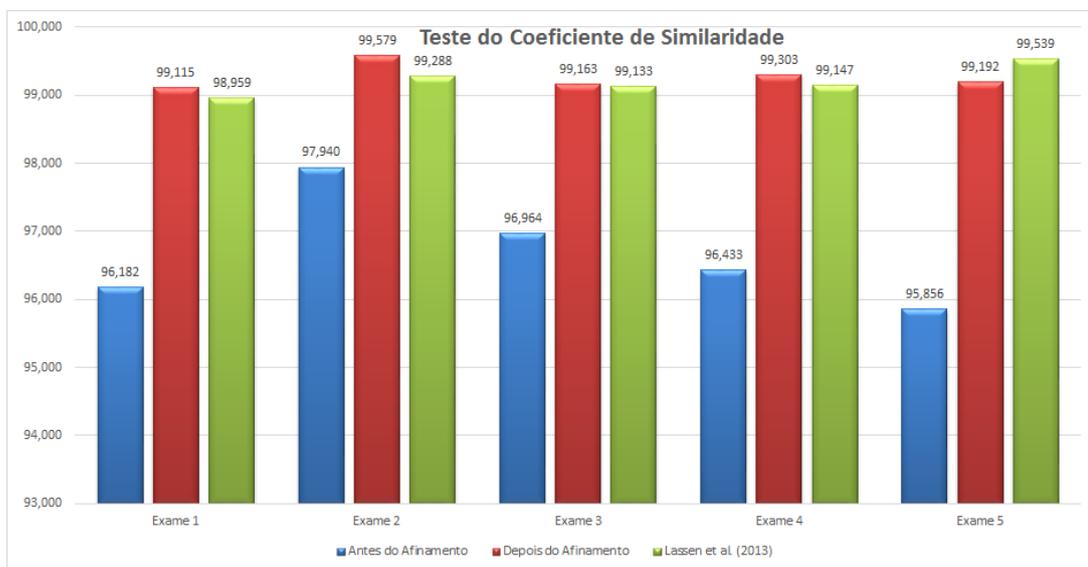


Figura 4.5: gráfico com as taxas $CS(\%)$ em relação a cada exame.

A última comparação das taxas é através da taxa de Sensibilidade (S), que informa a taxa de acerto do classificador para a classe fissura. Na Figura 4.6 é ilustrado o resultado da taxa de Sensibilidade para cada método em cada exame. É interessante observar que o método proposto antes do afinamento obtém um resultado bem acima das outras técnicas. Isto ocorre devido à sua espessura ser maior e desta forma o somatório de VP é maior neste método.

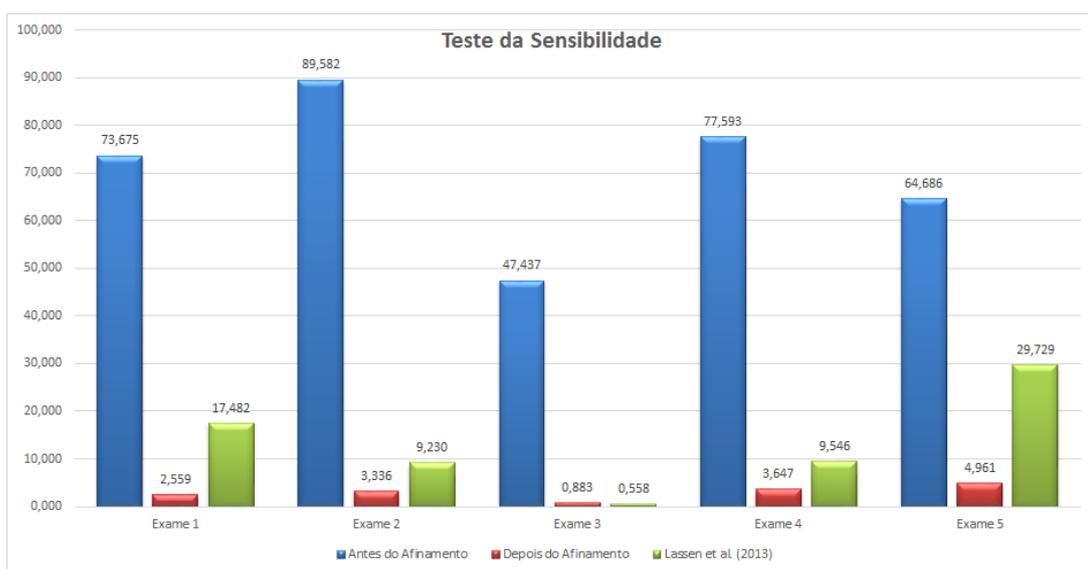


Figura 4.6: gráfico com as taxas $S(\%)$ em relação a cada exame.

Com base nos resultados expostos, ressalta-se o melhor desempenho do algoritmo proposto antes do afinamento ao observar as taxas de CS e Es , pois, seus valores são superiores. Utilizando as taxas CS , S e Es é possível observar o desempenho superior da técnica proposta. A sensibilidade obtém a menor taxa de acerto entre as três taxas, porém ainda se mostra uma taxa satisfatória, uma vez que a classificação é realizada em nível de *voxel*. Logo, mesmo que a fissura detectada pelo algoritmo não possua todos os *voxels*, ainda é possível obter uma representação satisfatória da fissura pulmonar.

Uma abordagem possível para o levantamento do resultado, consiste em calcular as detecções totais não fazendo distinção entre exames. As taxas de acerto dos métodos são ilustradas na Figura 4.7. Observa-se o melhor desempenho do algoritmo proposto sem a utilização do afinamento, pois baseado dos valores de Es , CS e S , o mesmo se sobressai perante os outros métodos, tomando-se como base todos os exames. Analisando a Figura 4.7 é possível observar que o algoritmo proposto obtém uma taxa de acerto para a classe de fissuras de aproximadamente 70%, o que é um valor satisfatório sendo assim suficiente para recomendar a utilização de rede MLP com atributos LBP de imagens de TC para classificação de fissuras pulmonares.

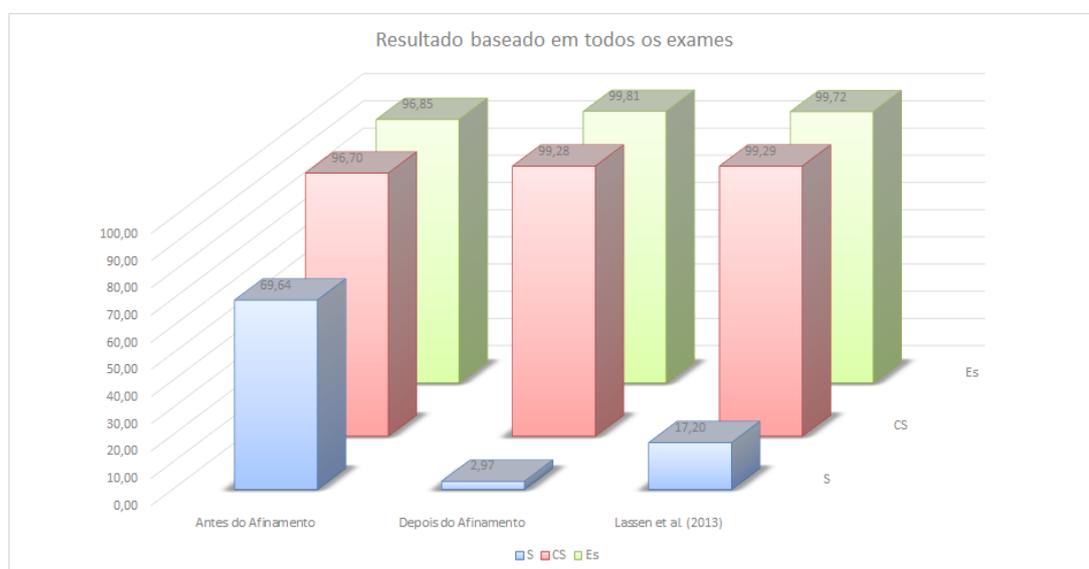


Figura 4.7: gráfico com as taxas para cada método.

O modelo de segmentação de fissuras baseado no método de Lassen et al. (2013) comparado com o resultado obtido pelo método proposto nesta dissertação e sendo baseado nos valores de VP, VN, FP e FN obtém um resultado pior. Desta forma, é importante realizar uma outra análise comparativa que consiste na análise através da distância média entre a fissura segmentada manual e a segmentada automática.

4.3 Comparação entre técnicas utilizando distância média

É ilustrado na Figura 4.8 uma comparação entre as distâncias médias obtidas em cada exame estudado nesta dissertação para cada método aplicado, o método proposto neste trabalho com e sem afinamento e o terceiro método descrito em Lassen et al. (2013).

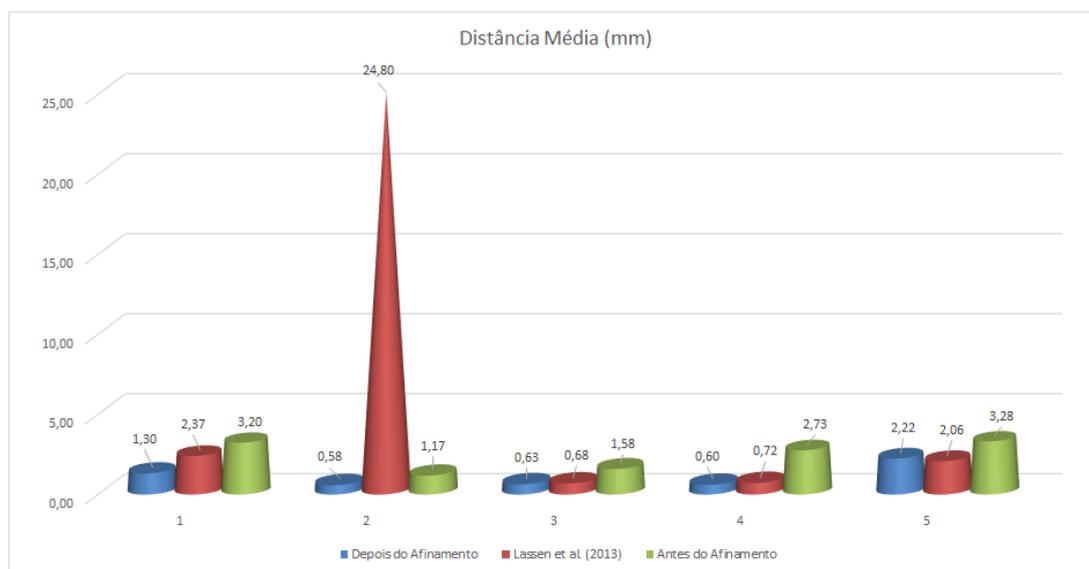


Figura 4.8: distâncias médias para cada exame.

A partir da Figura 4.8 é possível observar que os valores das distâncias médias são bem próximos, o que torna o algoritmo proposto válido. É importante observar que baseado nos valores de Es , S e CS o melhor resultado foi utilizando o método proposto sem afinamento. Já utilizando a métrica da distância média, o método que obtém melhor desempenho foi o método proposto com afinamento. Para confirmar o desempenho do algoritmo proposto nesta dissertação é feita uma análise dos desvios padrões para cada exame. Na Tabela 4.7 são ilustrados os resultados dos desvios padrões para cada exame utilizado para validação nesta dissertação, onde é possível observar que o método proposto, após o afinamento, obtém menor desvio padrão em quatro dos 5 exames, o que comprova que os resultados obtidos possuem uma baixa variância em relação aos dados do padrão-ouro.

Tabela 4.7: resultados pelo Método Proposto.

	Desvio Padrão (mm)				
	Exame 1	Exame 2	Exame 3	Exame 4	Exame 5
Antes do Afinamento	5,46	3,47	3,77	6,26	9,22
Depois do Afinamento	3,11	2,28	2,18	2,03	4,55
Lassen et al. (2013)	4,22	58,32	2,23	2,75	3,80

Vale ressaltar que o algoritmo de Lassen et al. (2013) possui uma maior quantidade de etapas em seu algoritmo, com isso o trabalho proposto possui uma vantagem em relação à Lassen et al. (2013), pois, para a obtenção do resultado final são necessárias somente informações do exame em análise e não há a necessidade de realizar segmentações de outras estruturas pulmonares.

Capítulo 5

Conclusões, Contribuições e Trabalhos Futuros

Esta dissertação aborda um método computacional para a detecção automática de fissuras pulmonares em imagens de TC do tórax. O método proposto consiste na análise de padrões de textura LBP classificados por uma rede neural MLP e posteriormente pós-processados utilizando análise de componentes conectados e morfologia matemática. As imagens utilizadas são provenientes do banco de imagens LOLA11 disponível em <http://lola11.com>.

Para a avaliação dos métodos de segmentação, 100 amostras de imagens do pulmão de 5 exames do LOLA11 foram retirados e foram submetidas à avaliação de um médico especialista na área de Pneumologia do Hospital Universitário Walter Cantídio da Universidade Federal do Ceará. Dentre os métodos de segmentação avaliados a rede MLP utilizando os valores de LBP como atributos e o algoritmo Lassen et al. (2013) obtiveram os maiores percentuais.

Para o conjunto de imagens testadas, o classificador obteve um melhor desempenho para a dimensão, 15×15 *pixels*, da janela utilizada para gerar o histograma do LBP. Para chegar até essa dimensão foram testados os tamanhos 11×11 , 15×15 , 17×17 e 21×21 e os resultados comparados baseados nas métricas de $Es(\%)$, $CS(\%)$, $S(\%)$, distância média e desvio padrão da distância.

Desta forma, para o conjunto de imagens testadas, é inferido que a detecção automática utilizando LBP e MLP apresentam desempenho regular com taxas de $CS = 96,7\%$, $S = 69,6\%$ e $Es = 96,8\%$ para o método proposto antes do afinamento e $CS = 99,2\%$, $S = 3\%$ e $Es = 99,81\%$ para o método proposto com o afinamento no pós-processamento, considerando-se a incidência de falsos positivos e falsos negativos. Deste modo, pode-se

considerar que o algoritmo LBP com MLP obtém desempenho satisfatório por apresentar uma taxa de acerto ligeiramente maior do que 69% e uma quantidade reduzida de falsos negativos. A avaliação de ambos os métodos deu pela comparação dos resultados com um “padrão ouro”, obtido por dois médicos especialistas, sendo um pneumologista e um radiologista.

Uma outra abordagem de análise dos resultados para esta dissertação foi a distância média, na qual o resultado do algoritmo proposto sem e com afinamento final é comparado com o algoritmo de Lassen et al. (2013). O algoritmo proposto com afinamento obteve uma menor distância e um menor desvio padrão comparado com o método de Lassen et al. (2013).

Nesse sentido, as maiores taxas de acerto, a maior representatividade das detecções *VP* dos resultados do algoritmo e a menor distância média entre a fissura segmentada manual e a automática são motivos suficientes para recomendar a utilização da detecção de fissuras pulmonares baseada em MLP e LBP.

Uma outra conclusão importante é que o método de segmentação de fissura baseada em LBP e MLP apresenta um desempenho uniforme nas imagens, possuiu uma taxa alta de acerto em todos os exames, e não utiliza informações anatômicas do pulmão, o que em alguns casos pode falhar devido a alguma doença. Outra característica do método proposto é a segmentação automática, onde não há necessidade de interação entre o usuário e o método. Por fim, é importante ressaltar que o método proposto não utiliza informações de segmentações de outras estruturas pulmonares, diferentemente do algoritmo de Lassen et al. (2013) que utiliza a segmentação dos vasos sanguíneos para realizar a segmentação das fissuras.

Diversas contribuições são resultantes desta dissertação, dentre as quais merece destaque a segmentação automática das fissuras pulmonares em imagens de TC. Enfatiza-se a falta de registros na literatura de algoritmos semelhantes com tais contribuições. Além destas, pode-se citar outras contribuições como:

- novo método de segmentação de fissuras baseado em MLP e Texturas LBP;
- análise entre os métodos de detecção MLP com LBP e Lassen et al. (2013);
- obtenção de um conjunto de imagens, denominado “padrão ouro”, em que todas as fissuras pulmonares estão assinaladas.

Para trabalhos futuros, sugerem-se

- realizar a expansão do método LBP para 3D com o intuito de uma melhor generalização da classe fissura e a classe não-fissura;
- realizar o teste com a MLP utilizando como atributo a matriz hessiana de cada *voxel* no exame;
- realizar a segmentação dos lóbulos baseada na detecção da fissura proposta neste trabalho; e
- realizar a integração ao sistema de auxílio ao diagnóstico *Lung Image System Analysis*.

Referências Bibliográficas

AHONEN, T.; HADID, A.; PIETIKAINEN, M. Face description with local binary patterns: Application to face recognition. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 28, n. 12, p. 2037–2041, Dec 2006. ISSN 0162-8828.

ALEXANDRIA, A. R. de. *Sistema de reconhecimento óptico de algarismos para medidores convencionais de energia*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2005.

ALMEIDA, M. A. D. *Repercussões agudas da ventilação não invasiva sobre o fluxo sanguíneo cerebral e a função cognitiva de pacientes com doença pulmonar obstrutiva crônica e indivíduos sadios*. Tese (Doutorado) — Universidade Federal do Ceará, 2011.

ARBIB, M. A. *The handbook of Brain Theory and Neural Networks*. [S.l.]: M.I.T Press, 2003.

ARIYÜREK, M. O.; GÜLSÜN, M.; DEMIRKAZIK, F. Accessory fissures of the lung: evaluation by high-resolution computed tomography. *European Radiology*, Springer-Verlag, v. 11, n. 12, p. 2449–2453, 2001. ISSN 0938-7994. Disponível em: <<http://dx.doi.org/10.1007/s003300100852>>.

AZEVEDO, F. M. de; BRASIL, L. M.; OLIVEIRA, R. C. L. de. *Redes Neurais com aplicações em Controle e em Sistemas Especialistas*. [S.l.]: Visual Books, 2000.

BANON, G. J. F.; BARREIRA, J. *Bases da Morfologia Matemática para a análise de imagens binárias*. 2ed. ed. [S.l.]: INPE, 1998.

BERNSEN, J. Dynamic thresholding of gray-level images. In: *International Conference on Pattern Recognition*. [S.l.: s.n.], 1986.

BISHOP, C. M. *Pattern Recognition and Machine Learning*. [S.l.]: Springer, 2006.

BOING, A. F.; ROSSI, T. E. Tendência temporal e distribuição espacial da mortalidade por câncer de pulmão no Brasil entre 1979 e 2004: magnitude, padrões regionais e diferenças entre sexos. *Jornal Brasileiro de Pneumologia*, v. 33, p. 544–551, 2007.

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

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

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

CHRISTODOULOU, C.; MICHAELIDES, S.; PATTICHIS, C. Multifeature texture analysis for the classification of clouds in satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, v. 41, p. 2662–2668, 2003.

DHAWAN, A. P.; HUANG, H. K.; KIM, D.-S. *Principles and Advanced Methods in Medical Imaging and Image Analysis*. [S.l.]: World Scientific, 2008.

DOSHI, N.; SCHAEFER, G. A comparative analysis of local binary pattern texture classification. *Visual Communications and Image Processing*, p. 1–6, 2012.

DOUGHERTY, G. *Digital Image Processing for Medical Applications*. [S.l.]: Cambridge, 2009.

DRUMMOND, G. B. Computed tomography and pulmonary measurements. *British Journal of Anaesthesia*, Edinburgh-Royal Infirmary, v. 80, p. 665–671, 1998.

EPSTEIN, C. L. *The Mathematics of Medical Imaging*. [S.l.]: Prentice Hall, 2003.

FÉLIX, J. H. da S. *Sistema de Visão Computacional para Detecção e quantificação de enfisema pulmonar*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2007.

FELIX, J. H. S.; CORTEZ, P. C.; HOLANDA, M. A.; COSTA, R. C. S. Automatic segmentation and measurement of the lungs in healthy persons and in patients with chronic obstructive pulmonary disease in CT images. *IFMBE Proceedings*, v. 18, p. 370–373, Outubro 2007.

- FRANGI, A. F.; NIESSEN, W. J.; VINCKEN, K. L.; VIERGEVER, M. A. Multiscale vessel enhancement filtering. In: WELLS, W.; COLCHESTER, A.; DELP, S. (Ed.). *Medical Image Computing and Computer-Assisted Intervention*. Springer Berlin Heidelberg, 1998, (Lecture Notes in Computer Science, v. 1496). p. 130–137. ISBN 978-3-540-65136-9. Disponível em: <<http://dx.doi.org/10.1007/BFb0056195>>.
- FROTA, R. A. *Avaliação de algoritmos de redes neurais artificiais em tarefas de detecção de novidades: uma abordagem unificadora*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2005.
- GEVENOIS, P. A.; YERNAULT, C. Can computed tomography quantify pulmonary emphysema. *European Respiratory Journal*, n. 5, p. 843–848, 1995.
- GLASBEY, C. A. Na analysis of histogram-based thresholding algorithms. *CVGIP: Graphical Models and Image Processing*, v. 55, p. 532–537, 1993.
- GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. I. *Digital Image Processing*. 3rd. ed. Knoxville: Gatesmark Publishing, 2009.
- GUO, Z.; ZHANG, D.; ZHANG, D. A completed modeling of local binary pattern operator for texture classification. *Image Processing, IEEE Transactions on*, v. 19, n. 6, p. 1657–1663, June 2010. ISSN 1057-7149.
- HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 3, p. 610–621, 1973.
- HAYKIN, S. O. *Neural Networks and Learning Machines*. [S.l.]: Pearson Prentice Hall, 2008.
- HEIDJEN, F. V. *Image based measurement systems object recognition*. New York: Wiley, 1995.
- HENDEE, W. R.; RITENOUR, E. R. *Medical Imaging Physics*. [S.l.]: Wiley-Liss, 2002.
- HOUNSFIELD, G. N. Computerized transverse axial scanning (tomography): Part 1. description of system. *British Journal of Radiology*, v. 46, p. 1016–1022, 1973.
- HUANG, G.-B.; CHEN, L.; SIEW, C.-K. Universal approximation using incremental constructive feedforward networks with random hidden nodes. *IEEE Transactions on Neural Networks*, v. 17, p. 879–892, 2006.

- HUANG, X.; LI, S.; WANG, Y. Shape localization based on statistical method using extended local binary pattern. In: *Multi-Agent Security and Survivability, 2004 IEEE First Symposium on*. [S.l.: s.n.], 2004. p. 184–187.
- INCA. Instituto nacional de câncer ministério da saúde. Brasília: Ministério da Saúde, august 2014.
- JAIN, A. K. *Fundamentals of Digital image Processing*. [S.l.]: Prentice Hall, 1989.
- JUNIOR, J. de M. S.; CORTEZ, P.; BACKES, A. Color texture classification using shortest paths in graphs. *Image Processing, IEEE Transactions on*, v. 23, n. 9, p. 3751–3761, Sept 2014. ISSN 1057-7149.
- JUNIOR, J. J. de M. S.; BACKES, A. R.; CORTEZ, P. C. Color texture classification based on gravitational collapse. *Pattern Recognition*, v. 46, n. 6, p. 1628 – 1637, 2013. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320312005353>>.
- KAK, A. C.; SLANEY, M. *Principles of Computerized Tomographic Imaging*. Nova York, EUA: IEEE Engineering in Medicine and Biology Society, 1999. ISBN O-87942-198-3.
- KALENDER, W. A. Review: X-ray computed tomography. *Physics in Medicine and Biology*, v. 51, n. 13, p. 29–43, Junho 2006.
- KASHYAP, R.; KHOTANZAD, A. A model-based method for rotation invariant texture classification. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-8, n. 4, p. 472–481, July 1986. ISSN 0162-8828.
- KUHNIGK, J.-M. *Quantitative Analysis of Lung Morphology and Function in Computed Tomographic Images*. Tese (Doutorado), 2008.
- KUMAR., S. N.; KAVITHA, V. Automatic segmentation of lung lobes and fissures for surgical planning. In: *International Conference on Emerging Trends in Electrical and Computer Technology*. [S.l.: s.n.], 2011.
- LASSEN, B.; RIKXOORT, E. M. van; SCHIMIDT, M.; KERKSTRA, S.; GINNEKEN, B. van; KUHNIGK, J.-M. Automatic segmentation of the pulmonary lobes from chest ct scans based on fissures, vessels, and bronchi. *IEEE Transactions on Medical Imaging*, v. 32, p. 210–222, 2013.

LI, B.; CHRISTENSEN, G. E.; HOFFMAN, E. A.; MCLENNAN, G.; REINHARDT, J. M. Establishing a normative atlas of the human lung. *Academic Radiology*, v. 10, n. 3, p. 255–265, 2003.

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

LOLA11. *LObe and Lung Analysis*. 2011. Disponível em: <<http://www.lola11.com/>>.

LOSSON, O.; MACAIRE, L. Colour texture classification from colour filter array images using various colour spaces. *Image Processing IET*, p. 1192–1204, 2012.

MADANI, A.; KEYZER, C.; GEVENOIS, P. A. Quantitative computed tomography assessment of lung structure and function in pulmonary emphysema. *European Respiratory Journals*, v. 18, n. 8, p. 720–730, 2001.

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

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

MARKMAN, B. F. *A ecocardiografia de estresse com dobutamina na doença coronária*. Dissertação (Mestrado) — Faculdade de Medicina da Universidade Federal de Pernambuco, Recife, set. 1997.

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

MEDEIROS, C. M. de S. *Uma Contribuição ao problema de seleção de modelos neurais usando o princípio de máxima correlação dos erros*. Tese (Doutorado) — Universidade Federal do Ceará, 2008.

MINSKY, M.; PAPER, S. *Perceptrons*. [S.l.]: M.I.T Press, 1969.

M.PAKDEL; F.TAJERIPOUR. Texture classification using optimal gabor filters. In: *1st International eConference on Computer and Knowledge Engineering* (. [S.l.: s.n.], 2011.

- MURATA, N.; YOSHIZAWA, S.; AMARI, S.-I. Network information criterion-determining the number of hidden units for an artificial neural network model. *Neural Networks, IEEE Transactions on*, v. 5, n. 6, p. 865–872, Nov 1994. ISSN 1045-9227.
- NEMA. *Digital Imaging and Communications in Medicine*. 2014. Disponível em: <<http://dicom.nema.org/>>.
- NIBLACK, W. *An Introduction to Digital Image Processing*. [S.l.]: Prentice Hall, 1986.
- OCHS, R. A.; GOLDIN, J. G.; ABTIN, F.; KIM, H. J.; BROWN, K.; BATRA, P.; ROBACK, D.; MCNITT-GRAY, M. F.; BROWN, M. S. Automated classification of lung bronchovascular anatomy in {CT} using adaboost. *Medical Image Analysis*, v. 11, n. 3, p. 315 – 324, 2007. ISSN 1361-8415. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841507000278>>.
- OJALA, T.; MAENPAA, T.; PIETIKAINEN, M.; VIERTOLA, J.; KYLLONEN, J.; HUOVINEN, S. Outex – new framework for empirical evaluation of texture analysis algorithms. In: *Pattern Recognition, 2002. Proceedings. 16th International Conference on*. [S.l.: s.n.], 2002. v. 1, p. 701–706 vol.1. ISSN 1051-4651.
- OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, v. 29, n. 1, p. 51 – 59, 1996. ISSN 0031-3203. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0031320395000674>>.
- OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution grayscale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 34, p. 971–987, 2002.
- OLIVEIRA, L. R. de; CORTEZ, P. C.; CARVALHO, A. Telemedicina e interiorização do ensino médico. *IX Congresso Brasileiro de Informática em Saúde*, p. 38 – 42, 2004.
- PRATT, W. K. *Digital Image Processing*. [S.l.]: PIKS Scientific Inside, 2007.
- PU, J.; LEADER, J. K.; ZHENG, B.; KNOLLMANN, F.; FUHRMAN, C.; SCIURBA, F. C.; GUR, D. A computational geometry approach to automated pulmonary fissure segmentation in ct examinations. *IEEE Transactions on Medical Imaging*, v. 28, p. 710–719, 2009.

- RANDEN, T.; HUSOY, J. Filtering for texture classification: a comparative study. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 21, n. 4, p. 291–310, Apr 1999. ISSN 0162-8828.
- REBOUÇAS FILHO, P. P. *MCA Crisp: nova técnica de segmentação dos pulmões em imagens de Tomografia Computadorizada baseada no Método de Contorno Ativo*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2010.
- RIBEIRO, A. B. N. *Segmentação dos Vasos Sanguíneos Pulmonares em Imagens de Tomografia Computadorizada do Tórax*. Dissertação (Mestrado) — Universidade Federal do Ceará, 2013.
- RIKXOORT, E. M. van; BRAM. Automated segmentation of pulmonary structures in thoracic computed tomography scans: a review. *Physics in Medicine and Biology*, v. 58, n. 17, p. 187–220, 2013.
- RIKXOORT, E. M. van; GINNEKEN, B. van; KLIK, M.; PROKOP, M. Supervised enhancement filters: Application to fissure detection in chest ct scans. *IEEE Transactions on Medical Imaging*, v. 27, p. 1–10, 2008.
- RITTER, F.; BOSKAMP, T.; HOMEYER, A.; LAUE, H.; SCHWIER, M.; LINK, F.; PEITGEN, H. O. Medical image analysis. *Pulse, IEEE*, v. 2, n. 6, p. 60–70, Nov 2011. ISSN 2154-2287.
- RUCK, D. W.; ROGERS, S. K.; KABRISKY, M.; OXLEY, M. E.; SUTER, B. W. The multilayer perceptron as an approximation to a bayes optimal discriminant function. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, v. 1, 1990.
- SABINO, D.; COSTA, L.; RIZZATTI, E.; ZAGO, M. A texture approach to leukocyte recognition. *Real-Time Imaging*, v. 10, p. 205–216, 2004.
- SAPTHAGIRIVASAN, V.; MAHADEVAN, V. Denoising and fissure extraction in high resolution isotropic ct images using dual tree complex wavelet transform. In: *International Conference on Software Technology and Engineering*. [S.l.: s.n.], 2010.
- SATO, Y.; WESTIN, C. F.; BHALERAJ, A.; NAKAJIMA, S.; SHIRAGA, N.; TAMURA, S.; KIKINIS, R. Tissue classification based on 3d local intensity structures for volume rendering. *Visualization and Computer Graphics, IEEE Transactions on*, v. 6, n. 2, p. 160–180, Apr 2000. ISSN 1077-2626.

- SCHIMIDT, W. Initialization, backpropagation and generalization of feed-forward classifiers. *IEEE International Conference on Neural Networks*, v. 1, p. 598–604, 1993.
- SHAPIRO, L.; STOCKMAN, G. *Computer Vision*. [S.l.]: Prentice Hall, 2000.
- SIEGWART, R.; NOURBAKHSH, I. R. *Introduction to Autonomous Mobile Robots*. [S.l.]: The MIT Press, 2004.
- SILVA, J. S. S. *Segmentação Pulmonar em Estudos de Tomografia*. Dissertação (Mestrado) — Universidade de Aveiro, 2005.
- SLUIMER, I.; PROKOP, M.; GINNEKEN, B. Toward automated segmentation of the pathological lung in ct. *IEEE Transactions on Medical Imaging*, v. 24, n. 8, p. 1025–1038, agosto 2005.
- SONKA, M.; HLAVAC, V.; BOYLE, R. *Image Processing, Analysis, and Machine Vision*. [S.l.]: CL Engineering, 2007.
- STERN, E. J.; SWENSEN, S. J. *High-Resolution CT of the chest*. [S.l.]: Maple Press, 2001.
- SUAPANG, P.; DEJHAN, K.; YIMMUN, S. Medical image archiving, processing, analysis and communication system for teleradiology. In: *TENCON 2010 - 2010 IEEE Region 10 Conference*. [S.l.: s.n.], 2010. p. 339–345. ISSN pending.
- UGALDE, P.; CAMARGO, J. de J.; DESLAURIERS, J. Lobes, fissures, and bronchopulmonary segments. *Thoracic Surgery Clinics*, v. 17, n. 4, p. 587 – 599, 2007. ISSN 1547-4127. Thoracic Anatomy, Part I Chest Wall, Airway, Lungs. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1547412706001125>>.
- UKIL, S.; REINHARDT, J. Anatomy-guided lung lobe segmentation in x-ray ct images. *Medical Imaging, IEEE Transactions on*, v. 28, n. 2, p. 202–214, Feb 2009. ISSN 0278-0062.
- WANG, J.; BETKE, M.; KO, J. P. Pulmonary fissure segmentation on {CT}. *Medical Image Analysis*, v. 10, n. 4, p. 530 – 547, 2006. ISSN 1361-8415. Special Issue on Functional Imaging and Modelling of the Heart (FIMH 2005). Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841506000338>>.
- WANG, X.; NICOLAS; GEORGANAS, D.; PETRIU, E. M. Fabric texture analysis using computer vision techniques. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, v. 60, p. 44–56, 2011.

- WANG, Z.; MENG, X.; ZHAO, Y.; XUE, H.; LI1, Q.; LI1, J.; ZHANG1, T.; CHEN1, Y. Lung lobe segmentation based on hrct data. *Biomedical Engineering and Computer Science (ICBECS)*, p. 1–4, 2010.
- WEBB, W. R.; MULLER, N. L.; NAIDICH, D. P. *High-Resolution CT of the LUNG*. [S.l.]: Ma, 2001.
- WEBSTER, J. G. *Medical instrumentation application designer*. 3rd. ed. USA: John Wiley and Sons Inc., 1998.
- WIDROW, B.; WINTER, R. Neural nets for adaptative filtering and adaptative pattern recognition. *IEEE Computer*, v. 21, p. 25–39, 1988.
- WIEMKER, R.; BÜLOW, T.; BLAFFERT, T. Unsupervised extraction of the pulmonary interlobar fissures from high resolution thoracic {CT} data. *International Congress Series*, v. 1281, n. 0, p. 1121 – 1126, 2005. ISSN 0531-5131. {CARS} 2005: Computer Assisted Radiology and Surgery Proceedings of the 19th International Congress and Exhibition. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0531513105003535>>.
- WINKELER, G. F. P. *Efeitos Agudos da Administração de Pressão Positiva Contínua em Vias Aéreas de Modo não Invasivo Sobre o Parênquima Pulmonar de Voluntários Sadios nas Posições Supina e Prona: Alterações na Tomografia Computadorizada de Alta Resolução*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2006.
- YILDIZ, A.; GOLPINAR, F.; CALIKOGLU, M.; DUCE, M. N.; OZER, C.; APAYDIN, F. {HRCT} evaluation of the accessory fissures of the lung. *European Journal of Radiology*, v. 49, n. 3, p. 245 – 249, 2004. ISSN 0720-048X. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0720048X03001372>>.
- YOSHIKAWA, K.; TSUBOTA, N.; KODAMA, K. Prospective study of extended segmentectomy for small lung tumors. In: *The Annals of Thoracic Surgery*. [S.l.: s.n.], 2002. v. 73.
- ZAMBONI, M.; CARVALHO, W. R. *Câncer do pulmão*. [S.l.]: Atheneu, 2005.
- ZHANG, L.; HOFFMAN, E. A.; REINHARDT, J. M. Atlas-driven lung lobe segmentation in volumetric x-ray ct images. *IEEE Transactions on Medical Imaging*, v. 25, p. 1–15, 2006.

ZHAO, G.; PIETIKAINEN, M. Dynamic texture recognition using local binary patterns with an application to facial expressions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 29, n. 6, p. 915–928, June 2007. ISSN 0162-8828.

Apêndice A

Cálculo do LBP

O operador padrão binário (LBP) para análise textura local é definido como uma medida de textura invariante de escala de cinza, derivado de um definição geral de textura em uma vizinhança local.

O operador padrão binário (LBP) foi introduzido pela primeira vez como uma medida complementar para o contraste local da imagem (OJALA; PIETIKAINEN; MAENPAA, 2002). A primeira formação do operador foi utilizado com oito vizinhos, utilizando o valor do pixel central como um limiar.

Uma vez que o LBP, por definição é invariante para mudanças monotônicas na escala de cinza, foi implementada por uma medida ortogonal de contraste local.

O operador LBP permite detectar padrões binários locais uniformes em vizinhanças circulares de qualquer quantização do espaço angular e em qualquer resolução espacial. O operador é definido para um caso geral, com base em um conjunto circularmente simétrico de membros vizinhos P em um círculo de raio R , que é denotado por

$$LBP_{P,R}^{riu2} \tag{A.1}$$

em que P é o parâmetro que controla a quantização do espaço angular, enquanto que R determina a resolução espacial do operador e $u2$ consiste na definição de quantas transições são necessárias para o padrão binário seja uniforme (AHONEN; HADID; PIETIKAINEN, 2006). Por exemplo, um padrão $LBP_{8,2}^{riu2}$ consiste em um padrão cujo o raio do círculo é 2 pixels e a quantização angular é 8, ou seja, o espaço angular é dividido em 8 partes e o padrão binário é definido como homogêneo caso possua menos do que 2 transições entre 0 e 1 no número binário.

6	5	2
7	6	1
9	8	7

Figura A.1: exemplo de LBP (8,1).

Na Figura A.1 é ilustrado um exemplo de uma vizinhança de 1 *pixel* e quantização angular igual a 8. A partir desta região é aplicado uma limiarização utilizando o *pixel* central como limiar. O resultado deste limiar é ilustrado na Figura A.2.

1	0	0
1		0
1	1	1

Figura A.2: resultado da limiarização.

O padrão binário obtido é 11110001. Este padrão é homogêneo, pois possui 2 transições entre 0 e 1. Realizando a transformação deste valor para decimal é obtido o valor 241. Sendo este valor referente à um padrão homogêneo, é então incrementado o histograma correspondente à esta posição.